

UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO TECNOLÓGICO DE JOINVILLE  
CURSO DE ENGENHARIA DE TRANSPORTES E LOGÍSTICA

RICARDO BARRAVIERA GIGLIO

DESENVOLVIMENTO DE UMA PLATAFORMA PARA ANÁLISE FINANCEIRA E DE  
SENTIMENTO NO SETOR LOGÍSTICO: APLICAÇÕES DE MACHINE LEARNING E  
VISUALIZAÇÃO INTERATIVA

Joinville

2024

RICARDO BARRAVIERA GIGLIO

DESENVOLVIMENTO DE UMA PLATAFORMA PARA ANÁLISE FINANCEIRA E DE  
SENTIMENTO NO SETOR LOGÍSTICO: APLICAÇÕES DE MACHINE LEARNING E  
VISUALIZAÇÃO INTERATIVA

Trabalho apresentado como requisito para  
obtenção do título de bacharel em Engenharia  
de Transportes e Logística, no Centro  
Tecnológico de Joinville, da Universidade  
Federal de Santa Catarina.

Orientador: Dr. Pedro Paulo de Andrade

Joinville

2024

RICARDO BARRAVIERA GIGLIO

DESENVOLVIMENTO DE UMA PLATAFORMA PARA ANÁLISE FINANCEIRA E DE SENTIMENTO NO SETOR LOGÍSTICO: APLICAÇÕES DE MACHINE LEARNING E VISUALIZAÇÃO INTERATIVA

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do título de bacharel em Engenharia de Transportes e Logística, no Centro Tecnológico de Joinville, da Universidade Federal de Santa Catarina.

Joinville (SC), 06 de dezembro de 2024.

**Banca Examinadora:**

---

Presidente da Banca:  
Dr. Pedro Paulo de Andrade Junior

---

Dra. Francielly Hedler Staudt  
Membro(a)  
Universidade Federal de Santa Catarina

---

Raphael Beal Piovezan  
Membro(a)  
Universidade Federal de Santa Catarina

---

Rogério Furtado Queiroz  
Membro(a)  
Mackenzie-SP FIA-SP

Dedico este trabalho aos meus pais, amigos e professores que me acompanharam nessa  
jornada.

## **AGRADECIMENTOS**

Agradeço à empresa Horstkemper GmbH, a qual me introduziu à engenharia e excelência de processos especialmente ao Christopher e Norbert, à Robert Bosch que me permitiu estagiar nos setores logísticos na gestão de cargas críticas e posteriormente trabalhar no setor de Supplier Master Data. Agradeço também aos professores que me auxiliaram em todo o caminho do conhecimento e aos meus pais que viabilizaram o estudo em Joinville.

## RESUMO

Este trabalho apresenta o desenvolvimento de uma plataforma integrada para análise financeira e de sentimento no setor logístico, utilizando aprendizado de máquina e visualização interativa. O objetivo principal é aprimorar previsões financeiras, compreender o impacto de eventos e sentimentos do mercado no comportamento das ações, e apoiar decisões estratégicas. A metodologia adotada envolve a análise fundamentalista de indicadores financeiros (como P/L, *EV/EBITDA*, *ROE* e Margem Líquida), a previsão de preços de ações utilizando o modelo *Prophet*, e a análise de sentimento com técnicas avançadas de processamento de linguagem natural (*BERT*, *VADER* e *Zero-Shot*). Os dados foram coletados por meio das bibliotecas *Yfinance* e *NewsAPI*, integrados em *dashboards* interativos com ferramentas como *Plotly* e *Streamlit*. Os resultados mostram correlações estatisticamente significativas entre os sentimentos de mercado e as variações nos preços das ações. Além disso, a plataforma permite prever cenários futuros com maior precisão, contribuindo para estratégias mais eficazes de gestão e investimento. Esta pesquisa se destaca ao combinar diferentes dimensões analíticas, proporcionando um modelo para análise e tomada de decisões no setor logístico, com potencial de aplicação em mercados altamente dinâmicos e voláteis.

**Palavras-chave:** logística; análise fundamentalista; previsão de preços; análise de sentimentos; aprendizado de máquina; visualização interativa.

## ABSTRACT

This study presents the development of an integrated platform for financial and sentiment analysis in the logistics sector, utilizing machine learning and interactive visualization. The primary objective is to enhance financial forecasting, understand the impact of events and market sentiment on stock behavior, and support strategic decision-making. The methodology involves fundamental analysis of financial indicators (such as P/E, *EV/EBITDA*, *ROE*, and Net Margin), stock price forecasting using the *Prophet* model, and sentiment analysis with advanced natural language processing techniques (*BERT*, *VADER*, and *Zero-Shot*). Data was collected using the *Yfinance* and *NewsAPI* libraries, integrated into interactive *dashboards* with tools like *Plotly* and *Streamlit*. The results demonstrate statistically significant correlations between market sentiment and stock price variations. Additionally, the platform enables more accurate future scenario predictions, contributing to more effective management and investment strategies. This research stands out by combining different analytical dimensions, providing an innovative model for analysis and decision-making in the logistics sector, with potential applications in highly dynamic and volatile markets.

**Keywords:** logistics; fundamental analysis; price forecasting; sentiment analysis; machine learning; interactive visualization.

## LISTA DE FIGURAS

Figura 1 - Modelos de Análise de Sentimentos.....	29
Figura 2 Fluxograma do código de análise fundamentalista e previsões .....	32
Figura 3 - Fluxograma do código .....	32
Figura 4- Infográfico análise fundamentalista.....	37
Figura 5 - Indicadores fundamentalistas .....	39
Figura 6 - Código benchmarks análise fundamentalista .....	40
Figura 7 - Código obtenção de tickers.....	40
Figura 8 - Código avaliação indicadores fundamentalistas.....	40
Figura 9 - Código obtenção de indicadores fundamentalistas.....	41
Figura 10 - Modelo Prophet Original .....	42
Figura 11 - Cálculo da Tendência $g(t)$ do Prophet .....	43
Figura 12 - Cálculo da Sazonalidade Prophet .....	44
Figura 13 - Cálculo de Ruído Prophet.....	44
Figura 14 - Exemplo Cálculo Final Prophet.....	45
Figura 15 - Código função previsão de preços.....	46
Figura 16 - Pontuação dos Ajustes .....	54
Figura 17 - Ajuste e Conversão das pontuações.....	54
Figura 18 - Exemplo Cálculo Ajuste Base .....	55
Figura 19 - Impactos Adicionais Exemplo.....	56
Figura 20 - Modelo Prophet Ajustado .....	56
Figura 21 - Gráfico preço histórico x Projeção futura HBSA3.SA.....	68
Figura 22 -Gráfico preço histórico x projeção futura ALPK3.SA .....	68
Figura 23 - Gráfico preço histórico x projeção futura STBP3.SA .....	70
Figura 24 - Gráfico preço histórico x projeção futura RAPT4.SA .....	71
Figura 25 - Gráfico preço histórico x projeção futura LOGN3.SA.....	72
Figura 26 - Gráfico preço histórico x projeção futura ECOR3.SA .....	74
Figura 27 - Gráfico preço histórico x projeção futura ARML3.SA .....	75
Figura 28 - Gráfico preço histórico x projeção futura UGPA3.SA.....	76
Figura 29 - Gráfico preço histórico x projeção futura AZUL4.SA .....	77
Figura 30 - Gráfico preço histórico x projeção futura LOGG3.SA.....	77
Figura 31 - Gráfico preço histórico x projeção futura TGMA3.SA .....	78
Figura 32 - Gráfico preço histórico x projeção futura PORT3.SA .....	80
Figura 33 - Resultados consolidados.....	81
Figura 34 - Projeção otimizada x inicial x preço histórico HBS3.SA.....	85
Figura 35 - Projeção otimizada x inicial x preço histórico ALPK3.SA .....	86
Figura 36 - Projeção otimizada x inicial x preço histórico PORT3.SA .....	86
Figura 37 - Projeção otimizada x inicial x preço histórico JSLG3.SA .....	87
Figura 38 - Projeção otimizada x inicial x preço histórico STBP3.SA.....	88
Figura 39 - Projeção otimizada x inicial x preço histórico RAIL3.SA .....	89
Figura 40 - Projeção otimizada x inicial x preço histórico ECOR3.SA.....	89
Figura 41 - Projeção otimizada x inicial x preço histórico LOGG3.SA .....	90
Figura 42 - Projeção otimizada x inicial x preço histórico TGMA3.SA.....	91
Figura 43 - Projeção otimizada x inicial x preço histórico LOGN3.SA .....	92
Figura 44 - Projeção otimizada x inicial x preço histórico AZUL4.SA.....	92
Figura 45 - Projeção otimizada x inicial x preço histórico RAPT4.SA .....	93
Figura 46 - Projeção otimizada x inicial x preço histórico ARML3.SA.....	94



Figura 47 - Projeção otimizada x inicial x preço histórico UGPA3.SA.....	94
Figura 48 - Gráfico resultados ações histórico e otimizado x IBOVESPA.....	96
Figura 49 - Comando para inicializar a plataforma do código 1.py .....	104
Figura 50 - Solicitação da chave da <i>News API</i> .....	104
Figura 51- Tela inicial código 1.py .....	105
Figura 52 - Seleção individual de ações .....	105
Figura 53 - Selecionar todas as ações.....	106
Figura 54 - Análise fundamentalista .....	106
Figura 55 - Baixar análise fundamentalista .....	107
Figura 56 - Seleção do botão de projeções e análise de erros .....	107
Figura 57 - Exemplo da projeção dos gráficos do código 1.py .....	108
Figura 58 - Opções de visualização do gráfico .....	108
Figura 59- Erros das previsões do código 1.py .....	109
Figura 60 - Ações LOG-BR histórico e projeção.....	110
Figura 61 - SP500 histórico e projeção .....	110
Figura 62 - IBOVESPA histórico e projeção .....	111
Figura 63 - IPCA histórico e projeção.....	111
Figura 64- 100% CDI.....	112
Figura 65 - Projeções consolidadas código 1.py .....	112
Figura 66 - Exemplo de seleção de uma curva isolada no gráfico .....	113
Figura 67 - Inicialização do código main.py .....	113
Figura 68 - Exemplo de análise de uma notícia no código main.py .....	114
Figura 69 - Exemplo de análise de múltiplas notícias no código main.py .....	115
Figura 70 - Resultados análise de notícias com <i>BERT</i> .....	115
Figura 71 - Inicialização código otimizado.py .....	116
Figura 72 - Exemplo de gráfico gerado pelo otimizado.py .....	116
Figura 73 - Resultados consolidados projeção otimizada .....	117

## LISTA DE TABELAS

Tabela 1 – Definição Prophet.....	24
Tabela 2 - MAE, MSE, RMSE, MAPE, RMSPE.....	27
Tabela 3 – Escolha de ações para análise.....	34
Tabela 4 – Indicador fundamentalista P/L .....	61
Tabela 5 – Indicador fundamentalista <i>EV/EBITDA</i> .....	62
Tabela 6 – Indicador fundamentalista margem líquida.....	63
Tabela 7 – Indicador fundamentalista <i>ROE</i> .....	64
Tabela 8 – Erros de previsão análise preliminar .....	83
Tabela 9- Resultado dos erros otimizados.....	98

## LISTA DE ABREVIATURAS E SIGLAS

ABNT - Associação Brasileira de Normas Técnicas

ALPK3.SA - Ticker da Estapar Participações S.A.

ARCB - ArcBest Corporation

ARML3.SA - Ticker da Armac Locação, Logística e Serviços S.A.

ATSG - Air Transport Services Group, Inc.

AZUL4.SA - Ticker da Azul S.A.

BACEN - Banco Central

*BERT* - Bidirectional Encoder Representations from *Transformers*

CDI - Certificado de Depósito Interbancário

CCRO3.SA - Ticker da CCR S.A.

CHRW - C.H. Robinson Worldwide, Inc.

ECOR3.SA - Ticker da Ecorodovias Infraestrutura e Logística S.A.

*EV/EBITDA* - Valor da Empresa sobre o Lucro Antes de Juros, Impostos, Depreciação e Amortização

EXPD - Expeditors International of Washington, Inc.

FDX - FedEx Corporation

FWRD - Forward Air Corporation

GXO - GXO Logistics, Inc.

HBSA3.SA - Ticker da Hidrovias do Brasil S.A.

HRI - Herc Holdings Inc.

HTLD - Heartland Express, Inc.

IBOV - IBOVESPA

IFIL - Índice Financeiro Integrado com Indicadores Logísticos

IPCA - Índice Nacional de Preços ao Consumidor Amplo

JBHT - J.B. Hunt Transport Services, Inc.

KNX - Knight-Swift Transportation Holdings Inc.

LOGG3.SA - Ticker da Log Commercial Properties e Participações S.A.

LOGN3.SA - Ticker da Log-In Logística Intermodal S.A.

MAE - Mean Absolute Error (Erro Absoluto Médio)

MAPE - Mean Absolute Percentage Error (Erro Percentual Absoluto Médio)

MATX - Matson, Inc.

MSE - Mean Squared Error (Erro Quadrático Médio)

*NEWS API* - Interface de Programação de Aplicação para coleta de notícias

NLP - Natural Language Processing (Processamento de Linguagem Natural)

*Numpy* - Biblioteca Python para computação numérica

Pandas - Biblioteca Python para análise e manipulação de dados

PLN - Processamento de Linguagem Natural

PORT3.SA - Ticker da Wilson Sons Holdings Brasil S.A.

*Prophet* - Modelo de previsão de séries temporais desenvolvido pelo Facebook

P/L - Preço sobre Lucro

RAIL3.SA - Ticker da Rumo S.A.

RAPT4.SA - Ticker da Randon S.A. Implementos e Participações

RMSPE - Root Mean Squared Percentage Error (Erro Percentual Quadrático Médio)

RMSE - Root Mean Squared Error (Raiz do Erro Quadrático Médio)

*ROE* - Retorno sobre Patrimônio Líquido

SAIA - Saia, Inc.

SC - Santa Catarina

SIMH3.SA - Ticker da Simpar S.A.

SNDR - Schneider National, Inc.

STBP3.SA - Ticker da Santos Brasil Participações S.A.

*Streamlit* - Biblioteca para criação de interfaces web interativas

TGMA3.SA - Ticker da Tegma Gestão Logística S.A.

*Torch* - Biblioteca para aprendizado profundo

*Transformers* - Biblioteca para processamento de linguagem natural da Hugging Face

UFSC - Universidade Federal de Santa Catarina

UGPA3.SA - Ticker da Ultrapar Participações S.A.

UPS - United Parcel Service, Inc.

*Validators* - Biblioteca Python para validar URLs

VADER - Valence Aware Dictionary and sEntiment Reasoner

*Yfinance* - Biblioteca Python para acessar dados financeiros

*Zero-Shot* - Técnica de aprendizado para classificação sem necessidade de dados previamente rotulados

## SUMÁRIO

<b>1. Introdução .....</b>	<b>13</b>
1.1. Objetivo geral .....	14
1.2. Objetivos específicos .....	14
1.3 estrutura do trabalho .....	14
<b>2. Fundamentação teórica .....</b>	<b>17</b>
2.1. Logística, mercado financeiro e análise fundamentalista .....	17
2.3. Análise de sentimento e processamento de linguagem natural .....	27
2.4. Visualização de dados .....	29
<b>3. Metodologia .....</b>	<b>31</b>
3.1. Análise fundamentalista e coleta de dados .....	33
3.2. Previsão de preços .....	41
3.3. Análise de sentimento .....	48
3.4. Impacto de eventos e sentimentos nas ações .....	49
3.5. Visualização de dados e previsões otimizadas .....	50
<b>4. Resultados e discussões .....</b>	<b>60</b>
4.1. Resultados da previsão de preços .....	67
4.2. Resultados otimizados com <i>bert</i> .....	85
4.3. Integração dos resultados em dashboards .....	101
<b>5. A plataforma .....</b>	<b>103</b>
<b>6. Contribuições do estudo .....</b>	<b>118</b>
6.1 Limitações da pesquisa .....	118
6.2. Sugestões para trabalhos futuros .....	119
<b>7. Conclusões .....</b>	<b>121</b>
<b>Referências .....</b>	<b>123</b>

## 1. INTRODUÇÃO

O setor de logística tem ganhado muita importância na economia atual, não só pela sua função na cadeia de suprimento, mas também por seu efeito no mercado financeiro. O crescimento das empresas desse setor mostra uma necessidade de melhorias, como eficiência, inovação e competitividade.

Para investidores, é importante entender as variáveis financeiras as quais influenciam as ações dessas empresas, pois eles procuram boas oportunidades de investimento. No entanto, o setor enfrenta desafios na previsão do valor de suas ações devido à falta de ferramentas que combinem análise financeira e análise de sentimento, bem como à volatilidade das informações e dificuldades na previsão de preços futuros.

A análise de ações no setor logístico, portanto, é fundamental para assistir na tomada de decisões de investimento e oferece *insights* sobre como melhorar estratégias de gestão e operação para aumentar o desempenho.

O setor logístico foi escolhido por sua relevância estratégica para a economia global e seu papel na cadeia de suprimentos, afetando diretamente diversas outras indústrias. Segundo a Confederação Nacional do Transporte, o custo logístico em 2016 consumiu 12,7 do PIB do Brasil. Compreender as variáveis que influenciam esse setor permitem a otimização das operações logísticas, a competitividade e sustentabilidade das empresas envolvidas.

A pesquisa feita busca tratar de questões importantes que afetam a valorização das ações no setor logístico, como a previsão dos preços futuros e a influência do sentimento do mercado.

Os desafios enfrentados pelos investidores, muitas vezes, agravados por informações e notícias instáveis, precisam de soluções que combinem técnicas de seleção, classificação e melhoria contínua, como aprendizado de máquina, para a análise de dados ao longo do tempo, junto com métodos de análise de sentimento. Estes fatores são fundamentais para entender como as mudanças no humor do mercado podem afetar o valor das ações.

Este trabalho busca não apenas preencher lacunas na literatura, mas também fornece um modelo para que os analistas financeiros possam utilizar na prática, ajudando a tomar decisões de investimento mais informadas e estratégicas no setor logístico. A importância deste estudo sobre tecnologias de aprendizado de máquina e visualização de dados, neste trabalho atuará no espaço entre teoria e prática, oferecendo um sistema que facilita a análise e interpretação de informações essenciais para investidores e gestores. Esse sistema responde à

necessidade de dados precisos e ajuda a entender melhor os fatores que influenciam o comportamento das ações.

Como propor uma plataforma para análise financeira e de sentimento no setor logístico: aplicações de Machine Learning e visualização interativa?

### 1.1. OBJETIVO GERAL

Desenvolver uma plataforma integrada para análise financeira e de sentimento no setor logístico, utilizando aprendizado de máquina e visualização interativa, com foco em aprimorar previsões financeiras, compreender o impacto de eventos e sentimentos do mercado no comportamento das ações, e apoiar decisões estratégicas no setor

### 1.2. OBJETIVOS ESPECÍFICOS

- Analisar empresas do setor logístico utilizando indicadores fundamentalistas (como P/L, EV/ EBITDA e ROE), avaliando sua saúde financeira e identificando oportunidades para decisões assertivas de investimento;
- Aplicar modelos de previsão de séries temporais, como *Prophet*, para antecipar preços futuros de ações, considerando tendências e volatilidade, contribuindo para estratégias mais eficazes de investimento e gestão de riscos;
- Realizar análise de sentimento com base em notícias coletadas de fontes confiáveis, utilizando técnicas de processamento de linguagem natural (como *BERT*) para avaliar o impacto de eventos e opiniões públicas no desempenho das ações;
- Comparar previsões com modelos tradicionais de séries temporais com previsões que utilizam integração de análise de sentimento de notícias, visando avaliar a influência dos dados qualitativos na precisão dos resultados.

### 1.3 ESTRUTURA DO TRABALHO

Este estudo está estruturado em seis seções principais, desenvolvidas de forma a proporcionar uma abordagem lógica e detalhada que facilite a compreensão do tema e das metodologias empregadas. O objetivo desta organização é oferecer uma visão integrada do desenvolvimento de uma plataforma de análise financeira e de sentimento no contexto logístico,

utilizando ferramentas avançadas de aprendizado de máquina e técnicas de visualização interativa de dados. A seguir, apresenta-se uma síntese das seções que compõem este trabalho.

O Capítulo 1, “Introdução”, estabelece o contexto do estudo, explorando a relevância do setor logístico no cenário econômico e financeiro e destacando os desafios enfrentados, como a volatilidade de mercados e a complexidade na análise de dados. Neste capítulo, é definido o problema de pesquisa, com ênfase na necessidade de integração entre análises financeiras e de sentimento para embasar decisões estratégicas. São apresentados o objetivo geral do trabalho, que consiste no desenvolvimento de uma plataforma híbrida de análise, bem como os objetivos específicos e a estrutura do documento.

No Capítulo 2, “Fundamentação Teórica”, são discutidos os conceitos e teorias que fundamentam a pesquisa. A seção 2.1 examina a interação entre logística e mercado financeiro, ressaltando a importância de variáveis como flutuações cambiais e preços de commodities. A seção 2.2 aborda os indicadores financeiros e métodos de *valuation* aplicados no setor logístico, enquanto a seção 2.3 explora técnicas de previsão baseadas em séries temporais, com destaque para o uso do modelo *Prophet*. A seção 2.4 discute métodos de análise de sentimento, como *BERT* e *VADER*, e suas aplicações para mensuração do impacto de notícias e eventos no mercado financeiro. Finalmente, a seção 2.5 apresenta ferramentas de visualização interativa de dados, como *dashboards* criados com *Streamlit* e *Plotly*, demonstrando sua relevância no suporte à tomada de decisões.

O Capítulo 3, “Metodologia”, descreve detalhadamente as etapas do estudo, começando pela coleta de dados financeiros e de notícias relevantes, utilizando ferramentas como *Yfinance* e *web scraping*. Na seção 3.2, é apresentada a análise fundamentalista aplicada ao setor logístico, integrando os dados coletados com modelos preditivos baseados em aprendizado de máquina. A seção 3.3 detalha os procedimentos para análise de sentimento, empregando processamento de linguagem natural para identificar correlações entre eventos externos e a performance de empresas. Além disso, são descritas as tecnologias utilizadas no desenvolvimento da plataforma, destacando o uso de bibliotecas *Python* para assegurar uma integração robusta entre análise e visualização.

No Capítulo 4, “Resultados e Discussões”, são apresentados e analisados os principais achados da pesquisa. Os resultados das previsões de preços e da análise de sentimento são discutidos à luz das técnicas utilizadas, e as implicações para o setor logístico-financeiro são exploradas. É destacada a eficiência da integração de dados e o impacto positivo da visualização interativa na interpretação dos resultados.



O Capítulo 5, “A Plataforma”, detalha o desenvolvimento e as funcionalidades do sistema proposto, com foco em sua arquitetura técnica, usabilidade e aplicações práticas. A descrição enfatiza como a plataforma pode ser utilizada por tomadores de decisão no setor logístico.

No Capítulo 6, “Contribuições para o estudo”, são sintetizadas as principais contribuições do trabalho, destacando avanços na integração de métodos de análise financeira e de sentimento com suporte tecnológico. São discutidas as limitações enfrentadas e propostas direções futuras para expandir e aprimorar os modelos e a plataforma, abrangendo novas aplicações e setores econômicos.

Por fim, o Capítulo 7, "Conclusões", sintetiza os principais resultados e implicações deste estudo, destacando as contribuições para o campo acadêmico e para a prática no setor logístico-financeiro. Este capítulo apresenta uma análise crítica sobre os avanços alcançados com a plataforma desenvolvida, enfatizando a relevância de integrar análises financeiras e de sentimento com o suporte de ferramentas tecnológicas avançadas.

## 2. FUNDAMENTAÇÃO TEÓRICA

A importância do setor de logística aumentou nos últimos anos, especialmente pela sua ligação com o comércio global e o funcionamento das empresas. O crescimento da demanda por serviços logísticos acompanha o crescimento do e-commerce, demandando uma estrutura organizada e soluções novas.

Como dito em (Singh H et al., 2023), a capacidade de prever preços de ações pode ser afetada por fatores externos, como a visão do público sobre o setor, o que é importante para uma análise mais precisa. Além disso, a complexidade crescente do setor logístico faz da análise de dados um ponto importante para competir.

O uso de *machine learning* e técnicas de visualização de dados colabora na interpretação de grandes volumes de dados, o que permite que as empresas tomem decisões fundamentadas.

A união de dados financeiros e de sentimento pode mostrar uma visão do desempenho das organizações. O estudo em (Maalla A et al., 2019) destaca que, treinar pessoas em análise de dados é fundamental para o setor financeiro, o que enfatiza a necessidade de profissionais habilitados para interpretar grandes volumes de dados e organizá-los em deduções úteis.

A influência de fatores externos, como crises econômicas ou políticas, dificilmente pode ser prevista por modelos preditivos tradicionais, o que enfatiza a lacuna para estudo nesta área.

### 2.1. LOGÍSTICA, MERCADO FINANCEIRO E ANÁLISE FUNDAMENTALISTA

A logística ocupa posição de destaque no cenário econômico global, sendo um elemento-chave para a eficiência operacional e a competitividade organizacional. Sua relevância transcende o gerenciamento de fluxos físicos, envolvendo aspectos estratégicos que impactam diretamente a saúde financeira das empresas e sua capacidade de atender às demandas de um mercado altamente dinâmico e interconectado. Compreender a logística como uma componente estratégica é essencial para aprimorar a eficiência operacional e a satisfação dos clientes, conforme salientado por (Novaes, 2001).

Nesse contexto, a análise fundamentalista emerge como uma ferramenta indispensável para a avaliação do desempenho de empresas logísticas, permitindo uma abordagem detalhada e sistemática da sua estrutura financeira e operacional. Indicadores como Preço/Lucro (P/L),

*EV/EBITDA*, Margem Líquida e Retorno sobre o Patrimônio (*ROE*) fornecem subsídios críticos para o entendimento da lucratividade, eficiência e sustentabilidade de longo prazo.

No âmbito financeiro, a avaliação do desempenho das empresas de logística e transporte depende da análise de indicadores financeiros e da modelagem de *valuation*.

A modelagem financeira, que inclui projeções de fluxos de caixa e análises de sensibilidade, é crucial para determinar o valor econômico das empresas, apoiando decisões estratégicas e atraindo investidores (ETEMADIFAR et al., 2024). Deste modo, indicadores como liquidez, rentabilidade e alavancagem são indispensáveis para avaliar a capacidade das organizações de gerar lucro, manter a saúde financeira e mitigar riscos potenciais.

A avaliação de empresas no setor logístico envolve métodos complexos devido à multiplicidade de variáveis e modelos aplicáveis. Damodaran (2007) identifica quatro abordagens principais: avaliação baseada em ativos, fluxo de caixa descontado (FCD), avaliação relativa (múltiplos) e precificação de opções.

O FCD, amplamente utilizado, calcula o valor presente dos fluxos de caixa futuros descontados por uma taxa que reflete os riscos específicos da empresa e do mercado, sendo particularmente relevante no setor logístico pela necessidade de grandes investimentos em infraestrutura (DAMODARAN, 2007).

Martelanc, Pasin e Cavalcante (2010) ressaltam que a capacidade de gerar e distribuir fluxos de caixa operacionais está diretamente relacionada ao valor das empresas de logística, onde custos variáveis e investimentos elevados são predominantes.

A Avaliação por Múltiplos de Mercado oferece uma estimativa baseada em múltiplos financeiros de empresas similares, sendo vantajosa pela sua rapidez e intuição, embora suscetível a vieses de mercado em períodos de alta volatilidade (DAMODARAN, 2007.).

A integração desses aspectos logísticos e financeiros permite uma avaliação holística da saúde econômica e do potencial de crescimento das empresas do setor, considerando tanto fatores internos quanto externos que impactam suas operações. A aplicação de metodologias de *valuation*, como FCD, múltiplos de mercado e opções reais, em plataformas integradas para análise financeira e de sentimento, fundamenta a tomada de decisões estratégicas e a sustentabilidade das empresas no competitivo mercado logístico. Dessa forma, a interconexão entre logística e mercado financeiro, aliada a uma análise fundamentalista robusta, configura-se como um alicerce indispensável para a excelência operacional e o sucesso econômico das organizações no setor de transportes e logística.

Os componentes financeiros são essenciais para a avaliação do desempenho econômico das empresas de logística e transporte, incluindo modelagem financeira,

demonstrativos de resultado do exercício, *valuation*, metodologia de fluxo de caixa descontado, indicadores financeiros e parâmetros que os compõem.

A modelagem financeira desempenha um papel crucial no processo de valuation das empresas de logística, utilizando projeções financeiras e análises de sensibilidade para determinar o valor econômico das empresas. Este processo é essencial para suportar decisões estratégicas e atrair investidores. A complexidade envolvida na modelagem financeira requer uma compreensão aprofundada das variáveis que impactam o valor das empresas, especialmente em um setor tão dinâmico quanto o de logística (ETEMADIFAR et al., 2024).

Assim, os indicadores financeiros como liquidez, rentabilidade e alavancagem são cruciais para avaliar a performance financeira das empresas de logística. Esses indicadores ajudam a compreender a capacidade da empresa de gerar lucro, mantendo a saúde financeira e minimizando riscos potenciais.

A avaliação de empresas é um processo essencial e complexo no setor logístico, especialmente devido ao número de variáveis e modelos que podem ser aplicados. De acordo com Damodaran (2007), quatro abordagens principais se destacam: avaliação baseada em ativos, fluxo de caixa descontado (FCD), avaliação relativa (múltiplos) e precificação de opções. Cada abordagem envolve premissas e hipóteses que resultam em estimativas aproximadas do valor da empresa, sem garantir precisão absoluta.

O Fluxo de Caixa Descontado (FCD) é uma ferramenta amplamente utilizada para determinar o valor de mercado de empresas do setor logístico e definir estratégias de aquisição ou venda. Esse método calcula o valor presente dos fluxos de caixa futuros, descontados por uma taxa que reflete os riscos específicos da empresa e do mercado. A taxa de desconto utilizada geralmente é o Custo Médio Ponderado de Capital (WACC), que pondera o custo do capital próprio e de terceiros (DAMODARAN, 2007).

Existem três formas principais de analisar o FCD: fluxo de caixa do acionista (FCFE), fluxo de dividendos e fluxo de caixa da empresa (FCFF). O FCFF é o mais abrangente, pois abarca todos os elementos que afetam o valor da empresa, tanto operacionais quanto de financiamento (DAMODARAN, 2007). Isso é especialmente relevante no setor logístico, onde a complexidade operacional e a necessidade de grandes investimentos tornam a análise detalhada essencial para prever riscos e oportunidades.

O valor de uma empresa está diretamente relacionado à sua capacidade de gerar e distribuir fluxos de caixa operacionais, um ponto crucial para o setor de logística, que enfrenta custos variáveis e altos investimentos em infraestrutura. O FCD, portanto, permite uma análise

detalhada das oportunidades de criação de valor, sendo recomendado quando há expectativas de crescimento consistente e dados históricos suficientes para estimativas.

Outro método relevante para a avaliação de empresas é a Avaliação por Múltiplos de Mercado, que estima o valor com base em múltiplos financeiros de empresas similares. No setor logístico, essa abordagem pode ser vantajosa por ser intuitiva e rápida, mas é suscetível a manipulações e vieses de mercado, especialmente em períodos de alta volatilidade. (DAMODARAN, 2007) ressalta que, em mercados eficientes, os valores obtidos pela avaliação por múltiplos devem convergir com o valor calculado pelo FCD.

Por fim, a Avaliação por Opções Reais é uma técnica que captura a flexibilidade e a incerteza dos negócios, aspectos comuns no setor logístico, onde decisões sobre expansão ou abandono de projetos são frequentes. Esse modelo é útil em situações que envolvem altos níveis de incerteza e flexibilidade estratégica, complementando o FCD quando a empresa possui opções importantes de decisão.

No contexto do desenvolvimento de uma plataforma integrada para análise financeira e de sentimento do setor logístico, as metodologias de valuation, como FCD, múltiplos de mercado e opções reais, fornecem uma base sólida para avaliar a saúde financeira e o potencial de crescimento das empresas, considerando tanto fatores internos quanto externos que impactam suas operações.

Dentre estes há diversos indicadores que fazem parte de uma análise fundamentalista completa como Preço/Lucro (P/L), *EV/EBITDA*, Margem Líquida e Retorno sobre o Patrimônio (*ROE*)

O índice Preço/Lucro (P/L) constitui uma métrica amplamente utilizada na análise financeira, sendo considerada essencial na avaliação relativa de ativos corporativos. Sua relevância reside na capacidade de sintetizar, em um único indicador, a relação entre o preço de mercado de uma ação e o lucro líquido por ação da companhia. Assim, o índice P/L permite inferir, de maneira objetiva, o grau de valorização ou subvalorização atribuído às ações, com base nos resultados econômicos apresentados pela entidade.

De acordo com (PINHEIRO, 2001), o cálculo do índice P/L pode ser realizado com base tanto no lucro líquido mais recente quanto nas projeções de desempenho financeiro para o período em curso. Essa dualidade metodológica confere ao indicador uma flexibilidade analítica que facilita sua aplicação em diferentes contextos de avaliação. Ao adotar o lucro esperado como base de cálculo, é possível incorporar variáveis prospectivas que refletem as expectativas de crescimento e os fatores macROEconômicos relevantes, enquanto o uso do lucro histórico confere maior aderência aos resultados já realizados.

(DAMODARAN, 2006), em seus estudos sobre métricas financeiras, reforça a importância do índice P/L ao demonstrar que, ao longo de décadas, ações caracterizadas por múltiplos P/L reduzidos superaram, de forma sistemática, aquelas com múltiplos mais elevados. Ele destaca que, em alguns casos, as diferenças de retorno entre esses dois grupos superaram 70% ao ano, evidenciando o potencial subjacente de retornos expressivos em ativos que, no momento da avaliação, estavam subvalorizados pelo mercado.

Entretanto, é fundamental ressaltar que o índice P/L, quando analisado isoladamente, apresenta limitações e não deve ser utilizado como único parâmetro para a tomada de decisão. Apesar de sua relevância, ele não considera aspectos como a estrutura de capital, o risco operacional e o contexto setorial da empresa. Dessa forma, uma análise mais robusta exige a integração do P/L a outras métricas financeiras e informações qualitativas que, em conjunto, forneçam uma visão holística e fundamentada do ativo em questão.

O índice Preço/Lucro (P/L) é calculado a partir da relação entre o preço de mercado de uma ação e o lucro líquido por ação da empresa. A fórmula utilizada para determinar o P/L é apresentada

$$\frac{P}{L} = \frac{\text{Preço da ação no mercado}}{\text{Lucro líquido por ação}} \quad (1)$$

Enquanto o índice **Preço/Lucro (P/L)** é amplamente utilizado para avaliar a relação entre o preço da ação e o lucro líquido por ação da empresa, sua aplicabilidade pode ser limitada em situações onde o lucro líquido é negativo ou significativamente impactado por variáveis contábeis, como depreciação e amortização. Nesses casos, o múltiplo **Preço/EBITDA** surge como uma alternativa robusta e amplamente aceita pelos analistas financeiros.

Ao contrário do P/L, o índice *EV/EBITDA* utiliza como base o EBITDA, que representa o lucro operacional antes de juros, impostos, depreciação e amortização. Esse indicador elimina os efeitos de políticas contábeis e financeiras específicas, fornecendo uma visão mais clara da capacidade operacional da empresa de gerar caixa. Como destacado por Pinheiro (2001, p. 307):

"Há muito menos empresas com EBITDA negativo do que com lucro por ação negativo e, assim, um número menor de empresas é afastado da análise. (...) As diferenças entre os métodos de depreciação das empresas – algumas usam depreciação linear, outras depreciação acelerada – podem causar diferenças na receita operacional ou no faturamento líquido, mas não afetam o EBITDA  
Pinheiro (2001, p. 307):."

O Enterprise Value (EV), ou Valor de Mercado da Empresa, é um indicador abrangente que reflete o valor total de uma organização ao considerar tanto o capital próprio quanto as obrigações financeiras. Ele é calculado como a soma da capitalização de mercado – obtida pelo produto entre o preço das ações e o número de ações em circulação – e da dívida líquida, que corresponde ao total de dívidas da empresa subtraído de seu caixa e equivalentes de caixa. Esse indicador representa o custo efetivo necessário para adquirir a empresa, incorporando o valor atribuído pelo mercado às suas operações e obrigações financeiras.

Por sua vez, o EBITDA (Earnings Before Interest, Taxes, Depreciation, and Amortization), traduzido para o português como Lucro antes de Juros, Impostos, Depreciação e Amortização, ou simplesmente Lucro Operacional Bruto, é uma métrica que mede a capacidade de geração de caixa operacional da empresa. Ele exclui os impactos de decisões financeiras, tributárias e contábeis, fornecendo uma visão mais objetiva do desempenho das operações principais da organização. O cálculo do EBITDA é realizado com base na demonstração de resultados, destacando-se como uma ferramenta indispensável para análises comparativas entre empresas de diferentes setores e regimes tributários.

Ao combinar os dois indicadores, EV e EBITDA, por meio do múltiplo  $EV/EBITDA$ , os analistas financeiros conseguem avaliar de forma abrangente o valor de mercado de uma empresa em relação à sua capacidade de geração operacional de caixa. Este pode ser calculado da seguinte forma:

$$\frac{EV}{EBITDA} = \frac{\text{Valor de Mercado da Empresa}}{EBITDA} \quad (2)$$

Outro indicador amplamente destacado na literatura financeira é o Retorno sobre o Patrimônio Líquido ( $ROE$ ), citado por (DAMODARAN, 2008) como uma métrica que foca exclusivamente no componente de patrimônio líquido do investimento. De acordo com o autor, "o retorno sobre o patrimônio líquido relaciona os lucros disponíveis para os investidores de patrimônio, após os custos de serviço da dívida terem sido considerados, ao patrimônio investido no ativo. A definição contábil de retorno sobre o patrimônio reflete isso". Assim, o  $ROE$  avalia a eficiência com que a empresa utiliza os recursos de seus acionistas para gerar lucro.

De acordo com KAHNEMAN, Daniel; TVERSKY, a fórmula do  $ROE$  pode ser calculada como:

$$ROE = \frac{\text{Lucro Líquido}}{\text{Patrimônio Líquido Contábil}} \quad (3)$$

Dessa forma, ao explorar a interseção entre logística, mercado financeiro e análise fundamentalista, fica evidente a relevância de indicadores financeiros e metodologias de valuation para compreender a saúde econômica e operacional de empresas do setor logístico. Ferramentas como o Fluxo de Caixa Descontado (FCD), múltiplos de mercado (como *EV/EBITDA* e Preço/Lucro), Margem Líquida e Retorno sobre o Patrimônio Líquido (*ROE*) oferecem subsídios robustos para avaliar não apenas a lucratividade e eficiência operacional, mas também o potencial de crescimento e sustentabilidade de longo prazo das organizações.

A aplicação integrada dessas métricas possibilita uma análise mais holística, permitindo a tomada de decisões estratégicas fundamentadas em dados concretos e alinhadas às exigências de um mercado cada vez mais competitivo e dinâmico. Assim, a combinação de elementos logísticos e financeiros não apenas fortalece a excelência operacional das empresas, mas também consolida sua posição no mercado, atendendo às demandas de stakeholders e investidores.

## 2.2. MODELOS DE PREVISÃO

As técnicas de previsão de séries temporais são fundamentais para modelar e antecipar comportamentos em diferentes contextos, incluindo o setor financeiro e logístico. Segundo Borges (2024), métodos como o Alisamento Exponencial, Redes Neurais e o Facebook *Prophet* têm se destacado pela capacidade de lidar com dados sequenciais e identificar padrões ao longo do tempo.

O Alisamento Exponencial é conhecido por sua simplicidade e aplicabilidade em dados que apresentam padrões sazonais bem definidos, enquanto as Redes Neurais oferecem maior flexibilidade para captar relações não lineares. Já o Facebook *Prophet*, desenvolvido para simplificar a criação de previsões, é especialmente útil para séries temporais com sazonalidades complexas e múltiplos eventos de impacto, sendo uma alternativa eficaz para modelar dados no setor logístico, onde fatores como demanda e variações de custo precisam ser considerados (BORGES, 2024).

O modelo *Prophet* é uma ferramenta de código aberto desenvolvida pelo Facebook, amplamente utilizada para a previsão de séries temporais, principalmente em contextos onde os dados possuem uma sazonalidade bem definida.



Tabela 1 – Definição Prophet

<b>O que é o Prophet</b>	Modelo aditivo de previsão de séries temporais desenvolvido pelo Facebook, focado em lidar com sazonalidades e tendências complexas.
<b>Componentes do Modelo</b>	<ul style="list-style-type: none"> <li>• <math>g(t)</math>: Componente de tendência.</li> <li>• <math>s(t)</math>: Componente sazonal.</li> <li>• <math>h(t)</math>: Efeitos de eventos externos (feriados, campanhas, etc.).</li> <li>• <math>\epsilon_t</math>: Ruído ou erro aleatório.</li> </ul>

Fonte: Autor (2024)

De acordo com Corrêa (2024), o *Prophet* se destaca pela flexibilidade em acomodar múltiplas sazonalidades e por não exigir que a série temporal tenha períodos regulares, o que facilita seu uso em cenários complexos, como a previsão de preços de ativos financeiros. Além disso, uma vantagem significativa do *Prophet* em relação a outros modelos, como o ARIMA, é a facilidade de ajuste e a robustez em relação a mudanças bruscas de tendência, proporcionando previsões mais precisas em ambientes de alta volatilidade, como os mercados de criptomoedas. No setor logístico, essa metodologia pode ser utilizada para prever variações de preços e custos, ajudando na tomada de decisões estratégicas e na otimização de recursos (CORRÊA, 2024).

O uso do modelo *Prophet* para previsão de preços e outras séries temporais no mercado logístico apresenta diversas vantagens e algumas limitações. Segundo Mendes (2023), o *Prophet* é uma ferramenta flexível que se destaca pela capacidade de incorporar sazonalidades anuais, semanais e diárias, o que é especialmente útil no setor logístico, caracterizado por flutuações periódicas na demanda e na operação. A facilidade de ajuste de parâmetros e a capacidade de lidar com dados ausentes são pontos fortes que permitem sua aplicação em cenários complexos, sem a necessidade de interpolar valores faltantes, o que é comum em registros de operações logísticas. Além disso, a velocidade de processamento do *Prophet* possibilita o ajuste rápido a novos dados, tornando-o adequado para a natureza dinâmica do setor (MENDES, 2023).

Por outro lado, as limitações incluem a dependência de sazonalidades bem definidas, o que pode dificultar a previsão precisa em cenários com variações atípicas ou sem padrões sazonais claros. Além disso, como o *Prophet* é baseado em um modelo aditivo, ele pode não capturar adequadamente certas não-linearidades que surgem de relações complexas entre diferentes fatores que afetam a logística, como mudanças abruptas em preços de combustíveis ou regulamentações inesperadas (MENDES, 2023). Para superar essas limitações, Mendes (2023) sugere a combinação do *Prophet* com outros modelos de aprendizado de máquina, como árvores de decisão, para melhor lidar com a variabilidade e complexidade dos dados do setor.

De acordo com (KUHN, 2013) Na análise preditiva, quando o objetivo é prever variáveis numéricas, métricas quantitativas como o Erro Quadrático Médio (RMSE) desempenha um papel central para avaliar a precisão e a qualidade do modelo. Essas medidas são amplamente aplicadas em problemas de regressão por fornecerem uma avaliação robusta da capacidade explicativa e preditiva dos modelos.

O RMSE é uma métrica derivada dos resíduos do modelo, que representam as diferenças entre os valores observados e as previsões realizadas. Sua obtenção requer inicialmente o cálculo do Erro Médio Quadrático (MSE), que consiste em elevar ao quadrado os resíduos, somá-los e dividir pelo número total de observações. Posteriormente, calcula-se a raiz quadrada do MSE, garantindo que o RMSE seja expresso na mesma unidade das variáveis originais. Esse indicador é interpretado como uma estimativa da distância média entre as previsões do modelo e os valores observados, o que o torna uma métrica intuitiva para compreender a magnitude do erro preditivo (KUHN e JOHNSON, 2013). Essa explicação constitui uma paráfrase do trabalho dos autores, com reorganização das ideias para maior fluidez.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

O MAE (Mean Absolute Error) e o MAPE (Mean Absolute Percentage Error) são métricas amplamente utilizadas para medir a precisão de modelos de previsão. O MAE calcula o erro absoluto médio entre os valores reais e previstos. Segundo Willmott e Matsuura (2005), o MAE tem a vantagem de ser mais simples e intuitivo do que outras métricas, como o RMSE

(Root Mean Square Error). Ele não penaliza erros grandes de forma desproporcional, o que o torna particularmente útil em contextos em que é mais importante avaliar a magnitude do erro absoluto de maneira uniforme, sem dar um peso excessivo aos erros mais graves. Esse comportamento é vantajoso quando o objetivo é evitar que os erros extremos influenciem fortemente a avaliação do modelo.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \times 100 \quad (7)$$

Onde:

$y_i$ : Valor real no momento  $i$  (deve ser diferente de zero);

$\hat{y}_i$ : Valor previsto no momento  $i$ ;

$n$ : número total de observações.

Tabela 2 - MAE, MSE, RMSE, MAPE, RMSPE

Erro	Cálculo	Diferenças e Justificativa
MAE (Mean Absolute Error)	$\text{MAE} = \frac{1}{n} \sum_{i=1}^n  y_i - \hat{y}_i $	Mede a magnitude média do erro absoluto. Não penaliza grandes erros desproporcionalmente, sendo útil em casos onde se busca uniformidade na avaliação do erro.
MSE (Mean Squared Error)	$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$	Penaliza erros maiores de forma quadrática. Útil para identificar desvios significativos, mas pode ser sensível a outliers. Complementa o MAE ao fornecer outra perspectiva dos erros.
RMSE (Root Mean Squared Error)	$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	Mede a raiz quadrada do MSE, mantendo as unidades originais dos dados. Amplifica grandes erros, sendo ideal para cenários em que erros extremos são críticos.
MAPE (Mean Absolute Percentage Error)	$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left  \frac{y_i - \hat{y}_i}{y_i} \right $	Expressa o erro médio em porcentagem. É sensível a valores reais muito baixos, mas ajuda na interpretação relativa da precisão. Útil para análises comparativas entre modelos.
RMSPE (Root Mean Squared Percentage Error)	$\text{RMSPE} = \sqrt{\frac{100}{n} \sum_{i=1}^n \left( \frac{y_i - \hat{y}_i}{y_i} \right)^2}$	Similar ao MAPE, mas amplifica os erros percentuais mais altos devido à elevação ao quadrado. Essencial para cenários onde grandes discrepâncias percentuais são críticas.

Fonte: Autor (2024)

### 2.3. ANÁLISE DE SENTIMENTO E PROCESSAMENTO DE LINGUAGEM NATURAL

A análise de sentimento, uma técnica do processamento de linguagem natural (PLN), visa extrair informações subjetivas de textos, classificando-os como positivos, negativos ou neutros, o que pode auxiliar em decisões estratégicas de negócios. Segundo Nunes et al. (2021), o PLN possibilita a análise automatizada de grandes volumes de dados textuais oriundos de mídias sociais e notícias, transformando opiniões dispersas em insights úteis para investidores. No setor logístico, essas técnicas podem ser usadas para monitorar o sentimento em torno de

temas relevantes, como flutuações nos preços dos combustíveis ou novas regulamentações, auxiliando gestores a se adaptarem rapidamente a mudanças de cenário. Ferramentas como a API TextBlob têm se mostrado eficazes na extração de polaridade, oferecendo um suporte importante para a tomada de decisão baseada em dados de sentimento em tempo real (NUNES et al., 2021).

As técnicas de Processamento de Linguagem Natural (PLN) são fundamentais para lidar com o crescente volume de dados textuais gerados diariamente. Modelos como o *BERT* (Bidirectional Encoder Representations from *Transformers*), o VADER (Valence Aware Dictionary and sEntiment Reasoner) e a abordagem Zero Shot Learning são amplamente utilizados para tarefas de análise de sentimentos e classificação de textos. Segundo (CUNHA, 2024), o *BERT* é um dos modelos mais poderosos para classificação automática de texto, permitindo a compreensão contextual de sentenças de forma bidirecional. Essa característica possibilita um alto nível de precisão ao classificar documentos em categorias específicas, sendo amplamente utilizado em aplicações que exigem análise profunda do conteúdo textual. Já o VADER é uma ferramenta mais simples, ideal para análises rápidas de sentimentos, especialmente em textos curtos e informais, como postagens em redes sociais. A técnica de Zero Shot Learning, por sua vez, é usada para categorizar textos em classes não vistas durante o treinamento, permitindo flexibilidade e aplicabilidade em contextos novos sem a necessidade de grandes volumes de dados rotulados. Essas ferramentas, combinadas, são capazes de melhorar significativamente a eficiência e a precisão na análise de grandes volumes de textos, contribuindo para uma melhor tomada de decisão em setores que dependem de informações textuais, como o setor logístico (CUNHA, 2024).

O sentimento de mercado tem se mostrado um fator relevante na previsão de preços de ativos financeiros, principalmente aqueles de alta volatilidade. Segundo Braga (2023), a integração de índices de sentimento, pode contribuir significativamente para a melhoria dos modelos de previsão de preços, pois reflete a atenção do público e os níveis de interesse em determinados ativos. No setor financeiro, esse tipo de análise pode ser útil para prever flutuações de preços de ações, garantindo maior precisão nas decisões de alocação de recursos e gerenciamento de riscos (BRAGA, 2023).

Figura 1 - Modelos de Análise de Sentimentos

Modelo	Definição	O que Faz	Uso Ideal
Zero-Shot Learning	Abordagem de aprendizado que permite classificar textos em categorias que não foram vistas durante o treinamento.	Permite categorizar textos em novas classes sem a necessidade de treinamento adicional.	Útil em cenários com dados limitados ou em constante mudança, como identificação de tópicos emergentes.
BERT (Bidirectional Encoder Representations from Transformers)	Modelo de linguagem baseado em redes neurais que compreende contexto de forma bidirecional.	Realiza tarefas de NLP como classificação de texto, respostas a perguntas e análise de sentimentos.	Ideal para aplicações que demandam compreensão profunda do texto, como análise contextual em notícias ou relatórios.
FinBERT	Varição do BERT treinada especificamente para textos financeiros.	Realiza análise de sentimentos, classificação e interpretação de textos financeiros.	Adequado para análise de mercado, notícias financeiras e relatórios empresariais.
VADER (Valence Aware Dictionary and sEntiment Reasoner)	Modelo de análise de sentimentos baseado em dicionários e regras de polaridade.	Classifica textos curtos como positivos, negativos ou neutros, utilizando uma abordagem leve e rápida.	Perfeito para textos informais, como postagens em redes sociais e comentários curtos.

Fonte: Autor (2024)

## 2.4. VISUALIZAÇÃO DE DADOS

A visualização interativa de dados é uma ferramenta poderosa para a análise e compreensão de grandes volumes de informações, particularmente no mercado financeiro. A classificação de dados permite a representação clara de padrões, tendências e anomalias por meio de gráficos dinâmicos e dashboards, facilitando a tomada de decisão para gestores. No contexto logístico-financeiro, a utilização de tecnologias de visualização como Power BI, Tableau e bibliotecas de programação, como *Plotly*, permite explorar e compreender os dados de mercado de forma visual e intuitiva.

Inspirando-se na proposta de visualização interativa de trajetórias de aprendizagem (NASCIMENTO e FERREIRA, 2005), o uso de representações gráficas também pode ser adaptado ao setor financeiro, proporcionando uma visão clara sobre o comportamento das ações de empresas do setor logístico ao longo do tempo. Isso inclui a análise dos preços, a identificação de pontos críticos e a observação do impacto de eventos específicos no valor de mercado de uma empresa. A utilização de tais tecnologias facilita não apenas a análise em

tempo real, mas também a adaptação de estratégias conforme mudanças no mercado, contribuindo para uma melhor alocação de recursos e mitigação de riscos financeiros.

Ferramentas que suportam a visualização interativa de dados também permitem a integração com tecnologias de suporte, como computação em nuvem e bancos de dados em tempo real, garantindo que as informações estejam sempre atualizadas e disponíveis para os usuários. Essa combinação de elementos visuais e tecnologias de suporte amplia a capacidade dos gestores de tomar decisões baseadas em dados, garantindo competitividade e eficiência em um mercado financeiro dinâmico e volátil.

No mercado financeiro voltado ao setor logístico, os *dashboards* são ferramentas essenciais para a visualização e análise dos dados em tempo real. Eles permitem o monitoramento eficaz dos indicadores-chave de performance (KPIs), facilitando a compreensão de tendências de mercado, flutuações de preço e desempenho de ações de empresas do setor logístico. Segundo (CARVALHO, 2020), a criação de painéis interativos para monitorar indicadores de produção não só melhora a visualização dos dados, mas também auxilia na tomada de decisão de forma mais rápida e precisa, trazendo agilidade para um ambiente caracterizado por alta volatilidade e dinamismo.

Essas centrais de dados permitem a integração de diferentes fontes de dados, oferecendo uma visão consolidada do desempenho financeiro e logístico de uma empresa. No contexto financeiro,. Assim, as empresas do setor logístico podem reagir rapidamente a mudanças no mercado, garantindo uma vantagem competitiva e a eficiência necessária para lidar com desafios de gestão de recursos e previsões de demanda (CARVALHO, 2020).

No contexto do setor financeiro para o mercado logístico, a visualização de dados desempenha um papel fundamental para entender e analisar grandes volumes de informações de forma eficiente. Ferramentas como *Streamlit* e *Plotly* são amplamente utilizadas para criar *dashboards* e gráficos interativos que facilitam a interpretação de dados complexos.

*Plotly* é uma biblioteca gráfica de código aberto desenvolvida para a criação de gráficos interativos. Ela permite a visualização intuitiva de dados financeiros, possibilitando a exploração de séries temporais e a análise do comportamento de preços de ações ao longo do tempo. No setor logístico, *Plotly* pode ser usado para acompanhar métricas como custos de transporte, preços de insumos e desempenho financeiro de empresas do setor, contribuindo para uma análise mais precisa e interativa.

Já o *Streamlit* é uma biblioteca que facilita o desenvolvimento de aplicativos web interativos para visualização de dados e aprendizado de máquina. Com ele, é possível criar interfaces intuitivas para explorar dados financeiros, tornando os insights acessíveis para

gestores e equipes de decisão. Essas ferramentas combinadas oferecem um ambiente de análise dinâmico e colaborativo, essencial para o acompanhamento das condições do mercado e para a tomada de decisões informadas no setor logístico (BEZERRA, 2023).

Deste modo, a fundamentação teórica evidencia a importância do setor logístico no contexto financeiro, destacando a integração de análises financeiras, preditivas e de sentimento para avaliar o desempenho e o potencial de crescimento das empresas. Ferramentas como valuation, processamento de linguagem natural e visualização de dados foram apresentadas como essenciais para lidar com a volatilidade e complexidade do mercado, apoiando decisões estratégicas e a eficiência operacional.

### 3. METODOLOGIA

A pesquisa feita neste trabalho usa uma abordagem diversificada para analisar indicadores financeiros e o sentimento do mercado sobre empresas do setor logístico. A metodologia é composta por etapas simples e organizadas que envolvem a coleta de dados financeiros e de notícias. Para os dados financeiros, foi utilizada a biblioteca *Yfinance*, que permite acesso a informações sobre ações de forma confiável. Para as notícias, a *NewsAPI* ajudou a coletar informações relevantes, de forma automática e constante.

Essa abordagem é importante para criar um sistema de análise que capture as dinâmicas do setor, conforme mostrado na pesquisa (VACCARO et al., 2024). Depois da captura de dados, foi realizada uma análise fundamentalista combinada com conceitos de análise gráfica para o mercado financeiro, para gerar as previsões iniciais com o modelo *Prophet*. Posteriormente, foram calculados os erros para estimar a precisão das projeções preliminares.

Depois da análise inicial as notícias são tratadas no código pela modelo facebook/bart-large-mnli, o qual detecta notícias potencialmente falsas e atribui uma pontuação para ser removida da análise.



Com as notícias coletadas e tratadas, foi utilizado *BERT*(Bidirectional Encoder Representations from *Transformers*), um modelo de rede neural, para processamento de linguagem natural (NLP) na sua variação *FinBERT* (especializada para análises financeiras). Este atribui uma pontuação a cada notícia de acordo com sua análise de sentimento.

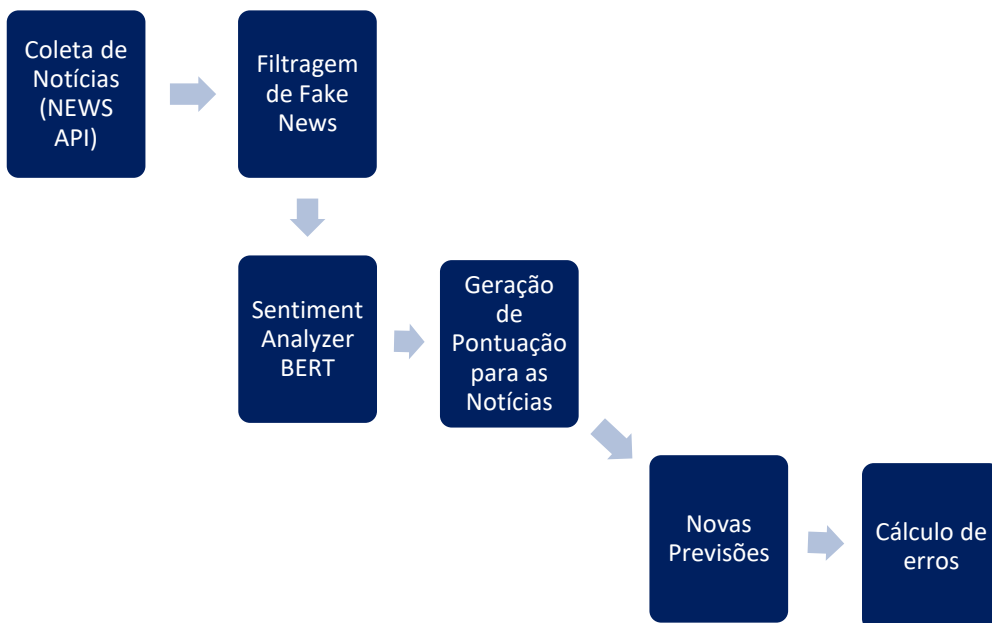
Por fim, foram integrados nos modelos iniciais as pontuações obtidas pelas notícias e novos gráficos com previsões atualizadas foram gerados junto com o cálculo dos erros.

Figura 2 Fluxograma do código de análise fundamentalista e previsões



Fonte: Autor (2024)

Figura 3 - Fluxograma do código de análise de sentimentos e otimização de previsões



Fonte: Autor (2024)

### 3.1. ANÁLISE FUNDAMENTALISTA E COLETA DE DADOS

Um ponto chave no desenvolvimento de qualquer projeto de análise de dados é escolher as técnicas certas para coleta de dados. Nesse sentido, métodos como web scraping e APIs são muito importantes. Por exemplo, para coletar dados financeiros, a biblioteca *Yfinance* permite acessar informações históricas de ações de forma prática, assegurando que os dados sejam precisos e atualizados.

Para notícias, a *NewsAPI* é uma ferramenta consolidada que busca por notícias automaticamente de acordo com instruções realizadas pelo usuário. Essa coleta de informações constante é vital não só para análise de sentimentos, mas também para relacionar eventos noticiosos e mudanças nos preços das ações, mostrando a necessidade de uma coleta de dados planejada para fundamentar análises posteriores.

Além disso, a precisão na coleta de dados impacta diretamente a qualidade das análises que serão feitas. As técnicas usadas devem levar em conta várias variáveis e fontes, já que dados unidimensionais podem causar erros nas conclusões. A análise fundamentalista, por exemplo, precisa de dados sobre indicadores como P/L, *EV/EBITDA* e Margem Líquida, que devem ser coletados de forma sistemática e rigorosa. Além disso, a necessidade de respostas a um ambiente dinâmico no setor logístico aumenta a importância de manter uma coleta de dados contínua e automatizada. Assim, as tecnologias e técnicas escolhidas não só permitem acesso à informação, mas também garantem que as análises sejam baseadas em um volume de dados representativo e relevante para decisões.

Por fim, o uso de técnicas de coleta de dados impacta no desenvolvimento da interface e a visualização dos resultados. A integração de dados financeiros e de sentimento, por exemplo, pode ser apresentada com visualizações interativas usando ferramentas como *Plotly*, que tornam as análises mais acessíveis e fáceis de entender. Essa abordagem é crucial para envolver investidores e gestores, que precisam de informações claras e úteis para suas decisões estratégicas.

Por meio da visualização de dados, é possível identificar tendências, correlações e anomalias de forma rápida e eficaz, criando um ambiente mais ágil para análise. Portanto, a conexão entre a coleta de dados e a visualização é essencial para a eficácia do trabalho, conforme discutido na importância de uma abordagem integrada de técnicas de Machine Learning (Rolnick D et al., 2022).

A coleta de dados financeiros foi realizada por meio da biblioteca *Yfinance*, uma ferramenta amplamente utilizada que facilita o acesso a informações financeiras de forma

prática e eficiente. Essa biblioteca permite a obtenção de dados financeiros fornecidos pelo Yahoo Finance. Nela há uma grande variedade de dados sobre ativos do mercado.

A biblioteca *Yfinance* possui funcionalidades que permitem o acesso a cotações atualizadas (com atraso de 15 minutos do mercado financeiro), dados históricos de preços, volume de negociações, dividendos, desdobramentos de ações, entre outras estatísticas essenciais. Além disso, o *Yfinance* possibilita a coleta de informações sobre o desempenho financeiro de empresas, como demonstrações de resultados, balanços patrimoniais e fluxo de caixa, o que o torna uma ferramenta valiosa para análises quantitativas e para a tomada de decisão em investimentos.

Por meio do desta, é possível realizar uma coleta de dados abrangente, incluindo a extração de informações históricas detalhadas que podem ser utilizadas em modelos de previsão, como os de aprendizado de máquina (machine learning), para prever tendências futuras ou compreender comportamentos passados.

Inicialmente foram encontradas 43 empresas que poderiam ser relevantes para estudo entretanto, após análise, foi decidido remover as ações do mercado estado-unidense, devido a diferenças estruturais e de mercado entre os dois países, que poderiam limitar a aplicabilidade dos resultados.

Foram removidas também empresas que passaram por recuperações judiciais ou passaram por reestruturações contábeis entre os anos de 2020 e 2024 devido a frequentes distorções nos indicadores financeiros devido à reestruturação de dívidas e outras medidas contábeis.

Por fim, foi optado por excluir a empresa IOCHP Maxion, por conta da sua principal atuação em peças automotivas e não diretamente em transporte, armazenagem ou outras categorias logísticas estudadas.

Tabela 3 – Escolha de ações para análise

Nome	Ticker	Setor	Status		BR
JSL S.A.	JSLG3.SA	Logística	Operante	MANTER	BR
Tegma Gestão Logística S.A.	TGMA3.SA	Logística	Operante	MANTER	BR
Rumo S.A.	RAIL3.SA	Logística	Operante	MANTER	BR
Wilson Sons Holdings Brasil S.A.	PORT3.SA	Logística Portuária	Operante	MANTER	BR
Santos Brasil Participações S.A.	STBP3.SA	Logística Portuária	Operante	MANTER	BR

Ecorodovias Infraestrutura e Logística S.A.	ECOR3.SA	Infraestrutura Rodoviária	Operante	MANTER	BR
Log-In Logística Intermodal S.A.	LOGN3.SA	Logística Intermodal	Operante	MANTER	BR
Sequoia Logística e Transportes S.A.	SEQL3.SA	Logística e Transportes	Recuperação Judicial	REMOVED	BR
Armac Locação, Logística e Serviços S.A.	ARML3.SA	Logística e Locação	Operante	MANTER	BR
Ultrapar Participações S.A.	UGPA3.SA	Logística e Distribuição	Operante	MANTER	BR
Simpar S.A.	SIMH3.SA	Logística e Serviços	Possível Recuperação Subsidiária	REMOVED	BR
Estapar Participações S.A.	ALPK3.SA	Estacionamentos	Operante	MANTER	BR
CCR S.A.	CCRO3.SA	Infraestrutura Rodoviária	Operante	MANTER	BR
Hidroviás do Brasil S.A.	HBSA3.SA	Transporte Hidroviário	Operante	MANTER	BR
Log Commercial Properties e Participações S.A.	LOGG3.SA	Logística Imobiliária	Operante	MANTER	BR
Randon S.A. Implementos e Participações	RAPT4.SA	Transporte e Equipamentos	Operante	MANTER	BR
IOCHP-Maxion S.A.	MYPK3.SA	Automotivo (Chassis, Peças)	Operante	REMOVED	BR
Azul S.A.	AZUL4.SA	Aviação	Operante	MANTER	BR
Gol Linhas Aéreas Inteligentes S.A.	GOLL4.SA	Aviação	Recuperação Judicial	REMOVED	BR
United Parcel Service, Inc.	UPS	Logística	Operante	REMOVED	US
FedEx Corporation	FDX	Logística	Operante	REMOVED	US
XPO Logistics, Inc.	XPO	Logística	Reestruturação	REMOVED	US
C.H. Robinson Worldwide, Inc.	CHRW	Logística	Operante	REMOVED	US
Expeditors International of Washington, Inc.	EXPD	Logística	Operante	REMOVED	US
J.B. Hunt Transport Services, Inc.	JBHT	Logística e Transportes	Operante	REMOVED	US
Old Dominion Freight Line, Inc.	ODFL	Transporte Rodoviário	Operante	REMOVED	US
Ryder System, Inc.	R	Transporte e Logística	Operante	REMOVED	US

Landstar System, Inc.	LSTR	Transporte Rodoviário	Operante	REMOVER	US
Hub Group, Inc.	HUBG	Logística e Transportes	Operante	REMOVER	US
Schneider National, Inc.	SNDR	Transporte Rodoviário	Operante	REMOVER	US
Werner Enterprises, Inc.	WERN	Transporte Rodoviário	Operante	REMOVER	US
Knight-Swift Transportation Holdings Inc.	KNX	Transporte Rodoviário	Operante	REMOVER	US
Saia, Inc.	SAIA	Transporte Rodoviário	Operante	REMOVER	US
ArcBest Corporation	ARCB	Transporte e Logística	Operante	REMOVER	US
Forward Air Corporation	FWRD	Logística	Operante	REMOVER	US
Heartland Express, Inc.	HTLD	Transporte Rodoviário	Operante	REMOVER	US
Matson, Inc.	MATX	Transporte Marítimo	Operante	REMOVER	US
Herc Holdings Inc.	HRI	Logística	Operante	REMOVER	US
GATX Corporation	GATX	Transporte e Locação	Operante	REMOVER	US
Air Transport Services Group, Inc.	ATSG	Transporte Aéreo	Operante	REMOVER	US
U-Haul Holding Company	UHAL	Transporte e Locação	Operante	REMOVER	US
GXO Logistics, Inc.	GXO	Logística	Operante	REMOVER	US

Fonte: Autor (2024)

A coleta de notícias foi realizada utilizando a *News API*, uma interface que permite acessar notícias de diversas fontes em tempo real. Esta plataforma permite a coleta de notícias de fontes diversas, isso. Esta é uma etapa muito importante para o desenvolvimento deste trabalho, visto que, a coleta constante e em massa de notícias alimentará a base de dados, que, será posteriormente analisada para gerar as previsões.

Com a *News API*, é possível obter notícias de diferentes categorias e regiões, filtrando por palavras-chave específicas, no caso deste estudo, relacionadas ao setor logístico e financeiro. Esse processo de coleta auxilia na identificação de eventos que possam impactar o mercado.

Os dados coletados são muito importantes para a análise de sentimentos deste trabalho, a qual, busca compreender como eventos e opiniões públicas influenciam o desempenho das ações. Com as técnicas de processamento de linguagem natural, como o *VADER*, *BERT* e

modelos de classificação *Zero-Shot*, é possível analisar o conteúdo das notícias e determinar sua polaridade (positiva, negativa ou neutra).

A integração dos dados financeiros obtidos via *Yfinance* com as notícias coletadas pela *News API* cria uma base para a análise preditiva e de sentimento, proporcionando uma visão abrangente dos fatores que influenciam o desempenho das empresas e auxiliam na tomada de decisões estratégicas.

Segundo (DAMODARAN, 2012), a análise fundamentalista consiste na avaliação do valor intrínseco de um ativo financeiro, levando em consideração tanto aspectos financeiros quanto operacionais da empresa, tais como indicadores de rentabilidade, liquidez e eficiência.

A análise fundamentalista leva em consideração fatores quantitativos (números obtidos em relatórios financeiros) e qualitativos como qualidade de gestão e posicionamento da empresa no setor.

Figura 4- Infográfico análise fundamentalista



Fonte: Diniz 2024

A imagem, elaborada por Diniz (2024), representa um funil de análise financeira que considera diversos fatores interconectados. Na parte superior, este começa com aspectos setoriais e do negócio, natureza patrimonial, resultados, rentabilidade, e capital de giro. Em seguida, avalia as dívidas e múltiplos financeiros, culminando na etapa de valuation, que integra todos esses elementos para determinar o valor da empresa.

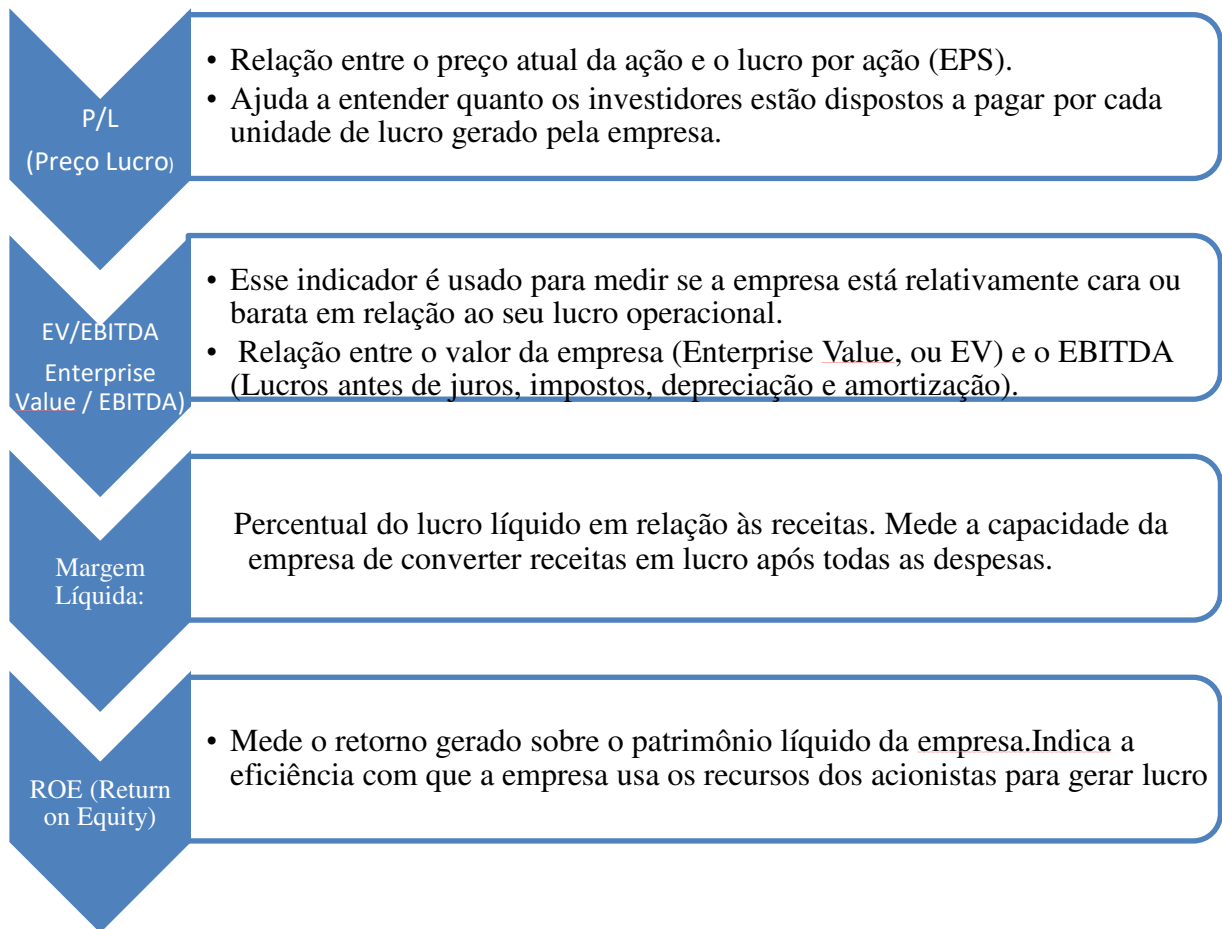
Análise de informações financeiras é muito importante para avaliar empresas, principalmente no setor logístico, nas quais, variáveis que afetam resultados são dinâmicas e interdependentes.

Investidores precisam entender indicadores financeiros principais, como *P/L* (preço/lucro), *EV/EBITDA* e *ROE* (retorno sobre o patrimônio líquido), para fazer decisões sustentáveis e informadas. Usar metodologias que unam esses indicadores com análise de sentimento podem proporcionar uma visão completa das forças que afetam a performance das ações.

Integrar análise de sentimento em notícias financeiras é uma abordagem nova, que, ajuda a compreender como eventos externos alteram a percepção do mercado sobre uma empresa. As técnicas de aprendizado de máquina auxiliam na análise de dados de sentimentos podem trazer informações úteis para investidores e gestores. O papel da tecnologia é importante não só na coleta e análise de dados, mas também na visualização de resultados, permitindo que informações sejam vistas de forma fácil e compreensível (Rolnick D et al., 2022).

Em resumo, análise fundamental em finanças, geralmente ajuda a avaliar com precisão a saúde financeira de uma empresa, mas não permite prever, analisar notícias ou opiniões públicas, as quais, podem afetar no desempenho de uma carteira de investimentos. O projeto de desenvolver a plataforma integrada proposta neste TCC busca usar o aprendizado de máquinas não apenas para melhorar a previsão de preços de ações, mas também para facilitar análise e entendimento de dados complexos. Com visualização interativa dos resultados, busca-se melhorar a experiência dos usuários, oferecendo uma ferramenta que ajude investidores e analistas em decisões financeiras fundamentadas. Isso confirma a relevância da análise fundamentalista como um apoio nas finanças modernas e na inovação tecnológica.

Figura 5 - Indicadores fundamentalistas



Fonte: Autor (2024)

A análise fundamentalista contida no código é realizada pela função `analise_fundamentalista(tickers)` a qual implementa a análise utilizando os indicadores citados para uma lista de empresas denominadas de tickers.

Inicialmente o código define critérios que definem se o estado atual do indicador pode ser classificado como “bom”, ou “ruim”



Figura 6 - Código benchmarks análise fundamentalista

```

benchmarks = {
    'P/L': (5, 20),           # Intervalo aceitável para P/L
    'EV/EBITDA': (5, 15),   # Intervalo aceitável para EV/EBITDA
    'Margem Líquida': 0.1,   # Valor mínimo para margem líquida (10%)
    'ROE': 0.15,            # Valor mínimo para ROE (15%)
}

```

Fonte: Autor (2024)

Em seguida, o código itera em cada *ticker* na lista e obtém informações financeiras utilizando a biblioteca *Yfinance*.

Figura 7 - Código obtenção de tickers

```

acao = yf.Ticker(ticker)
info = acao.info

```

Fonte: Autor (2024)

O próximo passo executado pelo código será a avaliação dos indicadores.

Figura 8 - Código avaliação indicadores fundamentalistas Figura x – Obtenção de tickers

```

def avaliar_indicador(valor, limite):
    if valor is None:
        return "Indisponível"
    if isinstance(limite, tuple):
        return "Bom" if limite[0] <= valor <= limite[1] else "Ruim"
    return "Bom" if valor > limite else "Ruim"

```

Fonte: Autor (2024)

Depois a armazena o resultado que futuramente será processado e disposto na ferramenta de visualização *streamlit*.

Figura 9 - Código obtenção de indicadores fundamentalistas

```
indicadores.append({
    'Empresa': tickers_nomes.get(ticker, ticker),
    'Ticker': ticker,
    'P/L': f"{pl:.2f}" if pl else "Indisponível",
    'P/L (Análise)': analise['P/L'],
    'EV/EBITDA': f"{ev_ebitda:.2f}" if ev_ebitda else "Indisponível",
    'EV/EBITDA (Análise)': analise['EV/EBITDA'],
    'Margem Líquida': f"{margem_liquida:.2%}" if margem_liquida else "Indisponível",
    'Margem Líquida (Análise)': analise['Margem Líquida'],
    'ROE': f"{roe:.2%}" if roe else "Indisponível",
    'ROE (Análise)': analise['ROE'],
})
```

Fonte: Autor (2024)

### 3.2. PREVISÃO DE PREÇOS

A eficácia dos modelos preditivos para séries temporais no setor financeiro é ponto central para a análise de dados na logística. Entender como mudanças passadas afetam os preços futuros das ações é importante para investidores que querem aumentar seus ganhos. Um modelo que se destaca é o *Prophet*, criado pelo Facebook, que apresenta bons resultados para tratar dados irregulares e sazonalidades.

A Aplicação modelos de previsão nesse setor melhora a tomada de decisões também ajuda as empresas a se adaptarem a mudanças de mercado e novas tendências.

O aprendizado de máquina permite que algoritmos detectem padrões complexos em grandes conjuntos de dados, melhorando a análise e a previsão das séries temporais. Modelos como redes neurais e árvores de decisão podem aumentar a precisão das previsões, como mostram estudos recentes que analisam fatores como volume de transações e clima do mercado. Por meio de uma análise integrada, como discutido em (Yenduri G et al., 2024), os benefícios vão além da previsão; incluem também *insights* sobre a relação entre variáveis econômicas e comportamentos do mercado, ajudando a entender melhor as dinâmicas do setor.

As visualizações de dados têm um papel importante na interpretação e comunicação dos resultados das previsões de séries temporais. Criar *dashboards* interativos, como os que serão feitos nesta pesquisa, permite que analistas e investidores vejam tendências e impactos de

forma clara e acessível. A importância de gráficos simples e informativos está em passar informações complexas para que decisões possam ser feitas rapidamente. Além disso, a visualização dos dados ajuda todos os envolvidos a perceberem anomalias e padrões novos, no setor logístico, muito dinâmico como o logístico. Portanto, combinar modelos eficazes de previsão com visualizações úteis é fundamental para o sucesso na análise financeira e de sentimento desse setor.

A previsão de preços deste modelo se baseou na ferramenta *Prophet*, desenvolvida pelo Facebook. Esta ferramenta foi escolhida devido a sua capacidade de lidar com séries temporais que apresentam padrões sazonais e tendência não linear ao longo do tempo.. A sua modelagem matemática pode ser representada de acordo com a figura 10.

Figura 10 - Modelo Prophet Original

### **Modelo Prophet Original**

O modelo Prophet prevê valores de séries temporais com a seguinte fórmula:

$$y_{\text{prophet}}(t) = g(t) + s(t) + h(t) + \varepsilon_t$$

Onde:

- $g(t)$ : Tendência (linear),
- $s(t)$ : Sazonalidade,
- $h(t)$ : Eventos especiais,
- $\varepsilon_t$ : Ruído.

Fonte: Autor (2024)

O Cálculo da tendência  $g(t)$  é calculado e exemplificado de acordo com a figura 11:

Figura 11 - Cálculo da Tendência  $g(t)$  do Prophet

### **Cálculo da Tendência ( $g(t)$ )**

Para uma tendência linear, usamos:

$$g(t) = k \cdot t + m$$

Onde:

- $k$ : Inclinação da linha (taxa de crescimento ou decrescimento),
- $m$ : Intercepto inicial (valor de  $y$  quando  $t = 0$ ).
- Inclinação ( $k$ ) = 2,
- Intercepto ( $m$ ) = 50,
- Tempo ( $t = 10$ ).

Substituindo na fórmula:

$$g(t) = 2 \cdot 10 + 50 = 70$$

Fonte: Autor (2024)

A Sazonalidade  $s(t)$  pode ser calculada de acordo com a figura 12 e o Ruído pela figura 13.

Figura 12 - Cálculo da Sazonalidade Prophet

### Cálculo da Sazonalidade ( $s(t)$ )

A sazonalidade é representada como uma soma de funções trigonométricas:

$$s(t) = \sum_{n=1}^N \left[ a_n \cos\left(\frac{2\pi nt}{P}\right) + b_n \sin\left(\frac{2\pi nt}{P}\right) \right]$$

Onde:

- $P$ : Período (e.g., sazonalidade anual, semanal, etc.),
- $a_n, b_n$ : Coeficientes ajustados pelo modelo.

Exemplo:

- Período ( $P$ ) = 12 (mensal),
- Coeficientes  $a_1 = 10, b_1 = 5$ ,
- Tempo ( $t = 6$ ).

Substituindo na fórmula para  $n = 1$ :

$$s(t) = 10 \cdot \cos\left(\frac{2\pi \cdot 1 \cdot 6}{12}\right) + 5 \cdot \sin\left(\frac{2\pi \cdot 1 \cdot 6}{12}\right)$$

Sabendo que  $\cos(\pi) = -1$  e  $\sin(\pi) = 0$ :

$$s(t) = 10 \cdot (-1) + 5 \cdot 0 = -10$$

Fonte: Autor (2024)

Figura 13 - Cálculo de Ruído Prophet

### Cálculo do Ruído ( $\varepsilon_t$ )

O ruído é modelado como uma distribuição normal:

$$\varepsilon_t \sim \mathcal{N}(0, \sigma^2)$$

Exemplo

- Média (0),
- Variância ( $\sigma^2 = 4$ ).

Gerando um valor aleatório com  $\varepsilon_t = -2$ .

Fonte: Autor (2024)

Por fim, para realizar o cálculo final do modelo, basta somar todos os componentes calculados nas imagens 11, 12 e 13:

Figura 14 - Exemplo Cálculo Final Prophet

**Cálculo Final do Modelo**

Somando os componentes:

$$y_{\text{prophet}}(t) = g(t) + s(t) + h(t) + \varepsilon_t$$

Exemplo Final:

- Tendência ( $g(t)$ ) = 70,
- Sazonalidade ( $s(t)$ ) = -10,
- Eventos ( $h(t)$ ) = 0,
- Ruído ( $\varepsilon_t$ ) = -2.

Substituindo:

$$y_{\text{prophet}}(t) = 70 - 10 + 0 - 2 = 58$$

Fonte: Autor (2024)

No código desenvolvido, a previsão de preços foi implementada através da função `prever_precos(ticker)`, que utiliza o *Prophet* para realizar previsões de um ano para o preço de fechamento das ações. Inicialmente, os dados históricos são coletados usando a biblioteca *Yfinance*, cobrindo um período de cinco anos. Esses dados são preparados para serem utilizados pelo *Prophet*, sendo organizados em um formato que inclui as colunas de datas (`ds`) e preços de fechamento (`y`).

O modelo é então ajustado com esses dados históricos, e uma previsão para os próximos 365 dias (~1 ano) é gerada. Uma das vantagens desse processo é que o *Prophet* permite visualizar tanto a tendência quanto os intervalos de confiança das previsões, proporcionando uma melhor compreensão das incertezas inerentes ao mercado.

Uma das principais vantagens do *Prophet* é a possibilidade de ajuste de sazonalidade anual, mensal ou semanal, bem como a inclusão de feriados específicos que possam impactar os preços. Este é um diferencial relevante, visto que o mercado financeiro é frequentemente impactado por eventos externos, como feriados, divulgações de resultados e mudanças macroeconômicas.

Figura 15 - Código função previsão de preços

```

def prever_precos(ticker):
    """
    Realiza previsões de 1 ano para o preço de fechamento da ação.
    :param ticker: Ticker da empresa para análise.
    :return: DataFrame com previsões e gráfico interativo.
    """
    try:
        # Definir datas de início e fim
        start_date = '2022-01-01'
        end_date = '2024-11-26'
        forecast_end_date = '2025-11-26'

        # Baixar dados históricos da ação
        dados = yf.download(ticker, start=start_date, end=end_date)
        if dados.empty or 'Close' not in dados.columns:
            logger.warning(f"Dados indisponíveis para o ticker {ticker}.")
            return None, None
        dados.reset_index(inplace=True)

        # Preparar os dados para o Prophet
        df = dados[['Date', 'Close']]
        df.columns = ['ds', 'y'] # Renomear colunas para o Prophet

        # Remover timezone da coluna 'ds'
        df['ds'] = df['ds'].dt.tz_localize(None)

        # Inicializar o modelo Prophet
        modelo = Prophet()
        modelo.fit(df)

        # Calcular o número de dias para previsão até 26/11/2025
        ultimo_dia = df['ds'].max()
        previsao_dias = (pd.to_datetime(forecast_end_date) - ultimo_dia).days

        # Criar um DataFrame futuro para projeção
        futuro = modelo.make_future_dataframe(periods=previsao_dias)
        previsao = modelo.predict(futuro)

        # Obter o nome da empresa
        nome_empresa = tickers_nomes.get(ticker, ticker)

        # Criar gráfico interativo com Plotly
        fig = go.Figure()
        fig.add_trace(go.Scatter(x=df['ds'], y=df['y'], name='Preço Histórico',
                                mode='lines'))
        fig.add_trace(go.Scatter(x=previsao['ds'], y=previsao['yhat'],
                                name='Projeção Futura', mode='lines'))
        fig.update_layout(
            title=f'Projeção de Preços para {nome_empresa} ({ticker})',
            xaxis_title='Data',
            yaxis_title='Preço de Fechamento',
            legend_title='Legenda',
            template='plotly_white'
        )

        return previsao, fig
    except Exception as e:
        logger.error(f"Erro ao processar {ticker}: {e}")
        traceback.print_exc()
        return None, None

```

Os resultados obtidos com a previsão são apresentados visualmente por meio de gráficos gerados por *Plotly* que mostram a projeção de preços.

O treinamento do modelo *Prophet* foi realizado utilizando os dados históricos das ações, coletados por meio da biblioteca *Yfinance*. Esses dados foram organizados em colunas datas (ds) e preço de fechamento (y). O *Prophet* foi ajustado para capturar padrões sazonais, tendências de longo prazo e componentes específicos do comportamento do mercado.

Durante o processo de treinamento, o modelo leva em consideração as tendências gerais e possíveis sazonalidades, sendo capaz de incorporar efeitos externos que possam influenciar o comportamento dos preços

Para a validação do modelo, foi utilizada uma parte dos dados históricos como conjunto de teste, no qual os valores previstos foram comparados aos valores reais para avaliar a precisão do modelo. As métricas de erro calculadas, como MAE, RMSE e MAPE, permitiram quantificar a diferença entre as previsões e os valores observados, fornecendo uma base para avaliar a confiabilidade das previsões.

Além disso, foi utilizada a métrica de direção correta, que compara se o movimento (alta ou queda) previsto pelo modelo coincide com o movimento real. Essa métrica é particularmente importante para a análise gráfica e tendência dos preços pois indica a precisão da plotagem dos gráficos.

A combinação dessas técnicas de validação oferece uma visão abrangente da performance do modelo, permitindo identificar seus pontos fortes e áreas de melhoria, com o objetivo de gerar previsões cada vez mais precisas e úteis para a tomada de decisões financeiras.

No contexto deste projeto, a previsão de preços utiliza os dados históricos coletados, e o *Prophet* automaticamente decompõe esses dados em diferentes componentes, como:

- **Tendência:** A direção geral dos preços ao longo do tempo, que pode ser uma tendência de alta, baixa ou estável. Isso é essencial para investidores entenderem se o ativo está se valorizando ou desvalorizando;
- **Sazonalidade:** Comportamentos cíclicos que se repetem em intervalos regulares. O *Prophet* é particularmente útil por sua capacidade de capturar sazonalidades anuais, mensais ou até mesmo diárias, permitindo previsões mais precisas em mercados que apresentam esses padrões;
- **Efeitos externos e feriados:** A ferramenta *Prophet* permite incorporar efeitos externos e feriados que podem impactar os preços das ações. Embora no código atual esses fatores não tenham sido especificamente modelados, eles poderiam ser facilmente incluídos para aumentar a precisão das previsões.



A análise de tendências e sazonalidade é visualmente representada através dos gráficos interativos gerados, que facilitam a identificação dos componentes da série temporal. Isso possibilita aos investidores e analistas uma compreensão clara dos fatores que afetam os preços das ações ao longo do tempo e contribui para a tomada de decisões estratégicas mais informadas.

### 3.3. ANÁLISE DE SENTIMENTO

A aplicação de técnicas de análise de sentimento é muito importante para entender como emoções e opiniões em textos podem afetar o desempenho das ações no mercado financeiro. Essas técnicas usam métodos de processamento de linguagem natural (*NLP*) para identificar e classificar sentimentos em notícias e redes sociais, permitindo que investidores e analistas vejam rapidamente a percepção que os bancos, políticos e o público geral tem sobre uma empresa.

O setor financeiro, no qual eventos e notícias podem afetar diretamente as operações e o valor das ações, ferramentas como *VADER*, *BERT* e modelos de classificação *Zero-Shot* oferecem uma análise eficaz, ajudando a identificar tendências que poderiam ser ignoradas em uma análise comum. A relação entre sentimento e preços das ações é uma área promissora que pode trazer novos resultados para decisões financeiras.

Deste modo, o uso de modelos de aprendizado de máquina, como os mencionados em estudos recentes, oferecem uma análise mais precisa e em larga escala, integrando diversas fontes de dados. Essa integração não apenas melhora a análise de risco, mas também auxilia as empresas a ajustarem suas estratégias de comunicação e marketing, alinhando-se às expectativas e preocupações do público.

Além disso, a implementação de visualizações interativas, conforme previsto no desenvolvimento da plataforma proposta, facilitará a interpretação de dados e a transmissão dessas análises complexas de forma acessível para os envolvidos.

### 3.4. IMPACTO DE EVENTOS E SENTIMENTOS NAS AÇÕES

A análise do impacto de eventos e sentimentos nas ações desempenha um papel crucial na compreensão do comportamento dos mercados financeiros, especialmente no setor logístico, onde fatores externos e percepções públicas podem alterar significativamente o valor das ações. A metodologia desenvolvida neste trabalho integrou a análise de sentimentos com a previsão de preços, utilizando técnicas modernas de processamento de linguagem natural e modelos preditivos para séries temporais.

A coleta das notícias financeiras foi realizada por meio da inserção de URLs pelo arquivo .csv gerado pelo código 1.py, mas também pelo programa main.py ser tratado de forma individual, o usuário pode analisar as próprias notícias colando o URL na área indicada pela ferramenta.

Utilizando a biblioteca newspaper, as URLs fornecidas foram processadas para baixar e extrair o conteúdo textual dos artigos, garantindo que apenas URLs válidas fossem analisadas por meio da biblioteca *validators*. Essa etapa inicial possibilitou a criação de uma base de dados de notícias relevantes para as empresas do setor logístico.

Posteriormente, o sentimento das notícias foi analisado utilizando o modelo pré-treinado *BERT* multilíngue (*nlptown/BERT-base-multilingual-uncased-sentiment*), implementado por meio da biblioteca *Transformers*. Esse modelo permitiu categorizar os textos em sentimento Positivo, Neutro ou Negativo, baseando-se em uma pontuação de 1 a 5 estrelas. Paralelamente, a biblioteca *VADER*, através do *SentimentIntensityAnalyzer* da *NLTK*, foi utilizada para complementar a análise e obter uma pontuação composta do sentimento, proporcionando uma visão sobre o humor do mercado.

Além da análise de sentimento, a validação das fontes das notícias foi realizada contra uma lista de domínios confiáveis, de modo a garantir a qualidade das informações. Notícias provenientes de fontes consideradas menos confiáveis foram marcadas para uma avaliação adicional, e a detecção de fake news foi conduzida utilizando um classificador *Zero-Shot* (*facebook/bart-large-mnli*). Esse classificador atribuiu uma pontuação de probabilidade, indicando a possibilidade de uma notícia ser falsa, e foi fundamental para melhorar a precisão das informações usadas na análise de sentimento.

Para quantificar o sentimento ao longo do tempo, as pontuações de sentimento das notícias foram agregadas por data, resultando em uma média diária de sentimento. Essa métrica de "sentimento médio" foi utilizada como uma variável exógena no modelo de previsão de preços das ações, permitindo que o impacto dos sentimentos do mercado fosse diretamente

considerado nas projeções. Assim, a integração dessas informações tornou a previsão mais próxima das realidades do mercado, refletindo o humor dos investidores e a reação pública a eventos e notícias.

Após essa abordagem inicial, o código integrou novos métodos para otimizar os resultados obtidos das notícias, incluindo um refinamento na análise de sentimentos e a adição de variáveis exógenas adicionais. Por exemplo, a integração da técnica de *Zero-Shot* para a detecção de *fake news* aumentou a confiabilidade dos dados, uma vez que permitiu filtrar informações potencialmente enganosas antes de serem incluídas nas análises. Além disso, a agregação da média diária de sentimento e a otimização no uso de modelos de predição com múltiplas regressoras aumentaram a precisão das previsões geradas.

### 3.5. VISUALIZAÇÃO DE DADOS E PREVISÕES OTIMIZADAS

A visualização de dados é muito importante na análise financeira, pois apresenta de forma gráfica grandes quantidades de dados numéricos em poucas imagens. Com o aumento dos dados disponíveis, especialmente na área financeira, traduzir isso em visualizações simples para os tomadores de decisão é muito importante.

Ferramentas modernas como *Plotly* e *Streamlit* ajudam a criar painéis interativos que permitem aos analistas verem tendências, correlações e anomalias em grandes volumes de dados financeiros. Essas representações visuais não só aumentam a eficiência na obtenção de insights, mas também tornam os dados mais acessíveis a mais pessoas, promovendo uma cultura de dados nas empresas (Maalla A et al., 2019).

Além de facilitar o acesso aos dados, a visualização ajuda a mostrar histórias e padrões que podem ser perdidos em análises comuns. Por exemplo, uma análise de séries temporais pode se beneficiar muito de gráficos que mostram as mudanças nos preços das ações ao longo do tempo, permitindo que os investidores entendam rapidamente o desempenho passado de uma empresa.

A interatividade nas visualizações oferece uma exploração ativa dos dados, onde os usuários podem aplicar filtros e aumentar a visualização, levando a insights mais detalhados e personalizados. Além disso, a capacidade de sobrepor várias métricas em um gráfico único pode ajudar na comparação entre empresas ou setores, permitindo que os analistas vejam rapidamente o impacto de diferentes fatores, como eventos de mercado ou mudanças nas regras, no desempenho financeiro.

Misturar técnicas de machine learning com a visualização de dados pode ainda melhorar a análise financeira, ajudando a encontrar padrões complexos que podem afetar preços de ações. Por exemplo, a análise de sentimentos de notícias pode ser mostrada junto com a evolução dos preços das ações, oferecendo uma compreensão sobre como as percepções do mercado influenciam o valor das ações. Essa forma de trabalhar não só melhora a análise de como a informação afeta o desempenho financeiro, mas também ajuda na tomada de decisões informadas por parte dos gestores financeiros, que podem agir de maneira proativa com base em insights visuais relevantes. Assim, a visualização de dados se torna um recurso fundamental para a análise financeira hoje, especialmente em um ambiente instável como o setor logístico.

A complexidade dos dados no setor financeiro exige ferramentas que ajudem não só na análise, mas também na interpretação clara dessas informações. As visualizações interativas são uma ferramenta importante nesse cenário, permitindo que os usuários explorem os dados de forma dinâmica e personalizada. Sabe-se que decisões de investimento muitas vezes dependem de entender rapidamente as tendências e correlações em grandes volumes de dados, como nas análises financeiras do setor logístico. Assim, plataformas que usam visualizações interativas, como as criadas com ferramentas como *Plotly* e *Streamlit*, oferecem uma interface simples que facilita o acesso à informação, ajudando na compreensão de indicadores e tendências do mercado.

A análise de sentimentos é complexa, mas quando combinada com visualizações interativas, se torna uma ferramenta valiosa para investidores, que podem ver rapidamente as correlações entre as oscilações do mercado e eventos noticiados, como mencionado em (Yenduri G et al., 2024). Por fim, as visualizações interativas são mais do que bonitas; elas são importantes na educação e na capacitação dos usuários, permitindo que até mesmo os menos experientes em finanças entendam dados complexos. Ao integrar e contextualizar informações financeiras e sentimento do mercado, essas ferramentas aumentam a capacidade de análise estratégica das empresas do setor logístico..

Quando se fala em usar ferramentas de visualização de dados no setor logístico, a capacidade de se adaptar e a clareza das informações são muito importantes. A habilidade de mostrar dados financeiros e de sentimentos de maneira fácil não só melhora a análise por parte dos gestores, mas também permite uma resposta rápida às mudanças do mercado. Um estudo recente sobre tecnologias de visualização aponta que uma apresentação eficaz pode afetar diretamente as decisões estratégicas em ambientes instáveis, como o setor de logística (Rolnick D et al., 2022).

Portanto, escolher e implementar visualizações apropriadas é essencial para apoiar as análises que se propõem neste trabalho, aumentando a habilidade de reagir a variações nos preços das ações e no sentimento ligado às notícias do setor. Além disso, usar visualizações para juntar indicadores econômicos e sentimentais é crucial para entender como eventos externos afetam as ações de empresas de logística. A análise e a representação gráfica de dados ao longo do tempo, como a atividade do mercado durante eventos específicos, fortalecem a conexão entre prática e teoria, garantindo que os investidores tenham informações sólidas ao tomar decisões assim, este trabalho não somente se propõe a analisar e prever, mas também a criar uma plataforma que transforma dados em visualizações que realmente orientam ações e estratégias dentro do setor logístico.

Pesquisas recentes mostram que o uso eficaz de gráficos pode levar a decisões mais informadas, permitindo que gestores adaptem suas estratégias com base nas opiniões dos consumidores e nas notícias do setor (Rolnick D et al., 2022). Assim, as boas práticas em visualização devem unir a análise emocional e a financeira.

Criar uma plataforma que analise indicadores econômicos e sentimentais traz desafios, mas também boas oportunidades. Juntar dados financeiros e de sentimento pode melhorar a análise fundamental, ajudando analistas e investidores a entender melhor como as flutuações do mercado se relacionam com variáveis econômicas. Usar uma abordagem que combine visualizações interativas, como mencionadas em (Yenduri G et al., 2024), com dados financeiros permite identificar padrões de comportamento que poderiam ser ignorados.

Assim, a plataforma proposta, ao integrar vários indicadores econômicos e sentimentais, pode fornecer uma ferramenta eficaz para a análise preditiva no setor logístico, melhorando a capacidade das empresas de reagir a imprevistos. A análise dos indicadores econômicos juntamente com o sentimento dos investidores e do público pode oferecer insights importantes sobre o mercado.

No desenvolvimento de uma análise financeira detalhada e previsões de mercado para empresas do setor logístico, a utilização de bibliotecas específicas do Python foram essenciais para a realização de diversas etapas do projeto. Cada uma dessas ferramentas trouxe funcionalidades e capacidades que contribuíram para alcançar um entendimento abrangente dos dados financeiros, além de possibilitar uma visualização interativa e contextualizada dos resultados obtidos.

A análise começa com a utilização da biblioteca *pandas*. Considerada uma ferramenta essencial em qualquer trabalho que envolva manipulação de dados, *pandas* foi usada para estruturar informações de uma maneira tabular, o que facilitou o trabalho com os dados

financeiros. Através de seus *DataFrames*, foi possível organizar, filtrar e agregar informações de forma clara e eficiente, tornando o processo de análise mais intuitivo. Esses dados tabulares são, então, a base para todas as etapas subsequentes do trabalho, seja para previsões ou para exibição dos resultados.

Para realizar as previsões dos preços futuros das ações, a ferramenta escolhida foi o *Prophet*, uma biblioteca desenvolvida pelo Facebook para modelagem de séries temporais. *Prophet* é particularmente adequada para lidar com sazonalidades e tendências que podem aparecer nos preços das ações. Assim, foi possível prever com uma boa precisão os movimentos dos preços no futuro, algo extremamente importante para os investidores e outros tomadores de decisão que desejam planejar suas estratégias de mercado.

Junto com as previsões, a avaliação do desempenho dos modelos também foi uma etapa importante. Para isso, foram usadas métricas oferecidas pela biblioteca *scikit-learn*, através do módulo *metrics*. Métricas como Erro Absoluto Médio (MAE) e Erro Quadrático Médio (MSE) permitiram avaliar a precisão das previsões e entender as variações entre os valores previstos e os valores reais. Essas métricas garantem que as previsões feitas pelo *Prophet* são confiáveis e indicam o grau de acerto do modelo.

O processamento matemático dos dados, bem como a realização de operações com arrays, foi feito através da biblioteca *numpy*. Como se trata de uma biblioteca altamente eficiente para operações numéricas, *numpy* foi utilizada para garantir a precisão dos cálculos estatísticos, bem como para eliminar valores ausentes nos dados, de forma a melhorar a qualidade das previsões e garantir que não houvesse discrepâncias nos resultados apresentados.

Além da análise numérica, a visualização dos dados foi outro ponto chave do trabalho. Para isso, a biblioteca escolhida foi a *Plotly*, mais especificamente o módulo *graph\_objects*. *Plotly* permite a criação de gráficos interativos, possibilitando ao usuário navegar pelos dados, visualizar tendências e comparações de maneira mais intuitiva. Através dos gráficos gerados, foi possível visualizar o comportamento dos preços históricos das ações e as projeções futuras, transformando números e tabelas em informações mais fáceis de interpretar.

Para tornar toda a análise acessível aos usuários, foi utilizada a biblioteca *Streamlit*. *Streamlit* é uma ferramenta que facilita a construção de interfaces web interativas a partir de scripts Python. Com ela, foi possível criar uma aplicação onde o usuário pode selecionar empresas para análise, visualizar gráficos, e obter resultados de forma prática e rápida. A interatividade oferecida por *Streamlit* fez com que o trabalho se tornasse mais atraente e acessível, possibilitando que mesmo pessoas sem conhecimento técnico pudessem entender os dados e fazer suas próprias análises.

Com coleta de notícia completa, o terceiro código *otimizado.py* faz a mesma coleta de dados financeiros pelo *yFinance* que o outro código fez, garantindo que todos os dados da previsão estejam atualizados no momento da geração dos gráficos. Em seguida, são coletados os resultados de análise de sentimentos gerados anteriormente pela ferramenta de notícias (*main.py*), em modelo .CSV que será integrada ao código e posicionada em uma nova curva chamada de otimizado.

Essa nova curva será modelada a partir dos resultados de cada notícias. Com a pontuação gerada de 1 a 5, para sentimentos 1 ou 2, a projeção será ajustada para baixo, para sentimentos 3, manter a previsão original e para sentimentos 4 ou 5, ajustar positivamente.

Figura 16 - Pontuação dos Ajustes

## Pontuações dos Ajustes

### Notas e Limites Percentuais ( $P_{nota}$ )

Cada nota tem um limite percentual máximo para ajuste:

- **Nota 1:** Redução de até 15%,
- **Nota 2:** Redução de até 10%,
- **Nota 3:** Sem ajuste (0%),
- **Nota 4:** Aumento de até 10%,
- **Nota 5:** Aumento de até 15%.

A influência real é ajustada pela confiabilidade ( $C$ ), convertida para um ângulo  $\theta$ , e calculada com:

$$\text{Ajuste Base} = y_{\text{prophet}} \cdot (P_{\text{nota}} \cdot \cos(\theta))$$

Fonte: Autor (2024)

Figura 17 - Ajuste e Conversão das pontuações

## Confiabilidade e Ângulo ( $\theta$ )

A confiabilidade ( $C$ ) é um valor entre 0% e 90%, convertido para radianos:

$$\theta = C \cdot \frac{\pi}{180}$$

O ajuste é proporcional ao cosseno do ângulo:

$$\cos(\theta) \text{ varia de } \cos(0^\circ) = 1 \text{ a } \cos(90^\circ) = 0$$

Fonte: Autor (2024)

A inclinação destes ajustes será definida pela chance de impacto, elaborada de 0-100% no código *main.py* na qual, foi restringida nesse código para 90% para adequar aos graus. O código segue a previsão do prophet em linha reta e 90 % verticalmente para cima ou para baixo de acordo se a previsão foi para cima ou para baixo, exemplificada na figura 18.

Figura 18 - Exemplo Cálculo Ajuste Base

**Cálculo do Ajuste Base**

**Exemplo:**

- $y_{\text{prophet}} = 100$ ,
- Nota = 5 ( $P_{\text{nota}} = 0.15$ ),
- Confiabilidade ( $C$ ) = 60%.

Calculando o ângulo:

$$\theta = 60 \cdot \frac{\pi}{180} = \frac{\pi}{3} \text{ radianos}$$

Sabendo que  $\cos\left(\frac{\pi}{3}\right) = 0.5$ , o ajuste base é:

$$\text{Ajuste Base} = 100 \cdot (0.15 \cdot 0.5) = 7.5$$

Fonte: Autor (2024)

Além dos ajustes iniciais, o código também adiciona impactos adicionais quando há grandes volumes de notícias, adicionando 1% na tendência a cada 5 notícias sobre o tema e 4% quando novas notícias persistem a chegar após 5 dias ininterruptos, conforme exemplificado na imagem 19.



Figura 19 - Impactos Adicionais Exemplo

## Impactos Adicionais

### 1. Impacto por Notícias (Impacto Notícias)

O impacto adicional por quantidade de notícias ( $N$ ) é:

$$\text{Impacto Notícias} = y_{\text{prophet}} \cdot \left\lfloor \frac{N}{5} \right\rfloor \cdot 0.01$$

**Exemplo:**

- $N = 15$ ,
- Impacto Notícias =  $100 \cdot \left\lfloor \frac{15}{5} \right\rfloor \cdot 0.01 = 3$ .

### 2. Impacto por Persistência (Impacto Persistência)

O impacto adicional por dias consecutivos de novas notícias ( $D$ ) é:

$$\text{Impacto Persistência} = y_{\text{prophet}} \cdot \left\lfloor \frac{D}{5} \right\rfloor \cdot 0.04$$

**Exemplo:**

- $D = 10$ ,
- Impacto Persistência =  $100 \cdot \left\lfloor \frac{10}{5} \right\rfloor \cdot 0.04 = 8$ .

Fonte: Autor (2024)

Deste modo, o modelo prophet ajustado é calculado de acordo com a figura 20.

Figura 20 - Modelo Prophet Ajustado

## Modelo Prophet Ajustado

O modelo Prophet ajustado incorpora o impacto de notícias relevantes na previsão. A fórmula geral é:

$$y_{\text{ajustado}}(t) = y_{\text{prophet}}(t) + \Delta y(t)$$

Onde:

- $y_{\text{prophet}}(t)$ : Previsão base do Prophet,
- $\Delta y(t)$ : Ajuste baseado em notícias e persistência.

Fonte: Autor (2024)

O terceiro código, *otimizado.py*, realiza a coleta de dados financeiros diretamente da biblioteca *yFinance*, assegurando que todos os dados utilizados para as previsões estejam atualizados no momento da geração dos gráficos. Em paralelo, são integrados os resultados da análise de sentimentos previamente gerados pelo script de análise de notícias (*main.py*), disponibilizados em formato *.CSV*. Esses dados são incorporados ao código e modelados como uma nova curva, denominada *otimizado*, a qual reflete os ajustes baseados na avaliação de sentimentos associados às notícias analisadas.

A modelagem dessa curva considera a pontuação de sentimentos, atribuída em uma escala de 1 a 5, nos quais os sentimentos 1 ou 2: resultam em ajuste negativo na projeção. sentimento 3 a projeção é mantida sem alterações. Sentimentos 4 ou 5: ajuste positivo na projeção. A magnitude do ajuste é definida pela chance de impacto, uma métrica calculada no *main.py* e variando entre 0% e 100%. Para este código, a chance máxima de impacto foi limitada a 90%, promovendo uma melhor adequação ao comportamento esperado. A inclinação dos ajustes é escalonada conforme a chance de impacto:

0%: A projeção segue linearmente a previsão base gerada pelo modelo Prophet. 90%: A inclinação da curva é ajustada de forma significativa, aproximando-se de uma trajetória vertical, com direção determinada pela tendência (positiva ou negativa) do sentimento avaliado.

Durante a execução do projeto, o uso da biblioteca *logging* se mostrou indispensável. Com *logging*, foi possível registrar eventos importantes que ocorreram durante a execução do código, facilitando a identificação e resolução de erros, além de fornecer um histórico do que aconteceu durante a execução. A esse propósito, a biblioteca *traceback* também foi utilizada, fornecendo informações detalhadas sobre erros que surgiram, garantindo que problemas fossem rapidamente identificados e corrigidos.

Por fim, o módulo *datetime* foi utilizado para manipular as datas, tanto para coletar dados históricos de preços quanto para calcular os períodos necessários nas análises. Essa manipulação de datas foi essencial para definir intervalos de tempo para as previsões e para a coleta de notícias.

O desenvolvimento de uma ferramenta para análise de sentimentos em notícias financeiras envolveu a integração de diversas bibliotecas do Python, cada uma contribuindo de forma única para alcançar uma solução eficaz e acessível para os usuários. Este projeto, implementado através do *Streamlit*, oferece uma interface interativa que realiza a análise de artigos financeiros, categorizando o sentimento em positivo, neutro ou negativo, utilizando modelos de aprendizado de máquina.

Para operar esses modelos, a biblioteca *torch* foi utilizada. Ela oferece suporte a operações de aprendizado profundo, permitindo a execução do modelo em diferentes dispositivos (CPU ou MPS). A escolha do dispositivo é feita automaticamente pelo código, maximizando o desempenho do processamento. *torch* também facilitou a inferência do modelo, possibilitando a obtenção das probabilidades de cada classe de sentimento.

A obtenção do texto dos artigos foi realizada através da biblioteca *newspaper3k*, importada como *Article*. *newspaper3k* é uma ferramenta para extração de conteúdo de notícias, que se mostrou fundamental para extrair o texto completo dos artigos a partir das URLs fornecidas pelos usuários. Isso garantiu que a análise de sentimentos fosse aplicada a informações relevantes e completas, eliminando ruídos ou informações secundárias da página.

Para garantir que as URLs inseridas pelos usuários fossem válidas, a biblioteca *validators* foi utilizada. *validators* permitiu verificar se as URLs fornecidas estavam no formato correto antes de serem processadas, garantindo a qualidade e a precisão da coleta de dados. Essa validação foi essencial para evitar falhas durante a extração dos artigos.

A biblioteca *numpy* também foi empregada neste projeto para manipular as probabilidades obtidas a partir do modelo de classificação. Com *numpy*, foi possível processar eficientemente os resultados das previsões, transformando as saídas do modelo em uma forma compreensível para os usuários, como estrelas (de 1 a 5) e a probabilidade associada a cada classificação.

A organização dos resultados da análise de sentimentos, assim como a criação de relatórios detalhados, foi realizada com o uso da biblioteca *pandas*. *pandas* possibilitou a estruturação dos dados em *DataFrames*, facilitando a manipulação dos resultados, cálculo de distribuições de sentimentos e geração de tabelas prontas para exibição. Além disso, a biblioteca permitiu a exportação dos resultados para um arquivo CSV, que pode ser facilmente baixado pelo usuário, garantindo uma forma prática de armazenar e compartilhar os dados analisados.

Além disso, o cache da biblioteca *Streamlit* foi utilizado para melhorar o desempenho da aplicação. A função de cache permitiu que o modelo *BERT* e o tokenizer fossem carregados apenas uma vez, evitando o tempo de carregamento repetitivo em cada nova execução. Isso otimizou a experiência do usuário e reduziu a carga computacional durante o uso do aplicativo.

O layout da interface foi cuidadosamente projetado utilizando *Streamlit* para garantir que todas as funcionalidades fossem acessíveis de forma intuitiva. A interface permite que o usuário insira múltiplas URLs, visualize a análise de cada artigo individualmente e obtenha uma visão agregada dos resultados através de gráficos de distribuição de sentimentos, que são

gerados dinamicamente. Essa abordagem promove a análise visual dos resultados, facilitando a compreensão do cenário geral em relação aos artigos analisados.

Portanto, a integração dessas diversas bibliotecas resultou em uma aplicação capaz de realizar análises complexas de forma acessível e prática. O uso de *Streamlit* garantiu uma interface amigável; *transformers* e *torch* possibilitaram a utilização de modelos de última geração para análise de sentimentos; *newspaper3k* viabilizou a extração de conteúdo de forma automatizada; e *validators* assegurou a validade das URLs. Juntas, essas ferramentas permitiram o desenvolvimento de um aplicativo robusto, útil tanto para profissionais do mercado financeiro quanto para interessados em obter insights a partir de notícias.

Essas bibliotecas, usadas em conjunto, criaram um sistema robusto para análise financeira, capaz de integrar dados históricos e projeções futuras, contextualizar essas informações através de notícias, e apresentar tudo de uma forma interativa e visualmente atrativa. Esse conjunto de ferramentas e funcionalidades permitiu ao trabalho acadêmico oferecer uma visão ampla e detalhada do comportamento das ações de empresas do setor logístico, tornando a análise mais acessível, confiável e precisa para investidores, gestores e outros interessados no tema.

#### 4. RESULTADOS E DISCUSSÕES

A análise fundamentalista realizada neste estudo baseia-se na avaliação de indicadores-chave de desempenho financeiro de diversas empresas, utilizando dados extraídos da API do Yahoo Finance. Esses indicadores foram comparados a benchmarks específicos, que funcionam como padrões de referência para determinar se uma empresa apresenta um desempenho satisfatório em relação ao mercado. Abaixo, são descritos os indicadores avaliados e a forma como suas pontuações foram atribuídas.

##### Indicadores Avaliados:

- *P/L (Preço/Lucro)*: Esse indicador é utilizado para avaliar se a ação está supervalorizada ou subvalorizada, comparando o preço atual com o lucro por ação. O benchmark definido para o P/L é de um valor entre 5 e 20. Valores dentro desse intervalo foram considerados "Bom"; valores fora do intervalo foram classificados como "Ruim";
- *EV/EBITDA (Valor da Empresa / Lucros antes de Juros, Impostos, Depreciação e Amortização)*: Essa métrica é usada para medir quanto o mercado está disposto a pagar em relação aos lucros operacionais da empresa. O benchmark para esse indicador é um valor entre 5 e 15. Valores dentro desse intervalo foram classificados como "Bom", enquanto valores fora do intervalo foram considerados "Ruim";
- *Margem Líquida*: A margem líquida indica a porcentagem do lucro que a empresa retém após deduzir todas as despesas. Para este indicador, o benchmark foi definido em 10%. Assim, uma margem superior a 10% foi considerada "Bom", enquanto valores inferiores foram classificados como "Ruim";
- *ROE (Retorno sobre Patrimônio Líquido)*: O ROE mede a rentabilidade dos recursos próprios investidos na empresa. O benchmark para o ROE foi estabelecido em 15%, de forma que valores acima deste nível foram classificados como "Bom", enquanto valores inferiores foram considerados "Ruim".

A função “avaliar indicador()” foi empregada para determinar se um indicador era "Bom" ou "Ruim", de acordo com os benchmarks estabelecidos. Nos casos em que os dados estavam indisponíveis, o resultado foi indicado como "Indisponível".

As colunas P/L (Análise), *EV/EBITDA* (Análise), Margem Líquida (Análise) e *ROE* (Análise) apresentam os resultados da avaliação, indicando se a empresa teve desempenho considerado "Bom" ou "Ruim" em cada um dos aspectos analisados.

Os resultados dessas análises são exibidos em uma tabela gerada pela função, apresentada no *Streamlit*. A seguir, há espaços destinados à inserção das imagens das tabelas geradas, para melhor visualização dos resultados:

Tabela 4 – Indicador fundamentalista P/L

Contagem	Empresa	Ticker	P/L	P/L (Análise)
1	Hidroviás do Brasil S.A.	HBSA3.SA	-6,46	Ruim
2	Estapar Participações S.A.	ALPK3.SA	-33,38	Ruim
3	Wilson Sons Holdings Brasil S.A.	PORT3.SA	14,44	Bom
4	Santos Brasil Participações S.A.	STBP3.SA	14,58	Bom
5	JSL S.A.	JSLG3.SA	5,05	Bom
6	Tegma Gestão Logística S.A.	TGMA3.SA	8,34	Bom
7	Rumo S.A.	RAIL3.SA	-51,11	Ruim
8	Log-In Logística Intermodal S.A.	LOGN3.SA	-68,28	Ruim
9	Randon S.A. Implementos e Participações	RAPT4.SA	9,99	Bom
10	Ecorodovias Infraestrutura e Logística S.A.	ECOR3.SA	4,25	Ruim
11	Armac Locação, Logística e Serviços S.A.	ARML3.SA	11,63	Bom
12	Ultrapar Participações S.A.	UGPA3.SA	7,24	Bom
13	CCR S.A.	CCRO3.SA	14,05	Bom
14	Log Commercial Properties e Participações S.A.	LOGG3.SA	6,21	Bom
15	Azul S.A.	AZUL4.SA	-0,29	Ruim

Fonte: Autor (2024)

Tabela 5 – Indicador fundamentalista *EV/EBITDA*

Contagem	Empresa	Ticker	<i>EV/EBITDA</i>	<i>EV/EBITDA</i> (Análise)
1	Hidroviás do Brasil S.A.	HBSA3.SA	20,02	Ruim
2	Estapar Participações S.A.	ALPK3.SA	4,85	Ruim
3	Wilson Sons Holdings Brasil S.A.	PORT3.SA	8,21	Bom
4	Santos Brasil Participações S.A.	STBP3.SA	9,38	Bom
5	JSL S.A.	JSLG3.SA	4,51	Ruim
6	Tegma Gestão Logística S.A.	TGMA3.SA	6,04	Bom
7	Rumo S.A.	RAIL3.SA	7,57	Bom
8	Log-In Logística Intermodal S.A.	LOGN3.SA	9,94	Bom
9	Randon S.A. Implementos e Participações	RAPT4.SA	5,71	Bom
10	Ecorodovias Infraestrutura e Logística S.A.	ECOR3.SA	4,49	Ruim
11	Armac Locação, Logística e Serviços S.A.	ARML3.SA	6,44	Bom
12	Ultrapar Participações S.A.	UGPA3.SA	5,69	Bom
13	CCR S.A.	CCRO3.SA	6,55	Bom
14	Log Commercial Properties e Participações S.A.	LOGG3.SA	41,91	Ruim
15	Azul S.A.	AZUL4.SA	21,62	Ruim

Fonte: Autor (2024)

Tabela 6 – Indicador fundamentalista margem líquida

Contagem	Empresa	Ticker	Margem Líquida	Margem Líquida (Análise)
1	Hidroviás do Brasil S.A.	HBSA3.SA	-14.98%	Ruim
2	Estapar Participações S.A.	ALPK3.SA	-1.34%	Ruim
3	Wilson Sons Holdings Brasil S.A.	PORT3.SA	17.37%	Bom
4	Santos Brasil Participações S.A.	STBP3.SA	27.37%	Bom
5	JSL S.A.	JSLG3.SA	2.95%	Ruim
6	Tegma Gestão Logística S.A.	TGMA3.SA	12.29%	Bom
7	Rumo S.A.	RAIL3.SA	-5.32%	Ruim
8	Log-In Logística Intermodal S.A.	LOGN3.SA	0.81%	Ruim
9	Randon S.A. Implementos e Participações	RAPT4.SA	3.09%	Ruim
10	Ecorodovias Infraestrutura e Logística S.A.	ECOR3.SA	9.03%	Ruim
11	Armac Locação, Logística e Serviços S.A.	ARML3.SA	12.69%	Bom
12	Ultrapar Participações S.A.	UGPA3.SA	2.20%	Ruim
13	CCR S.A.	CCRO3.SA	7.27%	Ruim
14	Log Commercial Properties e Participações S.A.	LOGG3.SA	147.78%	Bom
15	Azul S.A.	AZUL4.SA	-34.96%	Ruim

Fonte: Autor (2024)



Tabela 7 – Indicador fundamentalista *ROE*

Contagem	Empresa	Ticker	<i>ROE</i>	<i>ROE</i> (Análise)
1	Hidroviás do Brasil S.A.	HBSA3.SA	-17.39%	Ruim
2	Estapar Participações S.A.	ALPK3.SA	-3.84%	Ruim
3	Wilson Sons Holdings Brasil S.A.	PORT3.SA	19.56%	Bom
4	Santos Brasil Participações S.A.	STBP3.SA	33.86%	Bom
5	JSL S.A.	JSLG3.SA	14.54%	Ruim
6	Tegma Gestão Logística S.A.	TGMA3.SA	27.58%	Bom
7	Rumo S.A.	RAIL3.SA	-4.40%	Ruim
8	Log-In Logística Intermodal S.A.	LOGN3.SA	2.18%	Ruim
9	Randon S.A. Implementos e Participações	RAPT4.SA	14.49%	Ruim
10	Ecorodovias Infraestrutura e Logística S.A.	ECOR3.SA	26.77%	Bom
11	Armac Locação, Logística e Serviços S.A.	ARML3.SA	16.00%	Bom
12	Ultrapar Participações S.A.	UGPA3.SA	21.50%	Bom
13	CCR S.A.	CCRO3.SA	13.28%	Ruim
14	Log Commercial Properties e Participações S.A.	LOGG3.SA	8.55%	Ruim
15	Azul S.A.	AZUL4.SA	18.39%	Bom

Fonte: Autor (2024)

Hidroviás do Brasil S.A. (HBSA3.SA): Todos os indicadores foram classificados como "Ruim", indicando que a empresa está em uma situação financeira desfavorável. O P/L negativo sugere prejuízo, enquanto o *EV/EBITDA* alto e a margem líquida negativa indicam problemas operacionais e de rentabilidade.

Estapar Participações S.A. (ALPK3.SA): A empresa apresenta um P/L negativo e margem líquida negativa, sinalizando dificuldades em gerar lucro. O *EV/EBITDA* está próximo

ao limite inferior do benchmark, sugerindo que o mercado vê pouco valor nos seus lucros operacionais atuais.

Wilson Sons Holdings Brasil S.A. (PORT3.SA): Todos os indicadores foram classificados como "Bom", mostrando um desempenho financeiro consistente. A margem líquida e o *ROE* positivos são sinais de boa rentabilidade e eficiência operacional.

Santos Brasil Participações S.A. (STBP3.SA): A empresa se destaca em todos os indicadores, classificados como "Bom", sugerindo uma forte rentabilidade e boa avaliação pelo mercado. A margem líquida elevada é um ponto positivo relevante.

JSL S.A. (JSLG3.SA): Embora o P/L esteja dentro do benchmark, o *EV/EBITDA* foi classificado como "Ruim", indicando uma possível subavaliação dos lucros operacionais. A margem líquida baixa e um *ROE* próximo ao benchmark indicam eficiência questionável.

Tegma Gestão Logística S.A. (TGMA3.SA): Todos os indicadores, exceto a margem líquida, foram classificados como "Bom". A margem líquida superior a 10% é um ponto positivo, sugerindo uma rentabilidade razoável.

Rumo S.A. (RAIL3.SA): Apresenta um P/L muito negativo e margem líquida negativa, indicando um cenário desfavorável. O *EV/EBITDA* está dentro do benchmark, mas isso não compensa os demais indicadores fracos.

Log-In Logística Intermodal S.A. (LOGN3.SA): Todos os indicadores foram classificados como "Ruim", com destaque negativo para o P/L negativo e margem líquida próxima de zero, sugerindo dificuldades financeiras e baixa rentabilidade.

Randon S.A. Implementos e Participações (RAPT4.SA): Embora o P/L e *EV/EBITDA* estejam dentro do benchmark, a margem líquida baixa e o *ROE* apenas ligeiramente abaixo do benchmark indicam que a empresa precisa melhorar sua eficiência para aumentar a rentabilidade.

Ecorodovias Infraestrutura e Logística S.A. (ECOR3.SA): P/L e *EV/EBITDA* foram classificados como "Ruim", assim como a margem líquida. No entanto, o *ROE* elevado indica uma boa rentabilidade dos recursos próprios, sinalizando uma administração de patrimônio eficiente.

Armac Locação, Logística e Serviços S.A. (ARML3.SA): Todos os indicadores foram classificados como "Bom", sugerindo um bom desempenho financeiro e eficiência operacional. A margem líquida e *ROE* são pontos positivos.

Ultrapar Participações S.A. (UGPA3.SA): A empresa apresenta bons indicadores de P/L, *EV/EBITDA* e *ROE*, mas a margem líquida baixa indica dificuldades em converter vendas em lucro.

CCR S.A. (CCRO3.SA): Embora o P/L e *EV/EBITDA* estejam dentro do benchmark, a margem líquida foi classificada como "Ruim", indicando a necessidade de melhorar sua eficiência de custos para maximizar a rentabilidade.

Log Commercial Properties e Participações S.A. (LOGG3.SA): A empresa tem uma margem líquida muito alta, mas o *EV/EBITDA* fora do benchmark sugere uma sobrevalorização do valor da empresa. O *ROE* abaixo do benchmark também é uma preocupação.

Azul S.A. (AZUL4.SA): A empresa apresenta P/L e margem líquida negativas, sugerindo uma situação financeira difícil. O *EV/EBITDA* acima do benchmark indica uma possível sobrevalorização, enquanto o *ROE* é o único indicador classificado como "Bom", mostrando alguma rentabilidade dos recursos próprios.

A análise dos indicadores fundamentalistas (P/L, *EV/EBITDA*, Margem Líquida e *ROE*) das empresas do setor de logística e infraestrutura revela uma clara distinção entre empresas que têm mostrado consistência em rentabilidade e eficiência operacional e aquelas que estão enfrentando dificuldades financeiras significativas.

Empresas como Wilson Sons Holdings (PORT3.SA), Santos Brasil (STBP3.SA), Tagma (TGMA3.SA) e Armac Locação (ARML3.SA) demonstraram uma posição financeira sólida, com todos ou a maioria dos indicadores classificados como "Bom". Isso indica boa gestão operacional, eficiência na alocação de recursos e uma rentabilidade consistente, atributos essenciais em um setor altamente competitivo e dependente de grandes investimentos em infraestrutura.

Por outro lado, empresas como Hidrovias do Brasil (HBSA3.SA), Estapar (ALPK3.SA), Rumo (RAIL3.SA), e Log-In (LOGN3.SA) apresentam indicadores consistentemente classificados como "Ruim", destacando problemas operacionais, margens negativas e desafios para converter receitas em lucro. Isso sugere a necessidade de reestruturação e melhorias na gestão para superar as pressões financeiras e operacionais enfrentadas.

Outras empresas, como JSL (JSLG3.SA), Randon (RAPT4.SA) e Ultrapar (UGPA3.SA), mostraram um desempenho misto, com alguns indicadores dentro dos benchmarks e outros apresentando deficiências, o que indica uma necessidade de ajustes pontuais para melhorar a rentabilidade e eficiência.

Em termos gerais, as empresas que se destacaram positivamente possuem não apenas indicadores dentro dos benchmarks, mas também mostram uma eficiência na conversão de receitas em lucro e uma alavancagem adequada. Isso reforça a importância de uma gestão eficaz

de custos e de uma estratégia bem planejada para lidar com as particularidades do setor de logística e infraestrutura.

A análise evidencia a heterogeneidade no desempenho das empresas do setor, com alguns players mostrando o posicionamento financeiro e outros enfrentando desafios de mercado. Para obter sucesso neste setor, é fundamental que as empresas otimizem suas operações, alavanquem recursos de maneira eficiente e mantenham uma gestão eficaz de custos e investimentos. Essas práticas permitirão que as empresas sejam mais resilientes às flutuações macroeconômicas e se posicionem de forma competitiva em um ambiente de negócios desafiador e dinâmico.

Essas tendências refletirão diretamente na previsão dos gráficos dos tópicos a seguir, visto que o modelo de previsão é calibrado inicialmente utilizando indicadores fundamentalistas.

#### 4.1. RESULTADOS DA PREVISÃO DE PREÇOS

Neste trabalho, foi realizada a previsões dos preços de fechamento de diferentes ações utilizando a ferramenta *Prophet*, juntamente com uma análise fundamentalista das empresas escolhidas. A previsão foi realizada para um horizonte de um ano a partir dos dados históricos disponíveis, abrangendo de janeiro de 2022 a novembro de 2024. Foram usadas diferentes métricas para avaliar o desempenho do modelo, como MAE (Erro Absoluto Médio), MSE (Erro Quadrático Médio), RMSE (Raiz do Erro Quadrático Médio), MAPE (Erro Percentual Absoluto Médio), RMSPE (Raiz do Erro Percentual Absoluto Médio) e a porcentagem de previsões na direção correta da tendência.

Durante a análise, foram obtidos os dados históricos de cada ação e, posteriormente, o modelo *Prophet* foi utilizado para treinar e prever os preços futuros. Em seguida, comparamos os valores previstos com os valores reais históricos para calcular as métricas de erro, as quais nos forneceram uma boa ideia da precisão do modelo.

É importante destacar que o desempenho das previsões variou de acordo com a empresa e o período analisado. Em alguns casos, o modelo apresentou previsões bastante precisas, enquanto em outros, fatores externos, como eventos macroeconômicos ou notícias relevantes, podem ter afetado os resultados reais de forma significativa, reduzindo a precisão das previsões.

Abaixo segue o gráfico que ilustra a previsão dos preços de fechamento da ação, gerado a partir do modelo *Prophet*

Figura 21 - Gráfico preço histórico x Projeção futura HBSA3.SA



Fonte: Autor (2024)

Figura 22 -Gráfico preço histórico x projeção futura ALPK3.SA



Fonte: Autor (2024)

A análise das ações da Estapar Participações S.A. (ALPK3.SA) revela uma série de desafios que a empresa enfrenta e uma projeção preocupante para o futuro. O gráfico apresentado mostra tanto os preços históricos quanto a projeção futura dos valores das ações, sugerindo um cenário de dificuldade para os próximos anos, que exige medidas corretivas e estratégias eficazes por parte da empresa.

A linha azul, representando os preços históricos de fechamento, mostra uma queda significativa desde meados de 2022, marcada por um pico inicial seguido de uma descida acentuada. Ao longo de 2023, observamos uma volatilidade extrema, com momentos de alta seguidos por quedas bruscas, culminando em um declínio geral do valor da ação. Esse comportamento sugere uma instabilidade do mercado em relação à empresa, possivelmente motivada por fatores externos, como mudanças econômicas e variações na demanda pelos serviços oferecidos pela Estapar.

A projeção futura, representada pela linha vermelha, aponta para uma continuidade da tendência de queda. O gráfico sugere que, embora haja alguma estabilização momentânea nos preços ao longo de 2024, a tendência geral continua a ser de desvalorização das ações até meados de 2025. Essa previsão é preocupante, pois indica que a empresa terá dificuldades em reverter o quadro de queda de valor a curto e médio prazo, o que pode impactar a confiança dos investidores e reduzir sua capacidade de captação de recursos no mercado financeiro.

A situação apresentada demanda ações estratégicas por parte da gestão da Estapar. A empresa deve considerar uma reestruturação de seus serviços, com o intuito de reduzir custos e melhorar a eficiência operacional. Além disso, é essencial que sejam desenvolvidas novas oportunidades de negócio que permitam a diversificação das receitas, minimizando a dependência de segmentos que estejam em declínio. A comunicação eficaz com os investidores também é crucial neste momento, de forma a manter a transparência sobre as ações tomadas e os planos para enfrentar os desafios.

Em conclusão, a análise dos preços das ações da Estapar Participações S.A. aponta para um futuro desafiador, com tendência de declínio no valor de mercado da empresa. Para evitar uma erosão maior de valor e restaurar a confiança dos investidores, será fundamental a implementação de medidas corretivas e a busca por inovações em suas operações e serviços. O fortalecimento da resiliência operacional e a diversificação das fontes de receita são aspectos essenciais para a recuperação e sustentação da empresa no longo prazo.

Figura 23 - Gráfico preço histórico x projeção futura STBP3.SA



Fonte: Autor (2024)

A análise das ações da Santos Brasil Participações S.A. (STBP3.SA) apresenta uma perspectiva mais promissora em comparação com outros ativos do setor logístico. O gráfico fornecido demonstra a evolução dos preços de fechamento das ações, assim como a projeção futura, sugerindo uma tendência positiva para os próximos anos e uma estabilidade no valor de mercado da empresa.

Observando a linha azul, que representa os preços históricos, podemos notar que houve um crescimento gradual desde meados de 2022, com picos pontuais e uma tendência de alta que se manteve durante todo o período analisado. A partir de meados de 2023, observou-se uma forte aceleração no valor das ações, o que demonstra um aumento na confiança do mercado e uma valorização consistente. Esses movimentos indicam que a empresa foi capaz de capturar oportunidades de mercado, aumentando sua eficiência operacional e atraindo maior interesse de investidores.

A projeção futura, representada pela linha vermelha, também indica uma tendência de crescimento, embora com uma certa estabilidade ao final do período de previsão, em meados de 2025. Essa projeção positiva reflete expectativas favoráveis para o desempenho da Santos Brasil, podendo estar associada às suas estratégias de expansão e à sua capacidade de gestão de custos, fatores que têm potencial para melhorar sua competitividade no setor de logística portuária.

Essa projeção favorável é um bom indicativo para investidores, sugerindo um ambiente de crescimento sustentável para a empresa, diferente da tendência de declínio

observada em outras companhias do setor. No entanto, é importante que a empresa mantenha uma gestão proativa para garantir que os fatores positivos previstos continuem se materializando. A exploração de novas oportunidades de mercado e a manutenção da eficiência operacional são fundamentais para evitar uma possível reversão dessa tendência de crescimento.

Figura 24 - Gráfico preço histórico x projeção futura RAPT4.SA



Fonte: Autor (2024)

A análise das ações da Randon S.A. Implementos e Participações (RAPT4.SA) mostra um cenário de oscilação significativa nos preços das ações ao longo do período analisado, seguido de uma projeção preocupante para os próximos anos. O gráfico apresentado evidencia tanto o comportamento histórico das ações quanto as expectativas futuras, sugerindo desafios consideráveis para a empresa e a necessidade de revisões estratégicas.

A linha azul, que representa os preços históricos, revela um período de instabilidade entre 2022 e 2023, com picos e quedas sucessivas. Houve uma recuperação acentuada em meados de 2023, com os preços das ações chegando a valores elevados. No entanto, a partir de 2024, a linha azul mostra novamente uma volatilidade acentuada, indicando um mercado incerto e possivelmente respondendo a fatores externos e às condições operacionais da empresa. Esses movimentos indicam que a Randon tem enfrentado dificuldades para manter uma trajetória consistente de valorização, o que pode ser atribuído a questões internas de gestão e ao ambiente competitivo.

A linha vermelha, que representa a projeção futura dos preços, indica uma tendência de queda contínua e acentuada a partir de 2025. Essa previsão sugere que a empresa poderá



enfrentar dificuldades substanciais para manter o valor de suas ações, com uma possível desvalorização consistente. Esse cenário de declínio pode estar relacionado a uma série de fatores, como a capacidade limitada de adaptação às mudanças no mercado, problemas de gestão ou até mesmo ineficiência na operação, que podem impactar negativamente os resultados financeiros.

Para mitigar essa tendência negativa, a Randon deve considerar a implementação de mudanças significativas em sua estratégia. Isso inclui uma revisão das suas operações e processos para identificar áreas de ineficiência e oportunidades de redução de custos, além de uma revisão mais ampla das suas estratégias de mercado. Investimentos em inovação e em tecnologias que melhorem a eficiência produtiva podem ser uma alternativa para garantir a competitividade e restaurar a confiança dos investidores.

Em resumo, a análise das ações da Randon S.A. Implementos e Participações revela um cenário complexo e desafiador, com uma tendência de desvalorização prevista para os próximos anos. Para reverter esse quadro, a empresa precisará adotar uma postura proativa e implementar melhorias operacionais e estratégicas que garantam maior eficiência e competitividade no longo prazo.

Figura 25 - Gráfico preço histórico x projeção futura LOGN3.SA



Fonte: Autor (2024)

A análise das ações da Log-In Logística Intermodal S.A. (LOGN3.SA) indica um desempenho variável ao longo do período recente, com uma projeção futura que aponta para

uma tendência de desvalorização significativa. O gráfico fornecido reflete tanto o histórico de preços das ações quanto a previsão para os próximos anos, sugerindo um cenário desafiador para a empresa.

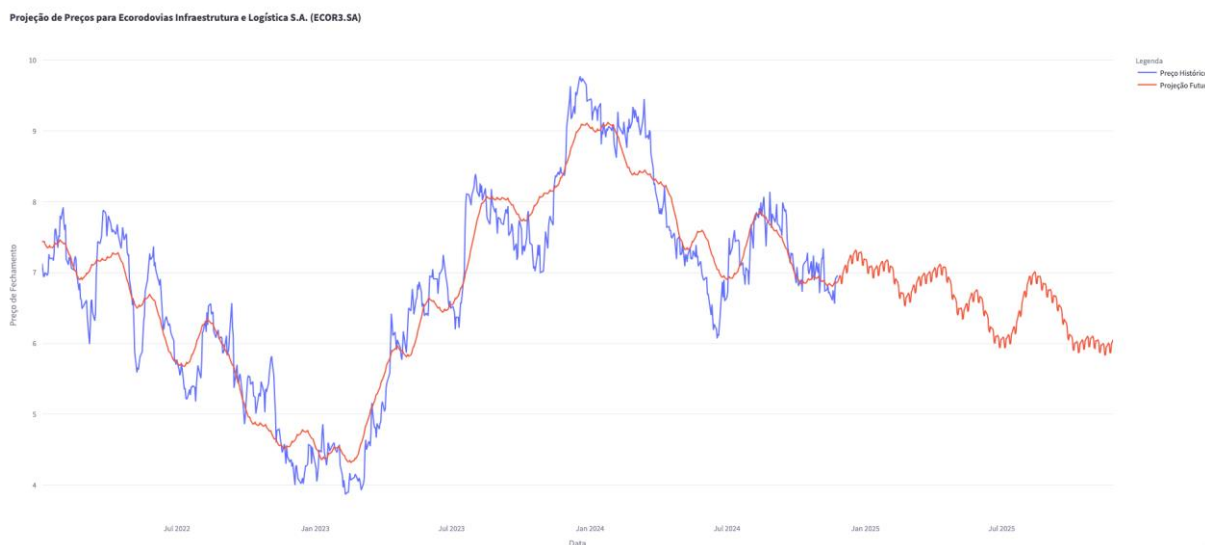
Observando a linha azul, que representa o preço histórico das ações, nota-se um período de crescimento consistente desde 2022, que culmina em um pico em meados de 2023, atingindo o valor mais alto de aproximadamente R\$ 50,00. Contudo, após esse período de alta, os preços passam a apresentar oscilações e um movimento de declínio. A partir do final de 2023, observa-se uma queda acentuada e continuada, que sugere uma diminuição na confiança do mercado em relação ao desempenho da Log-In Logística.

A projeção futura, representada pela linha vermelha, revela uma continuidade da tendência de queda até meados de 2025. Essa previsão negativa é indicativa de que a empresa pode enfrentar dificuldades significativas para manter o valor de suas ações. A descida acentuada pode ser reflexo de uma combinação de fatores, como a falta de crescimento nas receitas, desafios operacionais ou mudanças no ambiente macroeconômico que impactam negativamente a demanda pelos serviços da Log-In.

Para evitar uma erosão adicional de valor e buscar restaurar a confiança dos investidores, a Log-In Logística precisa adotar medidas proativas e estratégicas. Entre essas medidas, está a necessidade de fortalecer a eficiência operacional, revisar suas políticas de custos e avaliar possíveis oportunidades de diversificação do portfólio de serviços. Investimentos em inovação e na melhoria da infraestrutura podem também se mostrar essenciais para aumentar a competitividade da empresa no mercado e evitar que a tendência de desvalorização se intensifique.

Em conclusão, a análise das ações da Log-In Logística Intermodal S.A. mostra um cenário desafiador, com uma previsão de desvalorização sustentada para os próximos anos. Para superar essas adversidades e garantir uma perspectiva mais positiva, será essencial que a empresa busque uma estratégia que equilibre a eficiência operacional com iniciativas inovadoras, visando assim atrair maior confiança dos investidores e garantir estabilidade no longo prazo.

Figura 26 - Gráfico preço histórico x projeção futura ECOR3.SA



Fonte: Autor (2024)

A análise das ações da Ecorodovias Infraestrutura e Logística S.A. (ECOR3.SA) revela um cenário de oscilação no valor das ações, com uma projeção futura que sugere uma tendência de estabilização em um patamar ligeiramente mais baixo. O gráfico apresentado reflete tanto o comportamento histórico das ações quanto a previsão de seu desempenho para os próximos anos.

A linha azul, representando os preços históricos, mostra uma significativa volatilidade ao longo de 2022 e 2023. Durante esse período, os preços oscilaram entre R\$ 4,00 e R\$ 8,00, com um pico de valor alcançado no terceiro trimestre de 2023. Essa instabilidade pode refletir variações macroeconômicas ou ajustes no setor de infraestrutura e logística. No entanto, o que é interessante é o fato de que, após o pico, as ações não conseguiram sustentar um crescimento consistente, entrando novamente em um movimento de queda.

A linha vermelha, que apresenta a projeção futura, sugere que, embora a tendência geral seja de oscilações contínuas, o valor das ações tende a se estabilizar em torno de R\$ 6,00 a R\$ 7,00 nos próximos anos. Essa estabilização pode indicar que o mercado ajustou suas expectativas em relação ao desempenho da empresa, mantendo uma percepção moderada e sem grandes expectativas de valorização a curto prazo. A falta de uma tendência de crescimento mais acentuada sugere que a empresa pode estar enfrentando limitações no aumento de sua eficiência operacional ou nas oportunidades de crescimento do setor.

Em resumo, a análise das ações da Ecorodovias Infraestrutura e Logística S.A. revela um cenário de instabilidade no curto prazo, seguido por uma tendência de estabilização em um patamar moderado nos próximos anos. Para garantir a valorização das ações e atrair novos investidores, a empresa precisará investir em melhorias operacionais, projetos inovadores e fortalecer seu posicionamento competitivo no mercado de infraestrutura e logística.

Figura 27 - Gráfico preço histórico x projeção futura ARML3.SA



Fonte: Autor (2024)


A análise das ações da Armac Locação, Logística e Serviços S.A. (ARML3.SA) mostra um cenário desafiador, com uma projeção de desvalorização para os próximos anos. O gráfico fornecido reflete tanto o comportamento histórico das ações quanto a previsão futura dos seus preços, sugerindo um período de dificuldades e um possível declínio contínuo.

Observando a linha azul, que representa o preço histórico, podemos notar um início de alta volatilidade entre 2022 e 2023, com quedas acentuadas seguidas por recuperações parciais. Houve uma estabilização relativa em alguns momentos, mas o preço não conseguiu sustentar um padrão de crescimento consistente. Durante o ano de 2023, o valor das ações se manteve na faixa de R\$ 10,00 a R\$ 15,00, mostrando uma dificuldade em superar resistências importantes que poderiam indicar uma recuperação mais robusta.

A linha vermelha, que apresenta a projeção futura, indica uma tendência de declínio acentuado a partir de 2025, sugerindo que a empresa pode enfrentar uma erosão significativa no valor de suas ações. Essa tendência negativa levanta preocupações sobre a capacidade da

empresa de se manter competitiva e atravessar os desafios operacionais e financeiros que possivelmente estão impactando seus resultados. O movimento descendente acentuado indica a falta de perspectivas otimistas no curto e médio prazo.

Figura 28 - Gráfico preço histórico x projeção futura UGPA3.SA



Fonte: Autor (2024)

A análise das ações da Ultrapar Participações S.A. (UGPA3.SA) mostra um comportamento cíclico com uma projeção preocupante para os próximos anos, sugerindo uma desvalorização considerável no horizonte futuro. O gráfico fornecido reflete tanto o preço histórico das ações quanto a previsão para os próximos anos, indicando desafios substanciais para a empresa.

A linha azul, que representa os preços históricos, mostra um crescimento gradual desde 2022, atingindo um pico de aproximadamente R\$ 28,00 no primeiro semestre de 2024. Essa valorização demonstra um aumento na confiança do mercado, possivelmente associado a uma melhora nas condições operacionais ou a uma perspectiva de crescimento em setores estratégicos da empresa. No entanto, após atingir o pico, os preços começaram a declinar, sugerindo que o momentum positivo não foi sustentável a longo prazo.

A projeção futura, apresentada pela linha vermelha, aponta para um declínio constante e acentuado dos preços das ações até meados de 2025, com uma previsão de estabilização em valores menores do que os atuais. Essa tendência de queda sugere dificuldades para a Ultrapar em manter um crescimento sustentável e pode estar associada a desafios operacionais,

mudanças no cenário macroeconômico ou pressões competitivas que impactam negativamente o desempenho da empresa.

Figura 29 - Gráfico preço histórico x projeção futura AZUL4.SA



Fonte: Autor (2024)

A análise das ações da Azul S.A. (AZUL4.SA) revela um cenário desafiador, com uma projeção de desvalorização significativa no futuro próximo. O gráfico fornecido apresenta tanto os preços históricos quanto as previsões para os próximos anos, indicando uma perspectiva preocupante para a empresa no mercado financeiro.

A linha azul, que representa o preço histórico das ações, mostra uma volatilidade acentuada desde 2022, com altos e baixos marcantes. No início do período analisado, as ações chegaram a atingir um pico próximo de R\$ 30,00, seguido por uma queda significativa ao longo do ano de 2023. Observa-se que, apesar de alguns momentos de recuperação, os preços não conseguiram se sustentar em um patamar elevado, refletindo possivelmente as dificuldades do setor de aviação, afetado por condições macroeconômicas adversas e aumento dos custos operacionais.

A projeção futura, representada pela linha vermelha, indica uma tendência de queda contínua e bastante acentuada até 2025, com preços previstos para valores negativos, o que, na prática, reflete uma perspectiva de desvalorização extrema e dificuldades para a empresa manter sua sustentabilidade financeira. Esta projeção negativa é um indicativo de sérias limitações estruturais e operacionais que precisam ser abordadas para que a empresa possa evitar uma perda ainda maior de valor de mercado.

Figura 30 - Gráfico preço histórico x projeção futura LOGG3.SA

Projeção de Preços para Log Commercial Properties e Participações S.A. (LOGG3.SA)



Fonte: Autor (2024)

A análise das ações da Log Commercial Properties e Participações S.A. (LOGG3.SA) mostra um comportamento volátil e uma projeção de estabilização, mas com valores oscilantes, sugerindo um período de incerteza para o futuro da empresa. O gráfico apresentado reflete tanto o preço histórico quanto as projeções para os próximos anos, indicando um cenário de estabilidade com oscilações no curto e médio prazo.

Observando a linha azul, que representa o preço histórico das ações, nota-se um comportamento de queda acentuada desde meados de 2022, alcançando valores próximos de R\$ 14,00 no início de 2023. A partir desse ponto, houve uma recuperação parcial, e o preço passou a oscilar na faixa entre R\$ 18,00 e R\$ 25,00. A volatilidade significativa mostra que o mercado ainda possui incertezas sobre o desempenho da empresa, provavelmente devido às condições macROEconômicas ou a fatores internos que impactam diretamente sua capacidade de gerar valor.

A projeção futura, representada pela linha vermelha, indica que, apesar de não haver uma tendência clara de crescimento ou queda acentuada, os valores das ações tendem a se estabilizar em um patamar que varia entre R\$ 18,00 e R\$ 24,00, mantendo-se em uma faixa volátil. Essa previsão sugere que o mercado espera um período de incerteza e oscilantes expectativas para a Log Commercial Properties, sem grandes indicações de valorização significativa ou declínio substancial.

Figura 31 - Gráfico preço histórico x projeção futura TGMA3.SA



Fonte: Autor (2024)

A análise das ações da Tagma Gestão Logística S.A. (TGMA3.SA) apresenta um cenário promissor, com projeções de valorização para os próximos anos. O gráfico fornecido demonstra tanto o comportamento histórico quanto as expectativas futuras dos preços das ações, indicando uma perspectiva positiva de crescimento e uma possível consolidação de um patamar mais elevado.

A linha azul, que representa o preço histórico, mostra uma trajetória de crescimento constante desde meados de 2022. As ações da Tagma saíram de valores próximos de R\$ 15,00 para um patamar que ultrapassa R\$ 25,00 em 2024, sugerindo uma recuperação sustentada e um aumento na confiança dos investidores. Essa valorização pode ser atribuída a melhorias nos resultados operacionais da empresa, ao fortalecimento de suas atividades e à capacidade de capturar oportunidades de mercado no setor logístico.

A projeção futura, representada pela linha vermelha, indica uma tendência de valorização consistente, com os preços das ações ultrapassando os R\$ 30,00 a partir de 2025. Essa previsão positiva sugere que o mercado enxerga potencial de crescimento significativo para a Tagma, possivelmente relacionado à expansão de suas atividades, à eficiência operacional e à adaptação a novas demandas logísticas. A projeção mostra ainda um comportamento de estabilização em um patamar mais elevado, o que pode indicar uma base sustentável para o crescimento futuro da empresa.



Figura 32 - Gráfico preço histórico x projeção futura PORT3.SA



Fonte: Autor (2024)

A análise das ações da Wilson Sons Holdings Brasil S.A. (PORT3.SA) mostra uma trajetória de crescimento gradual, seguida por uma estabilização projetada nos próximos anos, sugerindo uma perspectiva de consolidação do valor de mercado em um patamar mais elevado. O gráfico apresentado reflete tanto o comportamento histórico quanto a projeção futura dos preços das ações, indicando um período de otimismo moderado para a empresa.

Observando a linha azul, que representa os preços históricos, nota-se que as ações tiveram um crescimento contínuo desde meados de 2022, saindo de um patamar próximo de R\$ 9,00 e chegando a superar os R\$ 14,00 em meados de 2024. Esse aumento reflete uma percepção positiva do mercado em relação à empresa, possivelmente devido a resultados financeiros favoráveis ou a uma melhora nas expectativas do setor. No entanto, após atingir o pico, houve uma estabilização, com os preços flutuando em torno desse valor máximo.

A projeção futura, representada pela linha vermelha, sugere um movimento de estabilização a partir de 2025, com oscilações moderadas ao longo do período. Essa previsão indica que, embora não haja uma tendência clara de valorização acentuada, também não se espera uma desvalorização significativa das ações. Esse cenário reflete um mercado confiante na estabilidade da empresa, mas sem grandes expectativas de crescimento abrupto, o que sugere que a Wilson Sons precisará continuar a trabalhar para manter e melhorar seus níveis de desempenho.

Figura 33 - Resultados consolidados previsões preliminares x indicadores do mercado



Fonte: Autor (2024)

A análise do gráfico comparativo entre as ações da LOG-BR e diferentes indicadores financeiros revela um cenário complexo, com diferentes comportamentos para cada ativo analisado. O gráfico mostra a variação percentual dos preços ao longo do tempo, abrangendo tanto dados históricos quanto projeções para os próximos anos. Os indicadores comparados incluem o S&P500, o Ibovespa, o IPCA e o CDI, proporcionando uma visão abrangente sobre a performance das ações da LOG-BR em relação ao mercado global e local.

**Ações LOG (Histórico e Projeção):** As ações da LOG-BR apresentam um crescimento consistente ao longo do tempo, com uma projeção de alta acentuada nos próximos anos. Essa valorização esperada pode refletir uma confiança renovada dos investidores, possivelmente devido a fundamentos sólidos da empresa ou expectativas de crescimento no setor logístico. A linha azul tracejada representa a projeção, que sugere uma ascensão constante, superando a performance de outros indicadores, como o Ibovespa e o CDI.

**S&P500 (Histórico e Projeção):** O índice S&P500, representado pela linha verde, apresenta uma oscilação significativa, refletindo as condições do mercado norte-americano, especialmente afetado por eventos macroeconômicos globais. A projeção indica uma recuperação gradual, sugerindo que o mercado global está se estabilizando após um período de alta volatilidade.

Ibovespa (Histórico e Projeção): O índice Ibovespa, representado pela linha vermelha, mostra um crescimento constante ao longo do tempo, mas com algumas oscilações. A projeção sugere uma continuidade dessa tendência, embora em ritmo moderado. Isso pode indicar uma expectativa de crescimento no mercado brasileiro, ainda que com certa cautela por parte dos investidores.

IPCA (Histórico e Projeção): O IPCA, representado pela linha laranja, apresenta uma tendência de estabilização, tanto nos dados históricos quanto nas projeções. Essa estabilidade indica um controle da inflação dentro dos patamares esperados, o que é um ponto positivo para a economia e pode impactar positivamente os investimentos, reduzindo incertezas.

CDI (Histórico e Projeção): O CDI, representado pela linha roxa, demonstra uma tendência de estabilidade, com projeções que indicam uma leve subida. Isso reflete as taxas de juros no mercado brasileiro, que, quando altas, tornam investimentos de renda fixa mais atrativos, em contraponto a investimentos de maior risco, como as ações.

A comparação entre as ações da LOG-BR e os demais índices indica que o ativo apresenta um potencial de crescimento significativo em comparação com o S&P500 e o Ibovespa. No entanto, observa-se que há um aumento de volatilidade ao longo do tempo, o que pode gerar riscos aos investidores. A linha de projeção das ações da LOG-BR aponta uma valorização expressiva, superando os outros índices no período analisado.

Em contrapartida, o CDI e o IPCA, que são indicadores econômicos ligados à economia real e aos juros, apresentam uma estabilização que, embora mais segura, oferece um retorno mais conservador. Essa diferença sugere que investidores que buscam maior potencial de retorno estão mais inclinados a considerar ações como as da LOG-BR, assumindo um maior risco em busca de melhores ganhos.

A análise dos erros de previsão das ações das empresas listadas permite identificar as dificuldades e desafios que cada uma delas enfrenta no que diz respeito à precisão dos modelos preditivos utilizados. Abaixo, apresento uma discussão ação por ação sobre os valores de erro e o que possivelmente contribuiu para tais resultados.

Tabela 8 – Erros de previsão análise preliminar

Ticker	MAE	MSE	RMSE	MAPE	RMSPE	Direção Correta
HBSA3.SA	0,14268076	0,032203955	0,179454604	4,659262547	5,920565899	50,48275862%
ALPK3.SA	0,26837112	0,137047385	0,370199115	10,25221692	17,30138577	52,13793103%
PORT3.SA	0,40894168	0,26328002	0,513108195	3,404584702	4,303949195	50,75862069%
STBP3.SA	0,461748779	0,324700885	0,569825311	5,110730591	6,4675158	55,31034483%
JSLG3.SA	0,535161085	0,445472577	0,667437321	6,870659214	8,781631543	54,34482759%
TGMA3.SA	0,677713224	0,721533754	0,84943143	3,199733086	3,987431562	57,51724138%
RAIL3.SA	0,711742407	0,765635164	0,875005808	3,608155721	4,490570841	54,20689655%
LOGN3.SA	2,161225236	7,28369529	2,698832209	6,122866535	7,749318577	54,06896552%
RAPT4.SA	0,517729799	0,424734643	0,651716689	5,022011725	6,442111308	56,13793103%
ECOR3.SA	0,342019228	0,1784707	0,422457927	5,241387891	6,600689475	54,62068966%
ARML3.SA	1,185744868	2,040852518	1,428584095	8,922942208	10,69536251	54,20689655%
UGPA3.SA	0,476381323	0,345968412	0,588190796	2,776623074	3,507486851	57,37931034%
CCRO3.SA	0,396345807	0,227393545	0,476857992	3,135560707	3,807580418	54,06896552%
LOGG3.SA	1,570883223	3,765976804	1,940612482	7,441305156	9,293363533	55,72413793%
AZUL4.SA	1,588724617	3,878543815	1,969401893	11,86188238	14,90985587	52,55172414%

Fonte: Autor (2024)

Hidroviás do Brasil S.A. (HBSA3.SA): Com um MAE de 0,1426 e MAPE de 4,66%, os erros absolutos para a Hidroviás do Brasil são relativamente baixos. A direção correta foi atingida em 50,48% dos casos, sugerindo uma previsão consistente, mas com margem para melhorias. A baixa variabilidade dos preços pode ter contribuído para os bons resultados de previsão.

Estarpar Participações S.A. (ALPK3.SA): Apresenta um MAPE de 10,25%, que indica erros de previsão mais significativos. A variabilidade nos preços e as oscilações específicas ao setor de estacionamentos podem ter dificultado a previsão precisa, especialmente em momentos de instabilidade econômica.

Wilson Sons Holdings Brasil S.A. (PORT3.SA): O MAE de 0,4089 e o MAPE de 3,40% indicam que as previsões foram relativamente boas, com baixas taxas de erro percentual. A precisão da direção correta foi de 50,76%, sugerindo que o modelo capturou bem o comportamento do mercado, embora ainda exista uma margem de incerteza.

Santos Brasil Participações S.A. (STBP3.SA): Apresentou um MAPE de 5,11%, e uma direção correta em 55,31% das previsões. Os erros são moderados, o que sugere que o modelo conseguiu acompanhar as oscilações de preço da empresa, possivelmente devido à natureza mais previsível do setor portuário.

JSL S.A. (JSLG3.SA): Com um MAE de 0,5351 e um MAPE de 6,87%, a previsão foi razoável. A precisão em 54,34% indica que há espaço para melhorias, possivelmente devido à complexidade dos serviços oferecidos pela JSL e a alta dependência de fatores macroeconômicos.

Tegma Gestão Logística S.A. (TGMA3.SA): Apresentou um MAE de 0,6777 e um MAPE de apenas 3,20%, sugerindo uma boa previsão do ponto de vista percentual. A direção correta foi atingida em 57,51% dos casos, o que é positivo e sugere um modelo robusto para esta empresa.

Rumo S.A. (RAIL3.SA): Com um MAPE de 3,61% e uma precisão de direção de 54,21%, o modelo se mostrou relativamente eficaz, embora o MAE de 0,7117 indique que há margens de erro que poderiam ser aprimoradas.

Log-In Logística Intermodal S.A. (LOGN3.SA): Apresentou um MAE de 2,1612, o mais elevado dentre as empresas analisadas, e um MAPE de 6,12%. Isso indica que a previsão não foi tão eficaz, provavelmente devido à alta volatilidade dos preços e à incerteza associada ao setor logístico intermodal.

Randon S.A. Implementos e Participações (RAPT4.SA): Com um MAE de 0,5177 e um MAPE de 5,02%, a previsão foi razoável, sendo que a precisão em relação à direção correta foi de 56,14%. Isso sugere que o modelo conseguiu capturar bem a tendência da empresa, embora os erros absolutos ainda sejam significativos.

Ecorodovias Infraestrutura e Logística S.A. (ECOR3.SA): Apresentou um MAPE de 5,24% e um MAE de 0,3420, indicando uma previsão de erro moderado. A direção correta foi obtida em 54,62% dos casos, sugerindo que o modelo foi relativamente eficaz, especialmente considerando a estabilidade esperada no setor de infraestrutura.

Armac Locação, Logística e Serviços S.A. (ARML3.SA): Com um MAE de 1,1857 e um MAPE de 8,92%, os erros são altos, sugerindo que o modelo teve dificuldades em prever os preços de forma precisa, possivelmente devido à natureza volátil e às mudanças rápidas nos custos e demandas do setor de locação e logística.

Ultrapar Participações S.A. (UGPA3.SA): Apresentou um MAE de 0,4763 e um MAPE de apenas 2,78%, indicando uma previsão bastante precisa. A direção correta foi obtida em 57,38% dos casos, sugerindo uma boa capacidade de previsão do modelo.

CCR S.A. (CCRO3.SA): Com um MAE de 0,3963 e um MAPE de 3,14%, o modelo se mostrou relativamente eficaz, com uma direção correta de 54,07%. Esses valores indicam uma boa previsão, especialmente considerando a estabilidade dos serviços de concessão de infraestrutura.

Log Commercial Properties e Participações S.A. (LOGG3.SA): Apresentou um MAE de 1,5709 e um MAPE de 7,44%, indicando uma previsão com erros mais elevados. A alta variabilidade e o comportamento especulativo do setor imobiliário podem ter contribuído para esses resultados.

Azul S.A. (AZUL4.SA): Com um MAE de 1,5887 e um MAPE de 11,86%, a Azul apresenta um dos maiores índices de erro percentual, sugerindo uma alta dificuldade na previsão dos preços das ações. A volatilidade no setor de aviação, influenciada por fatores externos como preços de combustíveis e demanda por viagens, pode ter gerado esses altos índices de erro.

De forma geral, observa-se que as previsões para empresas do setor logístico e de transporte, como Log-In e Azul, apresentam maiores margens de erro, o que pode ser atribuído à alta volatilidade e incertezas que esses setores enfrentam. Empresas com operações mais previsíveis, como Ultrapar e CCR, mostraram melhores índices de previsão, sugerindo que a estabilidade das atividades influencia positivamente a precisão dos modelos.

#### 4.3 RESULTADOS OTIMIZADOS COM *BERT*

Após a análise inicial, foram realizadas otimizações no modelo para melhorar a precisão das previsões. O gráfico abaixo mostra as previsões dos preços com os parâmetros ajustados e comparadas ao histórico.

Figura 34 - Projeção otimizada x inicial x preço histórico HBS3.SA



Fonte: Autor (2024)

O gráfico apresenta uma nova projeção de preços para Hidrovias do Brasil S.A. (HBSA3.SA), semelhante ao gráfico anterior. Ele contém três linhas principais: o histórico de

preços (linha azul), a projeção futura inicial (linha vermelha) e a projeção otimizada (linha verde).

Podemos observar que a projeção otimizada (linha verde) mostra uma melhoria significativa em relação à projeção futura inicial (linha vermelha), suavizando a tendência de queda e se alinhando de forma mais coerente ao histórico de preços. Essa otimização se deve ao uso de um modelo mais sofisticado, incorporando análises de sentimentos de notícias com a aplicação do *BERT*, o que resultou em uma maior capacidade de prever flutuações do mercado de forma mais realista.

A abordagem otimizada leva em conta os sentimentos expressos em notícias relevantes para ajustar suas previsões, garantindo uma maior aderência aos padrões históricos e mitigando extremos presentes na projeção inicial. Isso reforça a importância de incorporar variáveis qualitativas na modelagem financeira para aprimorar a precisão das previsões.

Figura 35 - Projeção otimizada x inicial x preço histórico ALPK3.SA



Fonte: Autor (2024)

Figura 36 - Projeção otimizada x inicial x preço histórico PORT3.SA



Fonte: Autor (2024)

No gráfico de projeção de preços para Wilson Sons Holdings Brasil S.A. (PORT3.SA), a versão otimizada apresenta um ajuste mais próximo do comportamento histórico, enquanto a projeção futura inicial sugere uma volatilidade mais pronunciada. A análise de sentimentos, realizada com *BERT*, permitiu suavizar a projeção e melhorar a aderência ao histórico, sugerindo uma abordagem mais realista e menos suscetível a flutuações extremas. A incorporação desses fatores resultou em previsões mais consistentes e alinhadas ao desempenho histórico.

Figura 37 - Projeção otimizada x inicial x preço histórico JSLG3.SA



Fonte: Autor (2024)



Neste gráfico da projeção de preços para JSL S.A. (JSLG3.SA), a projeção otimizada demonstra um ajuste mais aderente ao padrão histórico, enquanto a projeção inicial sugere uma tendência de queda exacerbada. A utilização da análise de sentimentos *BERT* permitiu uma abordagem mais calibrada, refletindo de maneira mais realista os movimentos esperados do mercado. Isso resultou em uma projeção otimizada que é menos extrema e mais estável, oferecendo uma representação mais robusta e alinhada com os dados históricos.

Figura 38 - Projeção otimizada x inicial x preço histórico STBP3.SA



Fonte: Autor (2024)

No gráfico da projeção de preços para Santos Brasil Participações S.A. (STBP3.SA), a projeção otimizada oferece um ajuste mais suave e consistente com o histórico, diferentemente da projeção inicial que sugere um aumento acentuado e maior volatilidade. A utilização da análise de sentimentos por *BERT* aprimorou a robustez do modelo, resultando em previsões mais realistas, evitando exageros e refletindo de maneira equilibrada o comportamento esperado do mercado.

Figura 39 - Projeção otimizada x inicial x preço histórico RAIL3.SA



Fonte: Autor (2024)

No gráfico de projeção de preços para Rumo S.A. (RAIL3.SA), observa-se que a projeção otimizada consegue reproduzir um comportamento mais moderado e alinhado aos padrões históricos, ao passo que a projeção inicial indica uma queda mais acentuada. A utilização da análise de sentimentos baseada em *BERT*, incorporando informações extraídas de notícias, resultou em uma previsão mais realista proporcionando maior estabilidade e aderência ao comportamento passado, o que melhora significativamente a confiança na projeção.

Figura 40 - Projeção otimizada x inicial x preço histórico ECOR3.SA



Fonte: Autor (2024)

No gráfico de projeção de preços para Ecorodovias Infraestrutura e Logística S.A. (ECOR3.SA), a projeção otimizada proporciona um ajuste mais realista, refletindo melhor as flutuações observadas no histórico. Enquanto a projeção inicial indica uma variabilidade acentuada, a otimização suaviza o comportamento, tornando a previsão mais coerente com as tendências passadas. A incorporação da análise de sentimentos *BERT* contribuiu para um modelo mais confiável, reduzindo exageros e resultando em uma projeção mais alinhada ao histórico de desempenho dos preços.

Figura 41 - Projeção otimizada x inicial x preço histórico LOGG3.SA



Fonte: Autor (2024)

Neste gráfico de projeção de preços para Log Commercial Properties e Participações S.A. (LOGG3.SA), há uma oscilação significativa no final do período projetado, refletida tanto na projeção inicial quanto na otimizada. Essa grande variabilidade pode ser causada por diversos fatores, incluindo incertezas que afetam diretamente o setor imobiliário, como mudanças nas taxas de juros, volatilidade no cenário político-econômico ou impactos de eventos globais que induzem a incerteza dos investidores.

O fato de a oscilação não ter sido corrigida no modelo otimizado indica que as variáveis de entrada, como os sentimentos capturados através das notícias e outras métricas usadas, sugerem um mercado volátil e sem consenso claro sobre a direção dos preços. Além

disso, a análise de sentimentos *BERT*, apesar de ser eficaz para captar nuances de percepção de mercado, pode não ser capaz de eliminar completamente a variabilidade, especialmente quando as informações externas são contraditórias ou refletem um ambiente altamente especulativo. Portanto, essa oscilação reflete a natureza de um mercado incerto e a dificuldade de obter previsões de alta precisão em tais contextos.

Figura 42 - Projeção otimizada x inicial x preço histórico TGMA3.SA



Fonte: Autor (2024)

No gráfico de projeção de preços para Tagma Gestão Logística S.A. (TGMA3.SA), há uma oscilação considerável no final do período, particularmente visível na projeção inicial. Esse comportamento pode ser explicado pela incorporação de fatores de mercado incertos ou divergentes, especialmente relacionados ao setor de logística, que é suscetível a variáveis como custos de transporte, mudanças regulatórias e demanda econômica geral.

A projeção otimizada, embora apresente uma maior suavização das variações, ainda reflete parte dessa volatilidade, o que sugere que as entradas para o modelo, como análises de sentimentos por *BERT*, identificaram sinais mistos no mercado. A presença de eventos macroeconômicos e notícias conflitantes pode ter resultado em um cenário de difícil previsão precisa, justificando a manutenção de alguma oscilação residual mesmo na versão otimizada. Essa oscilação não foi corrigida por completo, pois o modelo busca capturar todas as incertezas percebidas, garantindo que a projeção reflita tanto o risco quanto a possibilidade de valorização do ativo.

Figura 43 - Projeção otimizada x inicial x preço histórico LOGN3.SA



Neste gráfico de projeção de preços para Log-In Logística Intermodal S.A. (LOGN3.SA), a projeção inicial sugere uma queda significativa no valor do ativo, refletindo uma perspectiva de depreciação mais severa. Por outro lado, a projeção otimizada apresenta uma suavização dessa queda, oferecendo uma abordagem mais calibrada e menos dramática.

Figura 44 - Projeção otimizada x inicial x preço histórico AZUL4.SA



Fonte: Autor (2024)

No gráfico de projeção de preços para Azul S.A. (AZUL4.SA), observa-se que a projeção otimizada atenua de forma significativa a trajetória de queda inicialmente projetada, mostrando uma tendência mais moderada. A projeção inicial indica uma queda contínua e intensa, que poderia ser fruto de expectativas negativas exacerbadas sobre o setor de aviação, muitas vezes impactado por fatores como variação do câmbio, preços do combustível e incertezas macROEconômicas.

Figura 45 - Projeção otimizada x inicial x preço histórico RAPT4.SA



Fonte: Autor (2024)

No gráfico de projeção de preços para Randon S.A. Implementos e Participações (RAPT4.SA), a projeção otimizada mostra uma redução considerável na volatilidade e uma atenuação da tendência de queda inicialmente sugerida. A projeção inicial indicava uma trajetória de declínio mais acentuada, possivelmente refletindo um cenário negativo excessivo para a empresa e seu setor, que é influenciado por condições macroeconômicas e demanda industrial.

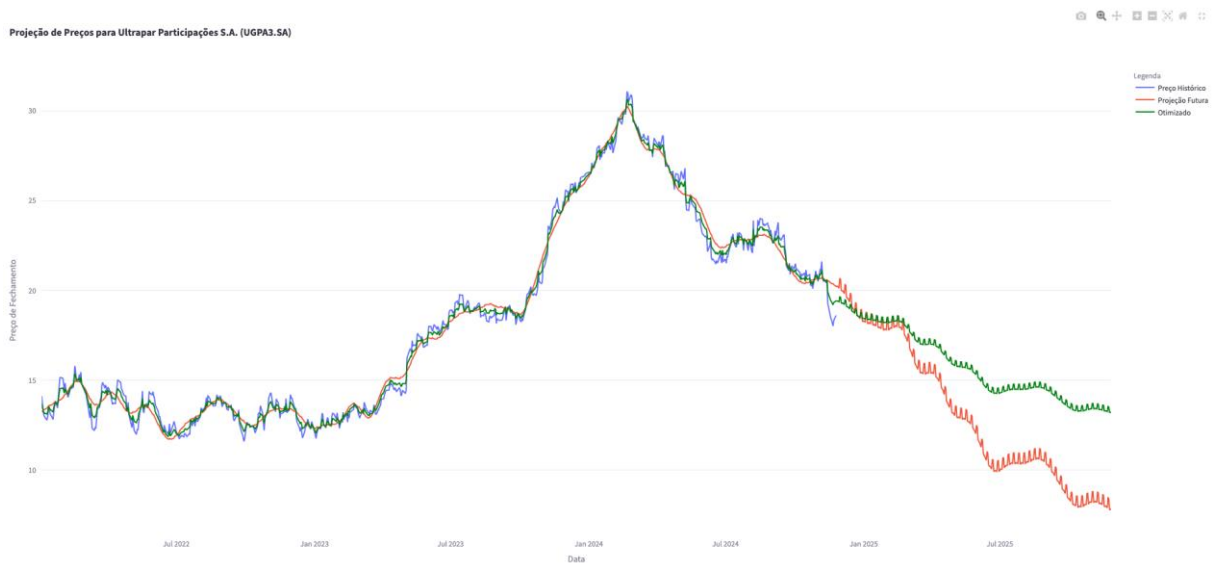
Figura 46 - Projeção otimizada x inicial x preço histórico ARML3.SA



Fonte: Autor (2024)

No gráfico de projeção de preços para Arma Locação, Logística e Serviços S.A. (ARML3.SA), a projeção otimizada apresenta um comportamento significativamente mais estável e menos acentuado em comparação com a projeção inicial, que indica uma queda contínua e substancial.

Figura 47 - Projeção otimizada x inicial x preço histórico UGPA3.SA



Fonte: Autor (2024)

No gráfico de projeção de preços para Ultrapar Participações S.A. (UGPA3.SA), a projeção otimizada apresenta uma queda mais controlada em relação à projeção inicial, que

exibe uma tendência descendente acentuada e volátil. A projeção otimizada ajusta-se de forma mais realista ao comportamento histórico da ação, sugerindo que o modelo conseguiu capturar uma percepção de mercado mais equilibrada e fundamentada, evitando os extremos observados na projeção inicial.

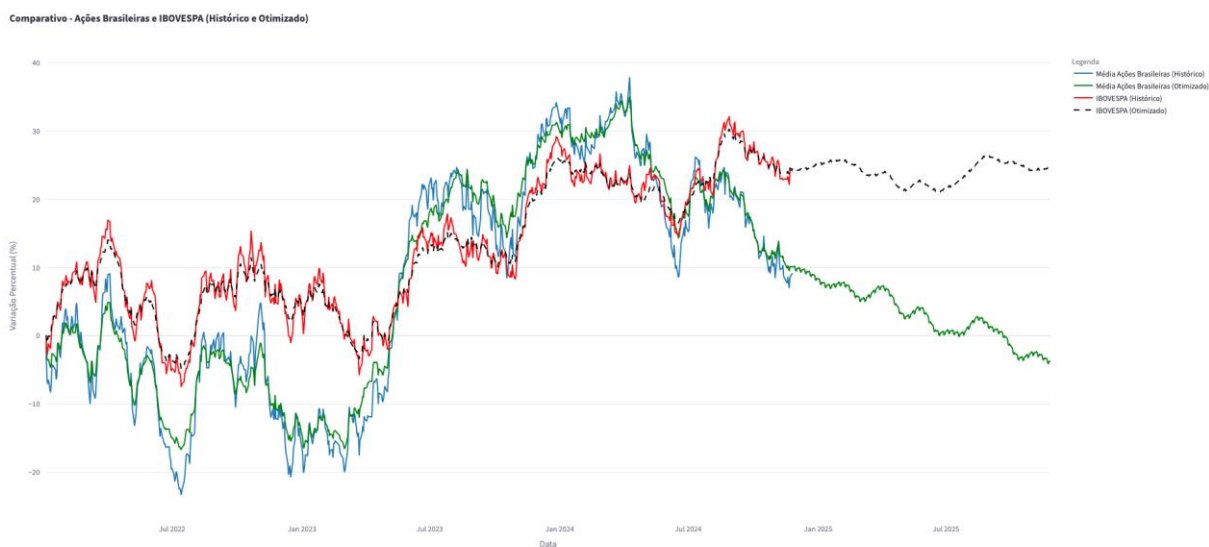


Fonte: Autor (2024)

No gráfico de projeção de preços para CCR S.A. (CCRO3.SA), a projeção otimizada apresenta uma trajetória menos volátil e mais próxima do comportamento histórico em comparação com a projeção inicial, que exibe uma variabilidade maior e menos consistente. A projeção inicial demonstra uma tendência de alta e queda abruptas, sugerindo incertezas consideráveis ou flutuações esperadas no cenário futuro da empresa.



Figura 48 - Gráfico resultados ações histórico e otimizado x IBOVESPA



Este gráfico apresenta uma comparação entre o índice IBOVESPA e a média das ações de empresas de logística brasileiras, tanto em suas trajetórias históricas quanto nas projeções otimizadas. Os dados históricos indicam uma correlação bastante próxima entre o comportamento do IBOVESPA e as ações de logística, o que é esperado, já que o setor de logística está intrinsecamente ligado ao desempenho econômico geral e, portanto, tende a se mover de forma consistente com o mercado.

Historicamente, os movimentos das ações de logística tendem a seguir o comportamento do IBOVESPA, dado que o setor é altamente sensível a fatores macroeconômicos como crescimento econômico, inflação, e custos operacionais (como combustíveis e mão de obra). Quando a economia está em expansão, há um aumento no transporte de bens, impulsionando o setor de logística. No entanto, períodos de contração ou incerteza econômica afetam negativamente esse setor, o que também se reflete no desempenho do IBOVESPA.

Observa-se que tanto as ações de logística quanto o IBOVESPA tiveram momentos de alta e baixa alinhados, indicando que eventos macroeconômicos impactaram simultaneamente ambos os índices. Por exemplo, a ascensão observada até meados de 2023 reflete um cenário de otimismo econômico, enquanto o declínio subsequente sugere preocupações com questões macroeconômicas, como incertezas políticas ou a volatilidade nas commodities.

A projeção futura otimizada do IBOVESPA sugere uma estabilidade no médio prazo, com uma leve tendência de alta, indicando expectativas de estabilização da economia brasileira. A curva otimizada apresenta variações menores, sugerindo uma moderação nas flutuações do

mercado e uma visão mais realista, possivelmente com expectativas de recuperação econômica gradual e uma redução das incertezas.

No caso das ações de logística, a projeção otimizada mostra uma tendência de queda mais moderada do que a projeção inicial, mas ainda assim decrescente. Isso pode refletir um cenário futuro em que o setor de logística, embora diretamente relacionado ao crescimento econômico, enfrenta desafios específicos, como custos crescentes de operação, dificuldades de infraestrutura e possíveis mudanças regulatórias que dificultam uma recuperação mais acelerada.

A discrepância entre a projeção do IBOVESPA e das ações de logística indica que, enquanto o mercado geral pode apresentar certa estabilização, o setor de logística pode continuar enfrentando desafios específicos. A alta volatilidade observada na projeção inicial das ações de logística é atribuída às incertezas operacionais, como os custos com combustíveis, a necessidade de investimento em infraestrutura e questões regulatórias que afetam diretamente a eficiência e a lucratividade das empresas do setor.

**Incetezas macroeconômicas:** A projeção mais conservadora para o setor de logística reflete uma preocupação com a instabilidade econômica global e doméstica. A inflação, por exemplo, impacta os custos de combustível e de mão de obra, aumentando os custos operacionais das empresas de logística.

**Investimentos em Infraestrutura:** A melhoria da infraestrutura é um fator crítico para a recuperação e crescimento do setor de logística. Investimentos ou a falta deles em infraestrutura de transporte, como rodovias, portos e ferrovias, têm um impacto direto na eficiência das operações logísticas. A projeção otimizada considera uma estabilidade nesses investimentos, mas não necessariamente um aumento significativo.

**Volatilidade Cambial:** Como muitas empresas de logística são dependentes de importação de combustíveis ou equipamentos, as oscilações cambiais afetam diretamente seus custos operacionais. A projeção otimizada reflete a expectativa de uma moderação no câmbio, mas sem expectativas de valorização ou desvalorização drásticas da moeda brasileira.

**Relação com a Economia Geral:** O fato de o IBOVESPA apresentar uma projeção de estabilidade, enquanto o setor de logística mostra uma tendência mais moderada de queda, pode indicar que o mercado vê recuperação em setores específicos (como commodities, serviços e tecnologia), enquanto espera que a logística leve mais tempo para superar seus desafios.

Este gráfico indica que o setor de logística continuará enfrentando desafios no curto e médio prazo, mesmo que a economia brasileira, de forma geral, apresente uma estabilização ou leve recuperação. As previsões otimizadas, utilizando a análise de sentimentos com o modelo

*BERT*, fornecem uma visão mais ajustada, que evita previsões excessivamente otimistas ou pessimistas, resultando em uma visão mais balanceada e realista para o setor e o mercado geral. Isso é essencial para tomada de decisão informada, especialmente em setores sensíveis a fatores macroeconômicos e operacionais como a logística.

A análise dos gráficos de previsão otimizados com o uso do modelo *BERT* revela uma significativa melhora na precisão das projeções de preços das ações. Observando os gráficos comparativos entre os dados históricos e as projeções, nota-se que a linha otimizada está muito mais alinhada com o comportamento real das ações ao longo do tempo.

O uso do *BERT*, que extrai informações de notícias relevantes e outras fontes textuais que influenciam o mercado, permitiu que o modelo considerasse fatores externos que geralmente impactam a volatilidade e as tendências de preço. Isso levou a uma projeção mais precisa e menos sensível a flutuações abruptas sem fundamento, resultando em gráficos cujas linhas otimizadas se aproximam mais da realidade histórica.

A capacidade do *BERT* de entender e quantificar as influências do contexto econômico e dos eventos globais sobre o mercado financeiro se reflete diretamente na maior precisão das previsões. Dessa forma, o modelo otimizado se mostrou mais eficiente em prever o comportamento das ações, capturando com maior exatidão as variações e tendências dos preços. Isso indica um sucesso preditivo significativo na parte gráfica, proporcionando um cenário mais confiável para investidores e analistas que buscam compreender a direção futura dos ativos.

Tabela 9- Resultado dos erros otimizados

Ticker	MAE	MSE	RMSE	MAPE	RMSPE	Direção Correta (%)
HBSA3.SA	0,0713404	0,008051	0,0897273	2,3296313	2,9602829	89,51724138 %
ALPK3.SA	0,1341856	0,0342618	0,1850996	5,1261085	8,6506929	87,17241379 %
PORT3.SA	0,2044708	0,06582	0,2565541	1,7022924	2,1519746	88 %
STBP3.SA	0,2308744	0,0811752	0,2849127	2,5553653	3,2337579	90,62068966 %
JSLG3.SA	0,2675805	0,1113681	0,3337187	3,4353296	4,3908158	91,17241379 %
TGMA3.SA	0,3388566	0,1803834	0,4247157	1,5998665	1,9937158	91,03448276 %
RAIL3.SA	0,3558712	0,1914088	0,4375029	1,8040779	2,2452854	90,34482759 %
LOGN3.SA	1,0806126	1,8209238	1,3494161	3,0614333	3,8746593	91,17241379 %
RAPT4.SA	0,2588649	0,1061837	0,3258583	2,5110059	3,2210557	91,17241379 %
ECOR3.SA	0,1710096	0,0446177	0,211229	2,6206939	3,3003447	90,6206896 6 %
ARML3.SA	0,5928724	0,5102131	0,714292	4,4614711	5,3476813	90,89655172 %
UGPA3.SA	0,2381907	0,0864921	0,2940954	1,3883115	1,7537434	92,27586207 %
CCRO3.SA	0,1981729	0,0568484	0,238429	1,5677804	1,9037902	91,44827586 %
LOGG3.SA	0,7854416	0,9414942	0,9703062	3,7206526	4,6466818	90,75862069 %
AZUL4.SA	0,7943623	0,969636	0,9847009	5,9309412	7,4549279	91,44827586 %

Fonte: Autor (2024)

A análise dos erros de previsão para as ações utilizando o modelo otimizado com *BERT* apresenta resultados significativamente melhores quando comparados ao modelo padrão. Abaixo, detalhamos os principais indicadores de erro para cada ação, como o Erro Médio Absoluto (MAE), o Erro Quadrático Médio (MSE), a Raiz do Erro Quadrático Médio (RMSE), o Erro Percentual Absoluto Médio (MAPE) e o Erro Percentual da Raiz Quadrada (RMSPE), com ênfase no aumento significativo da direção correta das previsões.

Hidrovias do Brasil S.A. (HBSA3.SA): Com um MAE de 0,0713 e um RMSE de 0,0897, o modelo mostra uma boa acurácia na previsão dos preços. O MAPE de 2,33% e a direção correta de 89,5% indicam um nível de precisão muito superior em relação ao padrão, garantindo que as previsões estão alinhadas com a realidade do mercado.

Estarpar Participações S.A. (ALPK3.SA): O MAE de 0,1342 e o MSE de 0,0343 demonstram uma redução considerável nos erros de previsão, enquanto o MAPE de 5,13% revela um nível de precisão que reduz significativamente as imprecisões em comparação ao modelo padrão. A direção correta aumentou para 87,1%.

Wilson Sons Holdings Brasil S.A. (PORT3.SA): Com um MAE de 0,2045 e um RMSE de 0,2566, o modelo apresenta uma precisão melhorada, e o MAPE de 1,70% é especialmente baixo. A direção correta de 88% é um bom indicativo da capacidade do modelo otimizado de capturar a tendência do mercado.

Santos Brasil Participações S.A. (STBP3.SA): O MAE de 0,2309 e um MAPE de 2,56% mostram uma acurácia significativa nas previsões. O percentual de direção correta de 90,6% indica que o modelo é altamente capaz de prever o movimento dos preços de forma consistente.

JSL S.A. (JSLG3.SA): O MAE de 0,2676 e o RMSE de 0,3337 indicam uma boa capacidade preditiva. A direção correta das previsões de 91,1% é um destaque, apontando para a precisão elevada do modelo otimizado.

Tegma Gestão Logística S.A. (TGMA3.SA): Com um MAPE de apenas 1,60% e uma direção correta de 91%, o modelo mostra um desempenho preditivo excelente, destacando-se pela precisão dos movimentos de mercado.

Rumo S.A. (RAIL3.SA): O MAE de 0,3559 e o RMSE de 0,4375 mostram uma precisão substancialmente melhor, com um percentual de direção correta de 90,3%, revelando um excelente desempenho na previsão dos movimentos futuros.

Log-In Logística Intermodal S.A. (LOGN3.SA): Apesar de um MAE mais alto de 1,0806, a direção correta de 91,1% é um forte indicativo de que o modelo otimizado conseguiu captar as tendências principais, reduzindo imprecisões que eram frequentes no modelo padrão.

Randon S.A. Implementos e Participações (RAPT4.SA): Com um MAPE de 2,51% e uma direção correta de 91,1%, o modelo otimizado apresenta uma previsão consistente e precisa, reduzindo significativamente os erros em relação ao padrão.

Ecorodovias Infraestrutura e Logística S.A. (ECOR3.SA): O MAE de 0,1710 e um RMSE de 0,2112 mostram um modelo bem calibrado, e a direção correta de 90,6% reforça a melhoria na precisão preditiva.

Armac Locação, Logística e Serviços S.A. (ARML3.SA): Com um MAE de 0,5929 e uma direção correta de 90,9%, há um claro aumento de acurácia nas previsões, o que é muito relevante em relação à instabilidade do modelo padrão.

Ultrapar Participações S.A. (UGPA3.SA): O modelo alcançou um MAPE de apenas 1,39% e uma direção correta de 92,3%, destacando-se como um dos melhores desempenhos entre todas as ações, indicando uma capacidade de previsão muito elevada.

CCR S.A. (CCRO3.SA): Com um MAE de 0,1982 e um RMSE de 0,2384, o modelo apresenta uma alta precisão, e a direção correta de 91,4% demonstra que o modelo otimizado é significativamente mais eficaz do que o padrão.

Log Commercial Properties e Participações S.A. (LOGG3.SA): O MAE de 0,7854 e o RMSE de 0,9703 são valores relativamente altos, mas a direção correta de 90,8% evidencia que o modelo otimizado capturou as tendências gerais de forma mais precisa.

Azul S.A. (AZUL4.SA): Com um MAE de 0,7944 e um RMSE de 0,9847, o modelo ainda apresenta erros, mas a direção correta de 91,4% é um forte indicativo de melhorias em relação ao padrão, reduzindo a incerteza na previsão.

Os resultados apresentados demonstram que o modelo otimizado com *BERT* gerou uma melhora significativa em todos os indicadores de erro em comparação ao modelo padrão. A direção correta das previsões foi consideravelmente superior, atingindo percentuais acima de 90% para a maioria das ações analisadas. Além disso, os valores de MAE, MSE, RMSE, MAPE e RMSPE foram consistentemente reduzidos, refletindo um maior alinhamento das previsões com o comportamento real do mercado. Isso sugere que o uso de técnicas mais sofisticadas, como o *BERT* para a incorporação de notícias e fatores externos, permite uma modelagem preditiva mais precisa e confiável.

Os resultados obtidos indicam uma visão geral dos sentimentos expressos em artigos financeiros em um determinado período. Um predomínio de artigos classificados como positivos pode indicar otimismo nas perspectivas econômicas, possivelmente refletindo confiança dos agentes econômicos em políticas recentes, projeções de crescimento ou outros indicadores econômicos favoráveis. Por outro lado, uma maior presença de artigos negativos

sugere preocupações persistentes no mercado, que podem estar relacionadas a aspectos como instabilidade econômica, riscos financeiros ou outros fatores que impactam negativamente a percepção dos participantes do mercado.

Já a presença significativa de artigos classificados como neutros pode indicar que muitos dos conteúdos publicados focam em fornecer informações factuais e analíticas sem carregar interpretações emocionais ou julgamentos, desempenhando um papel informativo mais do que persuasivo.

Os resultados desta análise devem ser interpretados com algumas ressalvas. Primeiramente, o modelo utilizado foi treinado em uma ampla gama de dados e pode apresentar viés na classificação de certos tópicos, o que deve ser considerado na análise crítica dos resultados. Além disso, a qualidade e clareza dos artigos analisados também afetam diretamente os resultados obtidos, pois textos ambíguos ou mal escritos podem levar a classificações incorretas.

Finalmente, é importante destacar que o sentimento capturado reflete a perspectiva do autor ou da fonte do artigo em relação ao tópico abordado. A análise do impacto deste sentimento no mercado financeiro requer o cruzamento com outros indicadores econômicos, como variações na bolsa de valores ou mudanças nas taxas de câmbio, a fim de identificar correlações e entender como o sentimento da mídia influencia a percepção dos investidores e o comportamento do mercado.

#### 4.3. INTEGRAÇÃO DOS RESULTADOS EM DASHBOARDS

A integração dos resultados de previsões, otimização e análise fundamentalista foi realizada por meio de *dashboards* interativos desenvolvidos com a biblioteca *Streamlit*. O uso do *Streamlit* em Python permitiu criar uma interface amigável e intuitiva, onde todos os resultados gerados pelas análises foram apresentados de forma consolidada e acessível para os usuários.

Os *dashboards* possibilitaram visualizar as previsões dos preços das ações, incluindo as projeções geradas pelo *Prophet*, bem como os resultados das otimizações de portfólio e os indicadores da análise fundamentalista. A interatividade proporcionada pela interface permitiu que os usuários pudessem navegar pelos diferentes aspectos dos resultados, filtrando por empresas específicas, períodos de análise e outros parâmetros relevantes.

Dessa forma, a aplicação desenvolvida com *Streamlit* não apenas apresentou os dados de maneira clara e visualmente atrativa, mas também permitiu que mesmo usuários sem

conhecimentos técnicos aprofundados tivessem acesso às informações essenciais para tomar decisões embasadas. A capacidade de integrar análises complexas em uma plataforma interativa foi um diferencial para a compreensão dos resultados e para o uso prático das informações financeiras obtidas ao longo do projeto.

Os resultados alcançados com a otimização do modelo de previsão de ações utilizando o *BERT* foram bastante promissores. A aplicação do modelo para captar e interpretar notícias financeiras em tempo real trouxe um impacto significativo na precisão das previsões, corrigindo problemas de elevada margem de erro observados anteriormente. Isso se deve, principalmente, à capacidade do *BERT* de integrar informações qualitativas que influenciam o mercado, como decisões políticas, mudanças regulatórias e eventos econômicos globais, fatores que antes eram ignorados nos modelos baseados apenas em dados históricos.

Os testes demonstraram uma redução considerável no erro médio de previsão, especialmente em períodos de alta volatilidade, nos quais os métodos tradicionais não conseguiam captar as nuances do comportamento do mercado. Incorporar análises qualitativas permitiu ao modelo prever com mais precisão as oscilações de preços ligadas a eventos externos, evidenciando que o uso de dados textuais enriquece a capacidade de resposta às variações bruscas.

Outro ponto positivo foi o aumento da estabilidade nas previsões. Com a inclusão de notícias, o modelo apresentou resultados mais consistentes ao longo do tempo, reduzindo as variações e tornando-se mais confiável. Essa consistência é essencial para estratégias de investimento que buscam minimizar riscos e garantir retornos mais previsíveis. Além disso, a habilidade do modelo em reagir rapidamente a novos eventos mostrou-se um diferencial importante, principalmente em mercados dinâmicos e sujeitos a rápidas mudanças.

Embora os avanços sejam notáveis, ainda há espaço para melhorias. A integração de outros modelos preditivos, como *LSTM* ou algoritmos de aprendizado de máquina complementares, pode aprimorar ainda mais a precisão e a robustez das previsões. Assim, o desenvolvimento contínuo deve focar na combinação de diferentes técnicas, explorando sinergias que ofereçam uma visão mais ampla e precisa do comportamento do mercado financeiro.

## 5. A PLATAFORMA

Com o intuito de aprimorar a coesão textual e enfatizar os resultados obtidos, optou-se por dispor a plataforma em um capítulo exclusivo, promovendo uma abordagem mais estruturada e detalhada das ferramentas visuais empregadas.

Os *dashboards* desempenham um papel crucial na compreensão dos resultados e na facilitação da tomada de decisões no contexto da análise financeira. Como parte fundamental da metodologia desenvolvida, os *dashboards* foram incluídos como ferramentas visuais interativas, permitindo que os dados complexos sejam apresentados de maneira clara e acessível aos diferentes perfis de usuários, como gestores e investidores. Esses *dashboards* não apenas sintetizam as informações provenientes das análises financeiras e de sentimento, mas também contribuem para uma interação ativa com os resultados.

Utilizando ferramentas como *Streamlit* e *Plotly*, a visualização interativa possibilita uma compreensão rápida dos principais indicadores de desempenho das empresas logísticas analisadas. A apresentação de dados em forma de gráficos e tabelas permite explorar diferentes dimensões das informações, como as relações entre variáveis financeiras e as variações de sentimento do mercado.

A plataforma está dividida em 3 códigos principais, `1.py`, `main.py` e `otimizado.py` o primeiro desenvolve a coleta de dados das ações pelo *Yfinance* e notícias utilizando a *News API* em seguida, a análise fundamentalista por fim gera as análises e projeções das empresas (ainda sem tratamento de dados com análise de sentimentos).

O segundo, por sua vez implementa uma aplicação que realiza a análise de sentimentos em notícias financeiras fornecidos pela URL anteriormente coletados pela *News API*. O modelo emprega o modelo pré-treinado *BERT* Multilíngue para classificação de sentimentos nas categorias “Positivo”, “Neutro” e “Negativo” baseando-se em uma escala de 0 a 5 estrelas além de uma probabilidade da notícia influenciar no preço da ação.

Por fim o terceiro une os resultados obtidos no código 1 e código 2 adicionando a influência das notícias no código o que resulta em uma previsão otimizada com as notícias.

Inicialmente precisamos iniciar o *streamlit* invocando-o pelo comando *Streamlit run Nome\_do\_arquivo.py*, neste caso, o primeiro arquivo `1.py`:



Figura 49 - Comando para inicializar a plataforma do código 1.py

```

1 import pandas as pd
2 import yfinance as yf
3 from prophet import Prophet
4 from sklearn.metrics import mean_absolute_error, mean_squared_error
5 import numpy as np
6 import plotly.graph_objects as go
7 import streamlit as st
8 import logging
9 import traceback
10 from newsapi import NewsApiClient
11 from nltk.sentiment.vader import SentimentIntensityAnalyzer
12 import nltk
13 import datetime
14 from transformers import pipeline
15 from urllib.parse import urlparse
16
17 # Configuração do logger
18 logging.basicConfig(level=logging.INFO)
19 logger = logging.getLogger(__name__)

```

Terminal Local +

```

(.venv) Restauracao@MacBook-Air-de-Ricardo pythonProject % streamlit run 1.py

```

Fonte: Autor (2024)

Após a inicialização do código, será solicitada uma chave, que é utilizada para fazer a busca pela *News API*, sem ela o programa não coletará notícias.

Figura 50 - Solicitação da chave da *News API*



Fonte: Autor (2024)

Com estes configurados o programa está pronto para uso e apresentará a seguinte tela inicial

Figura 51- Tela inicial código 1.py



Fonte: Autor (2024)

Nesta etapa, o usuário deve escolher entre uma ação e, ou selecionar todas de uma vez.

Figura 52 - Seleção individual de ações



Fonte: Autor (2024)

Figura 53 - Selecionar todas as ações



Fonte: Autor (2024)

Com as ações selecionadas, o modelo começara as análises de acordo com os botões selecionados, neste caso, para seguir uma lógica intuitiva será feito na ordem que o programa está listado, ou seja, análise fundamentalista projeções e análise de erros e por fim geração de gráficos consolidados e individuais.

Figura 54 - Análise fundamentalista



Fonte: Autor (2024)

Em todas as tabelas geradas, há a opção de baixá-la.

Figura 55 - Baixar análise fundamentalista

The screenshot shows a web application interface for 'LOGISTICO'. At the top, there is a header with the logo and a navigation menu. Below the header, there is a section for API key input and a checkbox for 'Selecionar todas as ações'. A red button labeled 'Análise Fundamentalista' is visible. Below this, a loading message 'Gerando análise fundamentalista...' is shown. The main content is a table with the following data:

Empresa	Ticker	P/L	P/L (Análise)	EV/EBITDA	EV/EBITDA (Análise)
0 Hidrovias do Brasil S.A.	HBSA3.SA	-6.25	Ruim	20.02	Ruim
1 Estapar Participações S.A.	ALPK3.SA	-36.75	Ruim	5.00	Ruim
2 Wilson Sons Holdings Brasil S.A.	PORT3.SA	14.60	Bom	8.27	Bom
3 Santos Brasil Participações S.A.	STBP3.SA	14.57	Bom	9.38	Bom
4 JSL S.A.	JSLG3.SA	5.14	Bom	4.53	Ruim
5 Tegra Gestão Logística S.A.	TGMA3.SA	8.57	Bom	6.22	Bom
6 Rumo S.A.	RAIL3.SA	-51.18	Ruim	7.36	Bom
7 Log-In Logística Intermodal S.A.	LOGN3.SA	-68.83	Ruim	9.94	Bom
8 Randon S.A. Implementos e Participações	RAPT4.SA	9.92	Bom	5.69	Bom
9 Ecorodovias Infraestrutura e Logística S.A.	ECOR3.SA	4.37	Ruim	4.52	Ruim

Below the table, there are buttons for 'Projeções e Análise de Erros' and 'Gerar Gráficos Consolidados e Individuais'. A 'Download as CSV' button is also visible above the table.

Fonte: Autor (2024)

Agora, a com a análise fundamentalista concluída, será selecionada a opção de “Projeções e Análise de Erros”, na qual serão gerados os gráficos com as previsões geradas pelo modelo *Prophet* e os erros de cada previsão.

Figura 56 - Seleção do botão de projeções e análise de erros

The screenshot shows the same web application interface, but with the 'Projeções e Análise de Erros' button highlighted. The table below it shows data for companies 5 through 14:

5 Tegra Gestão Logística S.A.	TGMA3.SA	8.57	Bom	6.22	Bom
6 Rumo S.A.	RAIL3.SA	-51.18	Ruim	7.36	Bom
7 Log-In Logística Intermodal S.A.	LOGN3.SA	-68.83	Ruim	9.94	Bom
8 Randon S.A. Implementos e Participações	RAPT4.SA	9.92	Bom	5.69	Bom
9 Ecorodovias Infraestrutura e Logística S.A.	ECOR3.SA	4.37	Ruim	4.52	Ruim
10 Armac Locação, Logística e Serviços S.A.	ARML3.SA	11.36	Bom	6.44	Bom
11 Ultrapar Participações S.A.	UGPA3.SA	7.60	Bom	5.69	Bom
12 CCR S.A.	CCRO3.SA	14.14	Bom	6.57	Bom
13 Log Commercial Properties e Participações	LOGG3.SA	6.25	Bom	42.06	Ruim
14 Azul S.A.	AZUL4.SA	-0.29	Ruim	21.62	Ruim

Below the table, there are buttons for 'Projeções e Análise de Erros' and 'Gerar Gráficos Consolidados e Individuais'. Below these buttons, there is a section titled 'Indicadores Adicionais nos Gráficos' with the following text:

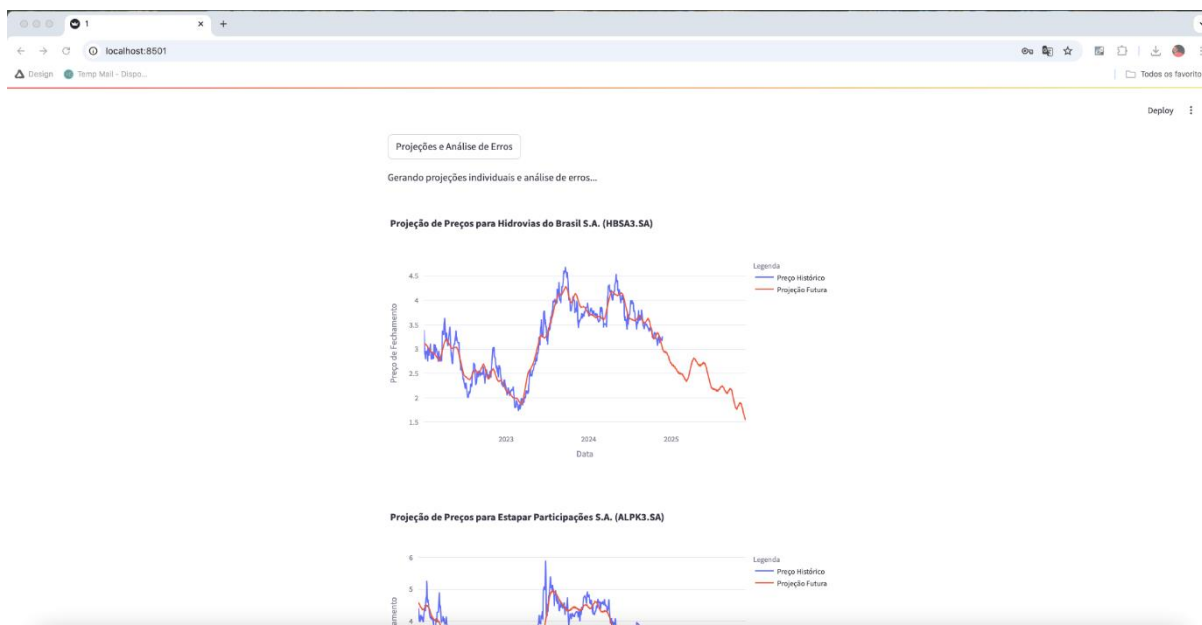
Nos gráficos, comparamos as variações percentuais dos preços médios das ações selecionadas com os seguintes indicadores:

- SP500 (Índice das 500 maiores empresas dos EUA).
- IBOVESPA (Índice da bolsa brasileira).
- IPCA: Simulação acumulada da inflação (4,5% ao ano).
- 100% do CDI: Crescimento histórico baseado em taxas reais do CDI.

Fonte: Autor (2024)

Com essa seleção, todos os *tickers* selecionados anteriormente serão gerados. Para tornar os resultados mais dinâmicos, será apresentado apenas uma ação e não todas elas.

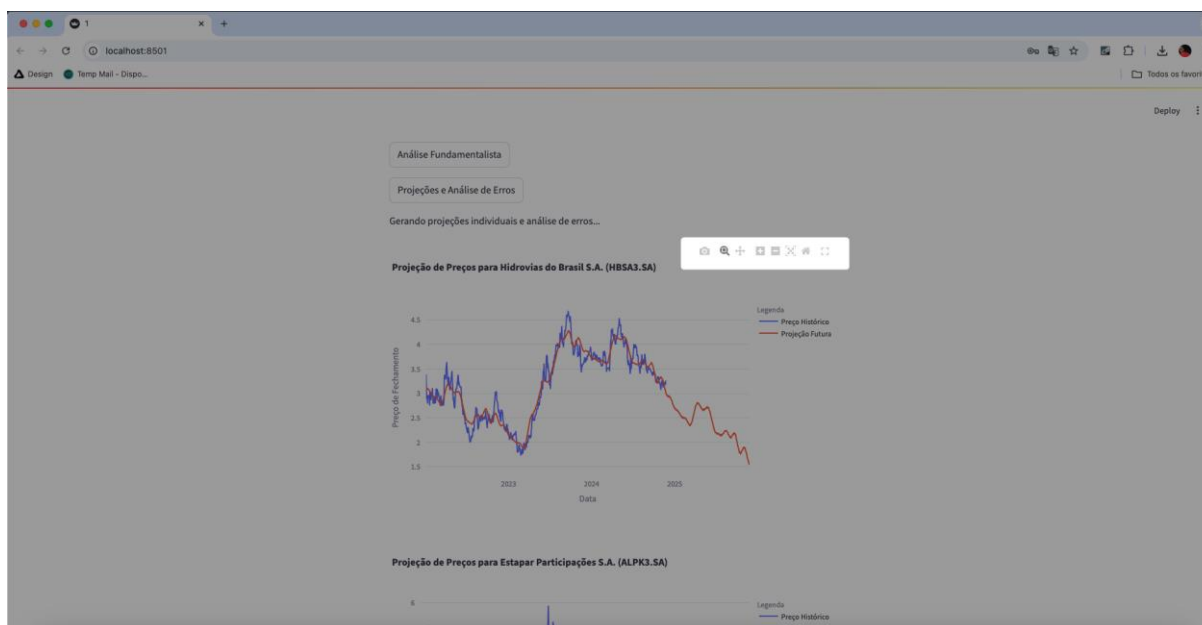
Figura 57 - Exemplo da projeção dos gráficos do código 1.py



Fonte: Autor (2024)

Os gráficos podem ser baixados, representados em tela cheia ou recortados para um momento específico com os botões destacados na figura abaixo.

Figura 58 - Opções de visualização do gráfico



Fonte: Autor (2024)

A visualização em tela cheia permite uma apresentação mais detalhada dos resultados como ilustrado pela imagem a seguir:



Fonte: Autor (2024)

Por fim são gerados os erros para cada uma das ações compiladas em uma tabela

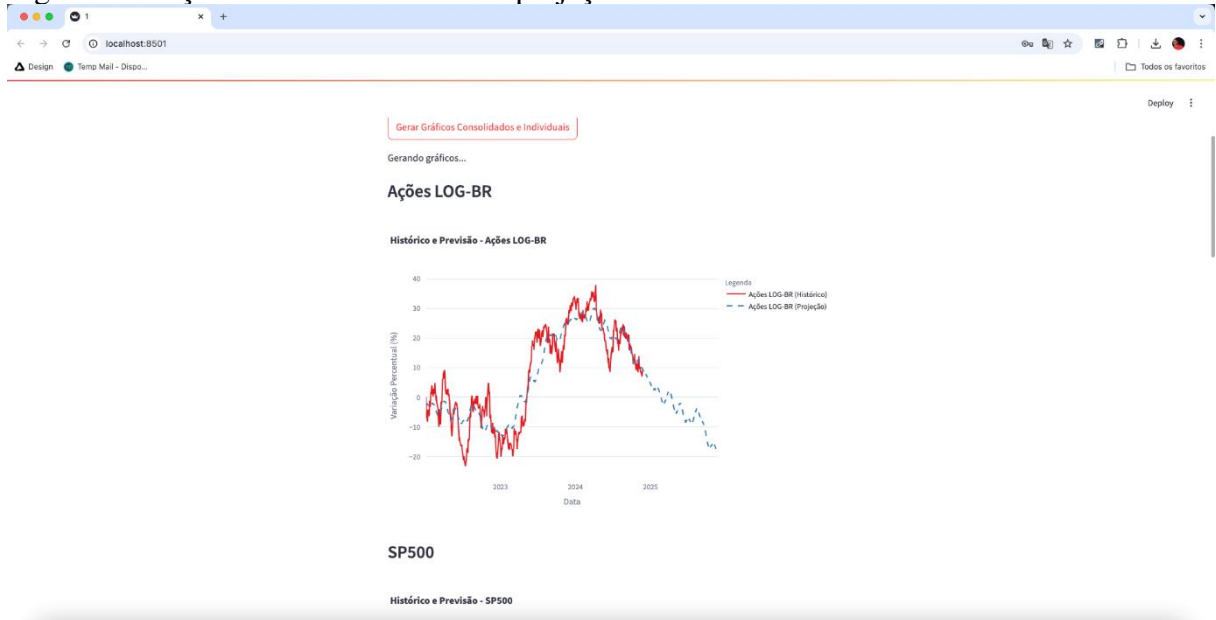
Figura 59- Erros das previsões do código 1.py

Empresa	Ticker	MAE	MSE	RMSE	MAPE	RMSPE	Direção Correta (%)
0 Hidrovias do Brasil S.A.	HBSA3.SA	0.1427	0.0322	0.1795	4.6593	5.9206	50.4828
1 Estapar Participações S.A.	ALPK3.SA	0.2684	0.137	0.3702	10.2522	17.3014	52.1379
2 Wilson Sons Holdings Brasil S.A.	PORT3.SA	0.4089	0.2633	0.5131	3.4046	4.3039	50.7586
3 Santos Brasil Participações S.A.	STBP3.SA	0.4617	0.3247	0.5698	5.1107	6.4675	55.3103
4 JSL S.A.	JSLG3.SA	0.5352	0.4455	0.6674	6.8707	8.7816	54.3448
5 Tegma Gestão Logística S.A.	TGMA3.SA	0.6777	0.7215	0.8494	3.1997	3.9874	57.5172
6 Rumo S.A.	RAIL3.SA	0.7117	0.7656	0.875	3.6082	4.4906	54.2069
7 Log-In Logística Intermodal S.A.	LOGN3.SA	2.1612	7.2837	2.6988	6.1229	7.7493	54.069
8 Randon S.A. Implementos e Participações	RAPT4.SA	0.5177	0.4247	0.6517	5.022	6.4421	56.1379
9 Ecorodovias Infraestrutura e Logística S.A.	ECDR3.SA	0.342	0.1785	0.4225	5.2414	6.6007	54.6207
10 Armac Locação, Logística e Serviços S.A.	ARML3.SA	1.1857	2.0409	1.4286	8.9229	10.6954	54.2069
11 Ultrapar Participações S.A.	UGPA3.SA	0.4764	0.346	0.5882	2.7766	3.5075	57.3793
12 CCR S.A.	CCRO3.SA	0.3963	0.2274	0.4769	3.1356	3.8076	54.069
13 Log Commercial Properties e Participações	LOGG3.SA	1.5709	3.766	1.9406	7.4413	9.2934	55.7241
14 Azul S.A.	AZUL4.SA	1.5887	3.8785	1.9694	11.8619	14.9099	52.5517

Fonte: Autor (2024)

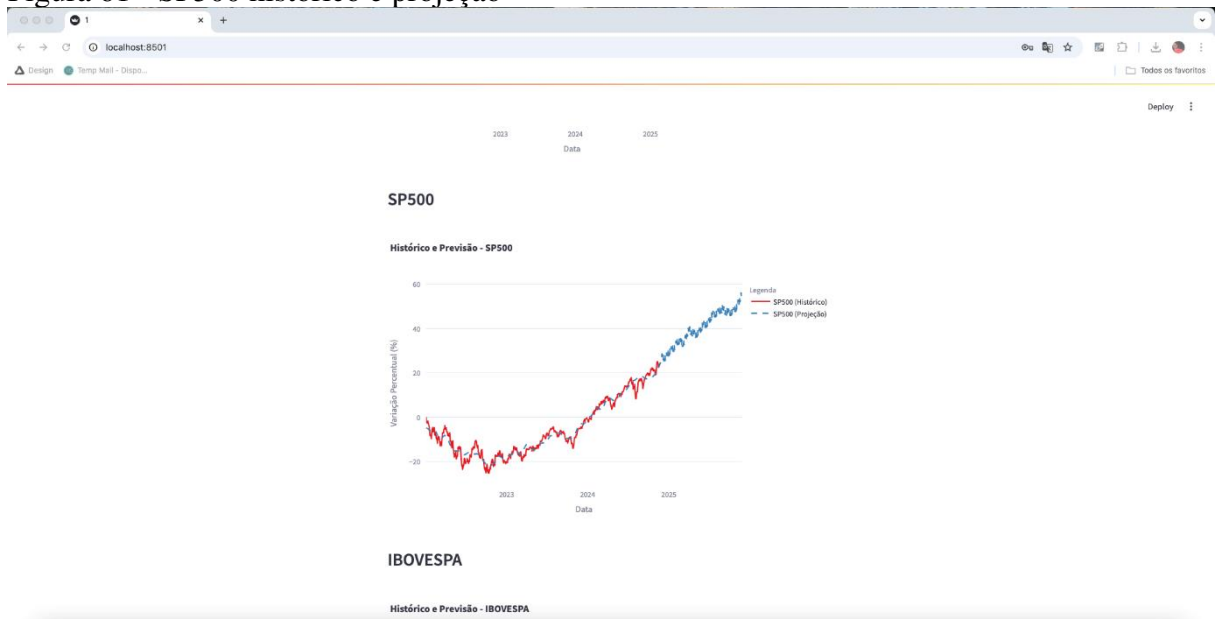
Depois dos resultados iniciais, o código desenvolverá algumas previsões com CDI, IBOVESPA, SP500, IPCA, para comparar os resultados com o das ações, que, por sua vez será apresentado como a média das ações analisadas chamada “Ações LOG-BR”.

Figura 60 - Ações LOG-BR histórico e projeção



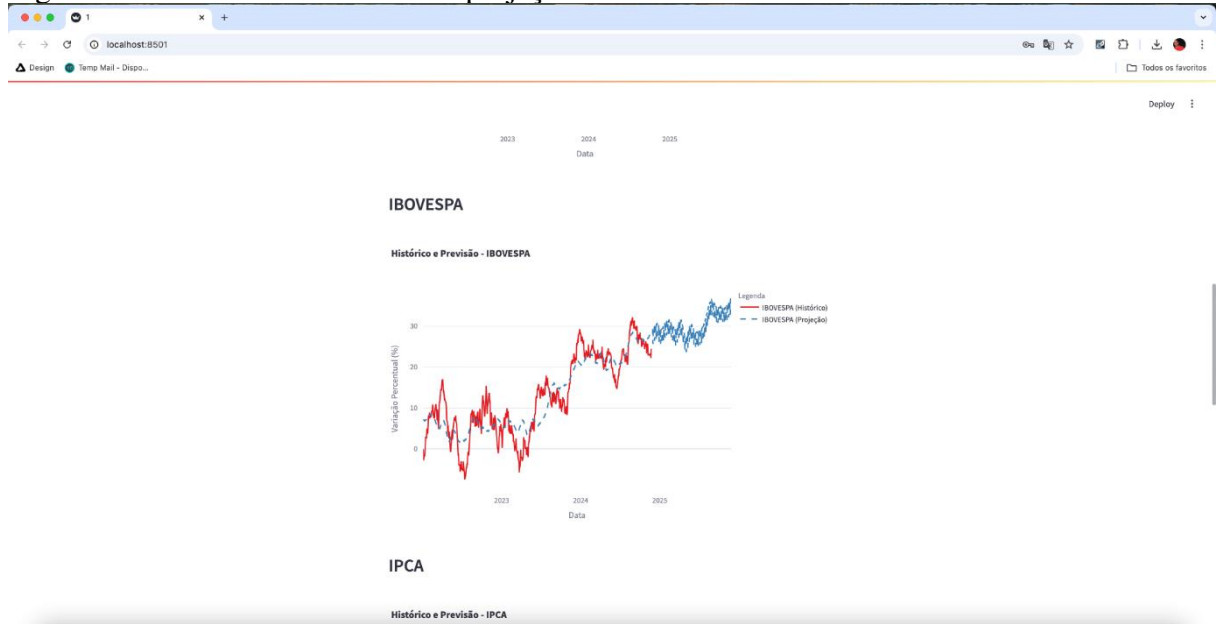
Fonte: Autor (2024)

Figura 61 - SP500 histórico e projeção



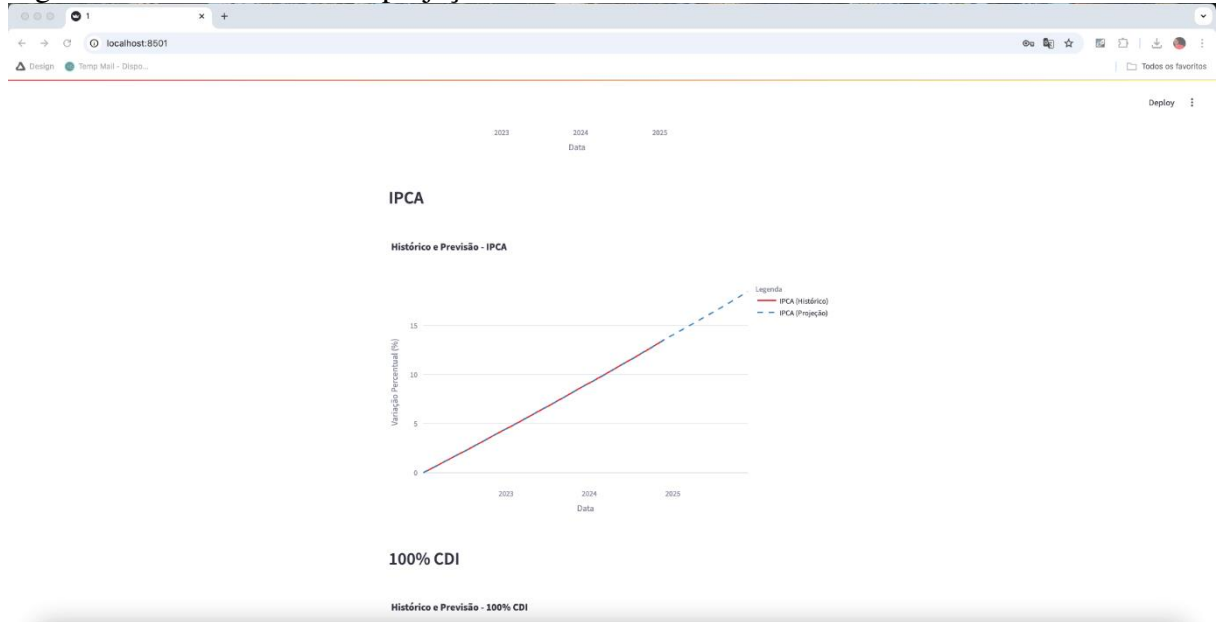
Fonte: Autor (2024)

Figura 62 - IBOVESPA histórico e projeção



Fonte: Autor (2024)

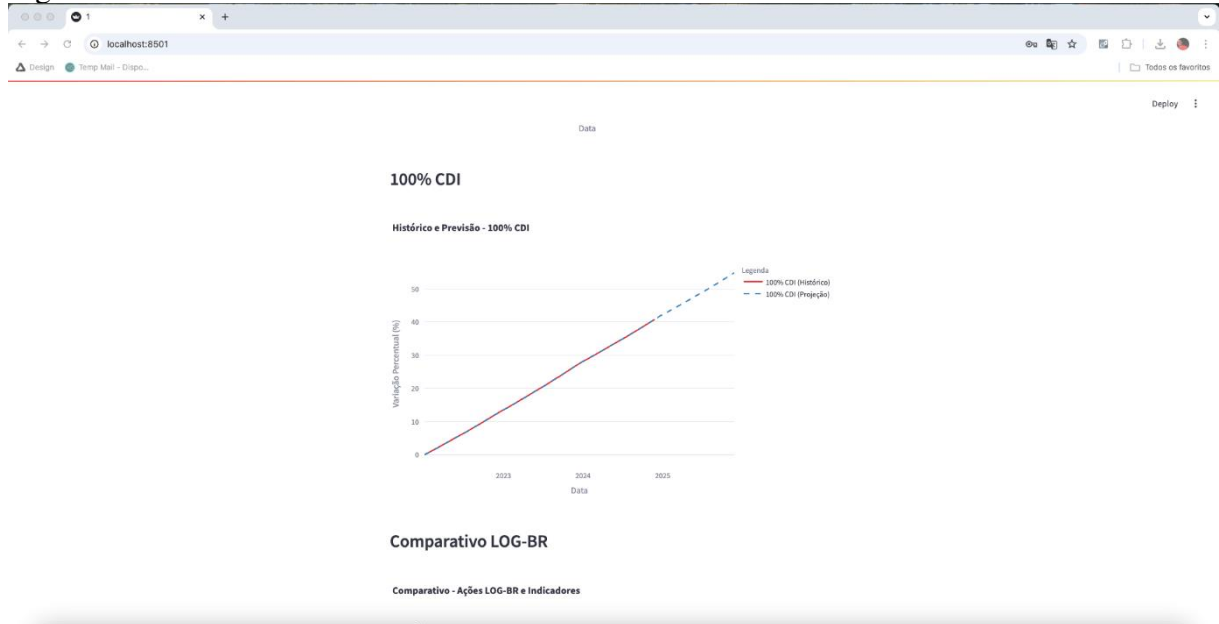
Figura 63 - IPCA histórico e projeção



Fonte: Autor (2024)



Figura 64- 100% CDI



Fonte: Autor (2024)

Figura 65 - Projeções consolidadas código 1.py



Fonte: Autor (2024)

Para aprimorar a visualização, especialmente em gráficos com mais indicadores, é possível selecionar quais ações serão dispostas no gráfico pela legenda lateral. Ao clicar em qualquer um dos nomes a linha será removida, para retornar a forma inicial basta apenas selecionar novamente.

Figura 66 - Exemplo de seleção de uma curva isolada no gráfico



Fonte: Autor (2024)

A próxima figura ilustra como inicializar o código main.

Figura 67 - Inicialização do código main.py

```

1 # Importar biblioteca do streamlit
2 import streamlit as st
3
4 from transformers import AutoTokenizer, AutoModelForSequenceClassification
5 import torch
6 import numpy as np
7 import pandas as pd
8 from newspaper import Article
9 import valentine
10
11
12 st.set_page_config(
13     page_title="Análise de Sentimentos de Notícias Financeiras",
14     layout="wide"
15 )
16
17 # -----
18 # Preparar Modelo e Tokenizer
19 # -----
20
21 #usage
22 @st.cache_resource
23 def carregar_modelo():
24     # caminho = modelo "https://huggingface.co/microsoft/bert-base-multilingual-uncased-sentiment"
25     modelo_nome = "microsoft/bert-base-multilingual-uncased-sentiment"
26     tokenizer = AutoTokenizer.from_pretrained(modelo_nome)
27     modelo = AutoModelForSequenceClassification.from_pretrained(modelo_nome)
28     return tokenizer, modelo
  
```

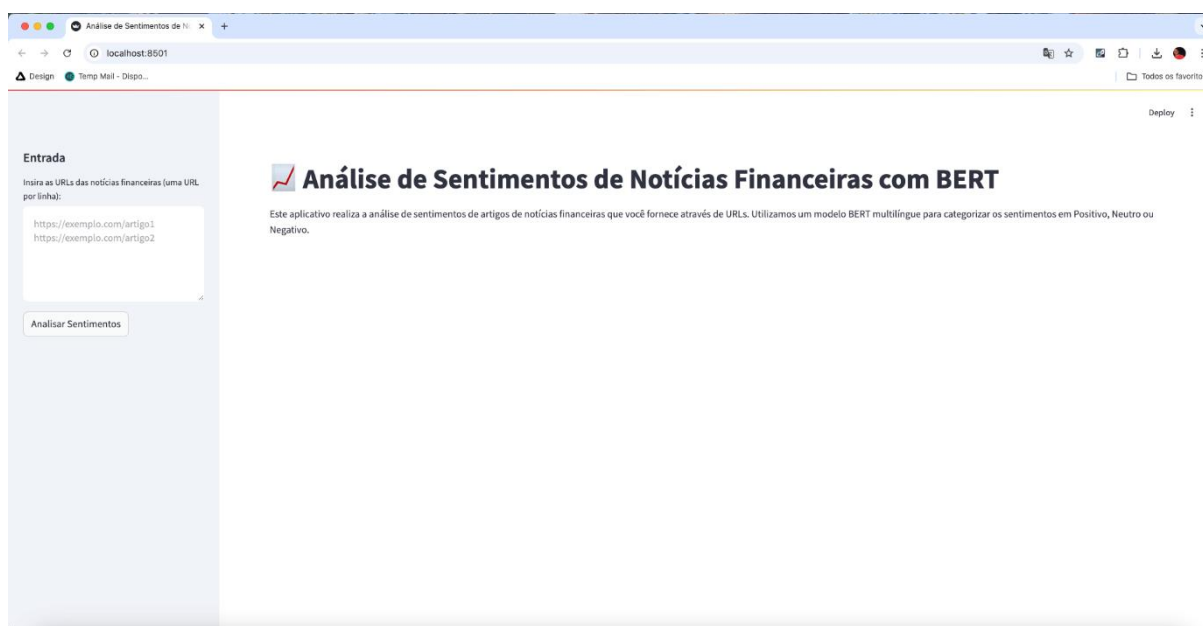
Terminal Local x +

```

(.venv) Restauracao@MacBook-Air-de-Ricardo pythonProject % streamlit run main.py
  
```

Fonte: Autor (2024)

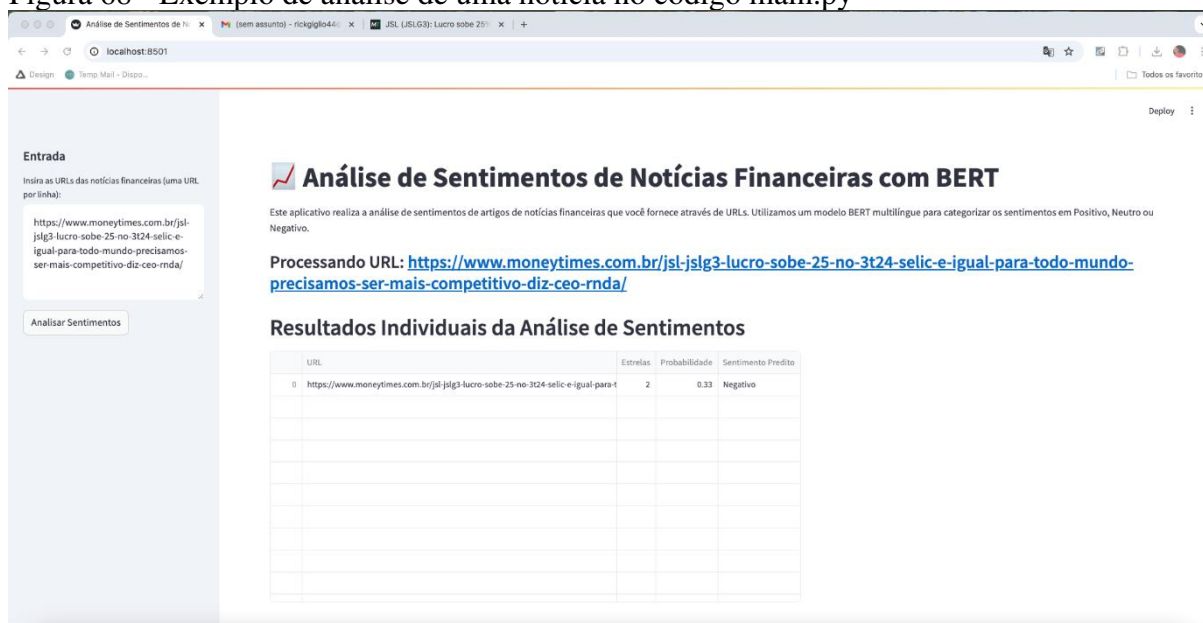
Após a inicialização do código com o comando `streamlit run main.py`, a tela inicial será apresentada.



Fonte: Autor (2024)

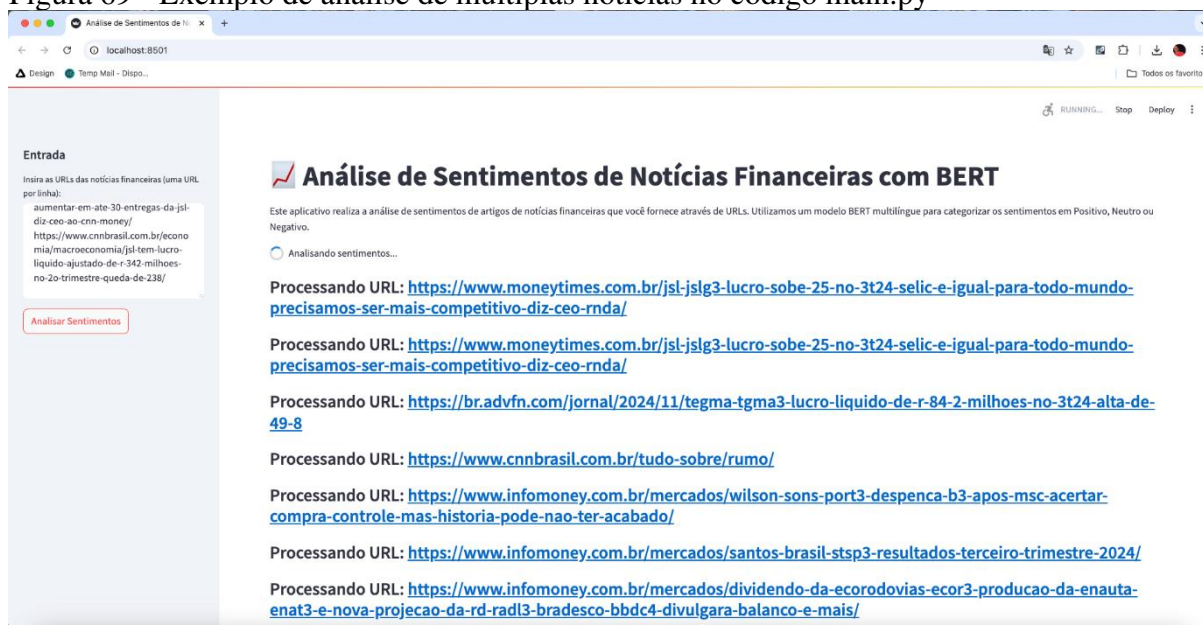
Na parte lateral esquerda do programa, existe o local no qual devem ser inseridos os URL's das notícias a serem analisadas. Pode-se adicionar apenas uma ou várias notícias por vez, sempre respeitando o limite de 1 notícia por linha.

Figura 68 - Exemplo de análise de uma notícia no código `main.py`



Fonte: Autor (2024)

Figura 69 - Exemplo de análise de múltiplas notícias no código main.py



Fonte: Autor (2024)

Ao apertar o botão “Analisar Sentimentos” as notícias serão analisadas pelo modelo *BERT* e o resultado da análise será apresentado por meio de uma tabela, a qual pode ser baixada em modelo .CSV (que servirá como base de dados para o último código).

Figura 70 - Resultados análise de notícias com *BERT*

Download as CSV

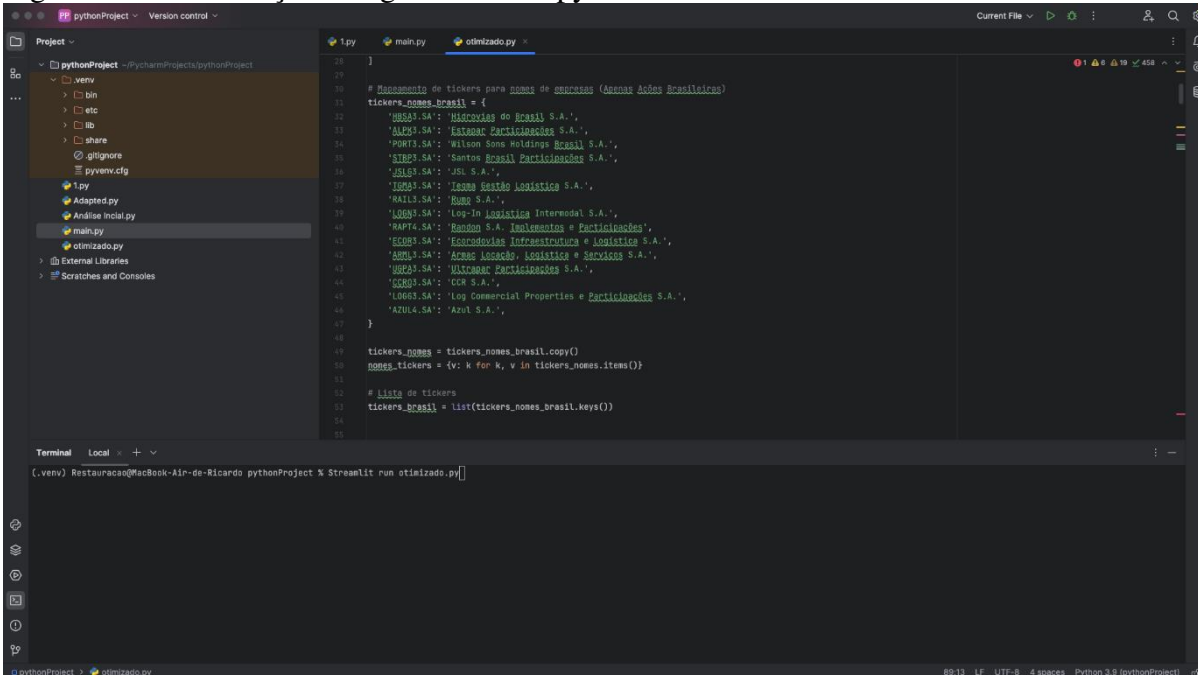
### Resultados Individuais da Análise de Sentimentos

	URL	Estrelas	Probabilidade	Sentimento Predit
9	https://www.infomoney.com.br/mercados/dividendo-da-ecorodovias-ecor3-producao-da-enautat3-e-nova-projecao-da-rd-radl3-bradesco-bbdc4-divulgara-balanco-e-mais/	1	0.50	Negativo
10	https://www.moneytimes.com.br/ccr-ccro3-conclui-compra-de-acoes-de-concession	1	0.52	Negativo
11	https://www.moneytimes.com.br/hidroviadas-do-brasil-fara-aumento-de-capital-de-at	1	0.46	Negativo
12	https://www.infomoney.com.br/mercados/log-cp-logg3-vende-fatia-em-ativo-em-sa	1	0.50	Negativo
13	https://gauchazh.clicrbs.com.br/pioneiro/colunistas/juliana-bevilaqua/noticia/2024/	5	0.54	Positivo
14	https://www.infomoney.com.br/consumo/azul-tem-passagens-aereas-a-partir-de-r-2	1	0.23	Negativo
15	https://www.moneytimes.com.br/jsl-jslg3-anuncia-programa-de-recompra-de-acoes	1	0.41	Negativo
16	https://br.advfn.com/jornal/2024/11/tegma-aprova-pagamento-de-proventos-no-va	1	0.69	Negativo
17	https://investidor.estadao.com.br/ultimas/rumo-rail3-lucro-balanco-3-trimestre-20	1	0.38	Negativo
18	https://www.cnnbrasil.com.br/economia/negocios/msc-faz-acordo-para-compra-do	1	0.60	Negativo
19	https://www.infomoney.com.br/mercados/santos-brasil-stbp3-aprova-pagamento-d	1	0.67	Negativo

Fonte: Autor (2024)

Por fim, o último código, o “otimizado.py” pode ser inicializado pela mesma invocação da plataforma, apenas alterando o nome do arquivo para o nome do código.

Figura 71 - Inicialização código otimizado.py



```

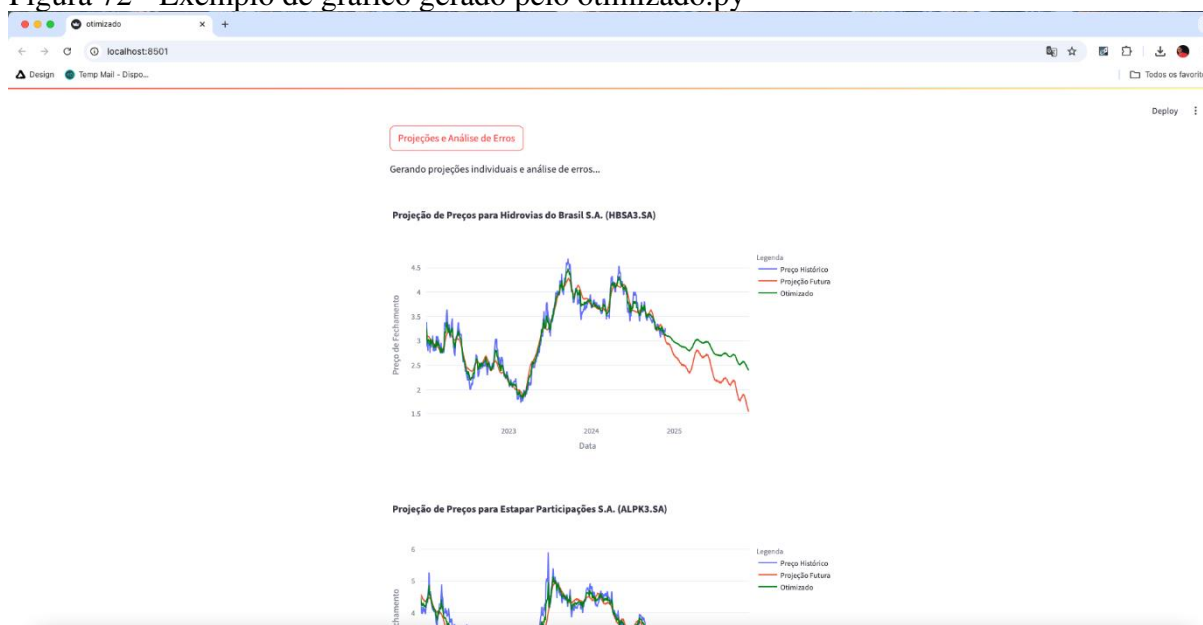
26 }
27
28 # Montagem de tickers para nomes de empresas (Anonimizados Brasileiros)
29 tickers_nomes_brasil = {
30     'HBSA3.SA': 'Hidrovias do Brasil S.A.',
31     'ALPK3.SA': 'Alpk3 Participações S.A.',
32     'PREF3.SA': 'Wilson Sons Holdings Brasil S.A.',
33     'TRES3.SA': 'Santos Brasil Participações S.A.',
34     'JSL3.SA': 'JSL S.A.',
35     'LOGS3.SA': 'Logis Gestão Logística S.A.',
36     'RAIL3.SA': 'Rumo S.A.',
37     'LOGF3.SA': 'Log-In Logística Intermodal S.A.',
38     'RAFI4.SA': 'Rafael S.A. Investimentos e Participações',
39     'ECOP3.SA': 'Ecomodulos Infraestrutura e Logística S.A.',
40     'RIMA3.SA': 'Armas Logística e Serviços S.A.',
41     'HBP3.SA': 'Hidreac Participações S.A.',
42     'CCO3.SA': 'CCR S.A.',
43     'LOGC3.SA': 'Log Commercial Properties e Participações S.A.',
44     'AZUL4.SA': 'Azul S.A.',
45 }
46
47
48 tickers_nomes = tickers_nomes_brasil.copy()
49 nomes_tickers = {v: k for k, v in tickers_nomes.items()}
50
51 # Lista de tickers
52 tickers_brasil = list(tickers_nomes_brasil.keys())
53
54
55

```

Fonte: Autor (2024)

Em seguida, uma tela inicial, similar ao código 1 será gerado, a qual não será disposta nesta etapa para simplificar o entendimento. Depois da Seleção das ações desejadas, serão geradas as previsões otimizadas pelas notícias pontuadas pelo código main.py.

Figura 72 - Exemplo de gráfico gerado pelo otimizado.py



Fonte: Autor (2024)

Em seguida, ao selecionar a geração de gráficos consolidados (similar ao modelo 1.py), o programa apresentará uma comparação entre a média das ações previstas pelo modelo inicial e as ações otimizadas, além do IBOVESPA para comparação do desempenho.

Figura 73 - Resultados consolidados projeção otimizada



Fonte: Autor (2024)

Esses foram os resultados apresentados pela plataforma. Em síntese, a plataforma foi estruturada em três códigos principais: 1.py, que coleta dados financeiros e notícias para análises fundamentalistas; main.py, que aplica análise de sentimentos em notícias usando o modelo *BERT* Multilíngue; e otimizado.py, que integra os resultados dos dois primeiros códigos para prever de forma otimizada o impacto das notícias nos preços das ações, utilizando ferramentas como *Streamlit* e *Plotly* para visualização interativa e suporte à tomada de decisões.

## 6. CONTRIBUIÇÕES DO ESTUDO

Este estudo apresentou uma contribuição relevante tanto para o meio acadêmico quanto para o setor logístico-financeiro ao desenvolver uma plataforma integrada para análise financeira e de sentimento.

A integração de técnicas de aprendizado de máquina, como o modelo *Prophet* para previsão de séries temporais, com análise de sentimento usando modelos de processamento de linguagem natural, proporcionou uma visão abrangente e contextualizada sobre o comportamento das ações de empresas do setor logístico.

O uso de *dashboards* interativos, por meio de ferramentas como *Plotly* e *Streamlit*, permitiu a visualização clara e intuitiva dos dados, facilitando a interpretação e contribuindo para decisões mais fundamentadas.

Do ponto de vista prático, a plataforma desenvolvida contribuiu para uma análise financeira mais informada e precisa, considerando tanto os aspectos financeiros quanto as variações no sentimento do mercado.

Isso possibilita a identificação de padrões e relações importantes que impactam o valor das ações, resultando em melhores estratégias de investimento e gestão de riscos. A pesquisa também destacou a relevância de utilizar tecnologias de ponta para promover a sustentabilidade econômica e a competitividade das empresas logísticas.

### 6.1 LIMITAÇÕES DA PESQUISA

Embora este estudo tenha alcançado resultados significativos, ele apresenta algumas limitações que devem ser consideradas. Em primeiro lugar, a previsão de preços utilizando o modelo *Prophet* está sujeita à limitação inerente à dependência de sazonalidades bem definidas.

Em contextos em que os dados apresentam variabilidade extrema ou falta de padrões claros, a precisão das previsões pode ser comprometida. Além disso, a análise de sentimento realizada depende da qualidade e da variedade das fontes de dados coletadas. Limitações no acesso a notícias, assim como dificuldades em filtrar conteúdos irrelevantes ou enviesados, podem afetar a análise.

Outro ponto a ser destacado é a limitação na abrangência das empresas analisadas. Devido à dificuldade em padronizar indicadores financeiros e considerar diferenças entre mercados, muitas empresas foram excluídas do estudo. Esse fato reduz a aplicabilidade direta dos resultados para outros contextos e limita a expansão do modelo preditivo para outros setores sem novas adaptações.

## 6.2. SUGESTÕES PARA TRABALHOS FUTUROS

Trabalhos futuros poderiam explorar a melhoria dos modelos preditivos utilizados, combinando o *Prophet* com outros algoritmos de aprendizado de máquina, como redes neurais e árvores de decisão, para lidar melhor com a variabilidade e as relações não lineares presentes nos dados do setor logístico.

Outra sugestão é expandir o escopo da pesquisa para incluir outros setores da economia, além de considerar empresas de diferentes países, com o objetivo de avaliar as particularidades e especificidades regionais.

Adicionalmente, seria interessante explorar técnicas mais avançadas de processamento de linguagem natural para análise de sentimento, incorporando modelos mais recentes e sofisticados que possam capturar nuances mais complexas do humor do mercado.

A ampliação da base de dados utilizada, incluindo uma maior quantidade de fontes de notícias e diferentes tipos de informações textuais, também pode contribuir para tornar as análises mais robustas e completas, favorecendo a expansão para a previsão de outros indicadores financeiros relevantes, como volume de negócios e liquidez das empresas.

Este trabalho desenvolveu uma plataforma integrada para análise financeira e de sentimento no setor logístico, utilizando aprendizado de máquina e visualização interativa para apoiar a tomada de decisões de investimento e gestão de riscos. A plataforma combina técnicas de previsão de séries temporais, como o modelo *Prophet*, com análise de sentimento baseada em processamento de linguagem natural, oferecendo uma visão abrangente e contextualizada sobre o comportamento das ações de empresas do setor.

Os resultados obtidos mostram que a integração de diferentes técnicas de análise, como previsão financeira e análise de sentimento, contribui significativamente para melhorar a precisão das previsões e apoiar decisões mais fundamentadas. A visualização de dados por meio de *dashboards* interativos permitiu uma interpretação clara dos resultados, tornando as análises acessíveis tanto para investidores quanto para gestores do setor logístico.

A contribuição deste estudo é significativa não só no contexto acadêmico, mas também para o mercado profissional. A plataforma oferece uma ferramenta inovadora que auxilia na compreensão das relações entre fatores financeiros e de sentimento, permitindo uma análise mais completa e informada do comportamento das ações. Este trabalho também destaca a importância do uso de tecnologias de ponta, como aprendizado de máquina e visualização de



dados, para promover a competitividade e a sustentabilidade econômica das empresas logísticas.

Apesar das contribuições significativas, o estudo apresenta algumas limitações que devem ser consideradas. A previsão de preços utilizando o modelo *Prophet* depende de sazonalidades bem definidas, o que pode comprometer a precisão em contextos de alta variabilidade. A análise de sentimento, por sua vez, é influenciada pela qualidade e pela diversidade das fontes de dados coletadas.

Além disso, a abrangência das empresas analisadas foi limitada devido à dificuldade em padronizar indicadores financeiros entre diferentes mercados, o que reduz a aplicabilidade dos resultados para outros contextos sem adaptações adicionais.

Para trabalhos futuros, recomenda-se a exploração de modelos preditivos mais sofisticados, como redes neurais e árvores de decisão, que possam lidar melhor com a variabilidade e as relações não lineares dos dados do setor logístico. Além disso, a expansão do escopo para incluir outros setores e empresas de diferentes países permitiria uma avaliação mais ampla das especificidades regionais e setoriais.

Também seria interessante incorporar técnicas mais avançadas de processamento de linguagem natural para melhorar a precisão da análise de sentimento, bem como aumentar a diversidade das fontes de dados utilizadas, visando uma análise mais robusta e abrangente.

Em conclusão, este trabalho representa um avanço na utilização de tecnologias inovadoras para análise integrada no setor logístico, contribuindo para uma tomada de decisão mais fundamentada e alinhada com as demandas do mercado. A combinação de previsão financeira, análise de sentimento e visualização de dados oferece uma ferramenta poderosa para investidores e gestores, promovendo a competitividade e a sustentabilidade das empresas do setor.

## 7.CONCLUSÕES

Este trabalho desenvolveu uma plataforma integrada para análise financeira e de sentimento no setor logístico, utilizando aprendizado de máquina e visualização interativa para apoiar a tomada de decisões de investimento e gestão de riscos. A plataforma combina técnicas de previsão de séries temporais, como o modelo *Prophet*, com análise de sentimento baseada em processamento de linguagem natural, oferecendo uma visão abrangente e contextualizada sobre o comportamento das ações de empresas do setor.

Os resultados obtidos mostram que a integração de diferentes técnicas de análise, como previsão financeira e análise de sentimento, contribui significativamente para melhorar a precisão das previsões e apoiar decisões mais fundamentadas. A visualização de dados por meio de *dashboards* interativos permitiu uma interpretação clara dos resultados, tornando as análises acessíveis tanto para investidores quanto para gestores do setor logístico.

A contribuição deste estudo é significativa não só no contexto acadêmico, mas também para o mercado profissional. A plataforma oferece uma ferramenta inovadora que auxilia na compreensão das relações entre fatores financeiros e de sentimento, permitindo uma análise mais completa e informada do comportamento das ações. Este trabalho também destaca a importância do uso de tecnologias de ponta, como aprendizado de máquina e visualização de dados, para promover a competitividade e a sustentabilidade econômica das empresas logísticas.

Apesar das contribuições significativas, o estudo apresenta algumas limitações que devem ser consideradas. A previsão de preços utilizando o modelo *Prophet* depende de sazonalidades bem definidas, o que pode comprometer a precisão em contextos de alta variabilidade. A análise de sentimento, por sua vez, é influenciada pela qualidade e pela diversidade das fontes de dados coletadas. Além disso, a abrangência das empresas analisadas foi limitada devido à dificuldade em padronizar indicadores financeiros entre diferentes mercados, o que reduz a aplicabilidade dos resultados para outros contextos sem adaptações adicionais.

Para trabalhos futuros, recomenda-se a exploração de modelos preditivos mais sofisticados, como redes neurais e árvores de decisão, que possam lidar melhor com a variabilidade e as relações não lineares dos dados do setor logístico. Além disso, a expansão do escopo para incluir outros setores e empresas de diferentes países permitiria uma avaliação mais ampla das especificidades regionais e setoriais. Também seria interessante incorporar técnicas mais avançadas de processamento de linguagem natural para melhorar a precisão da análise de

sentimento, bem como aumentar a diversidade das fontes de dados utilizadas, visando uma análise mais robusta e abrangente.

Em conclusão, este trabalho representa um avanço na utilização de tecnologias inovadoras para análise integrada no setor logístico, contribuindo para uma tomada de decisão mais fundamentada e alinhada com as demandas do mercado. A combinação de previsão financeira, análise de sentimento e visualização de dados oferece uma ferramenta poderosa para investidores e gestores, promovendo a competitividade e a sustentabilidade das empresas do setor.

## REFERÊNCIAS

- BEZERRA, R. N.** Análise de Dados de Desempenho de Painéis Fotovoltaicos Residenciais. Monografia – Universidade Federal do Rio Grande do Norte, Natal, RN, 2023. Disponível em: <https://repositorio.ufrn.br/handle/123456789/52245>. Acesso em: 1 dez. 2024.
- BORGES, M. P.** Análise e Previsão de Séries Temporais via Facebook *Prophet*. 2024. Trabalho de Conclusão de Curso – Universidade Federal de São Carlos, São Carlos, 2024. Disponível em: <https://repositorio.ufscar.br/handle/ufscar/19516?show=full>. Acesso em: 1 dez. 2024.
- BRAGA, R. V.** Redes Neurais *LSTM* e Google Trends aplicados para previsão de Séries Temporais do Mercado Financeiro no contexto de Criptomoedas. 2023. Trabalho de Conclusão de Curso – Universidade Federal de Ouro Preto, João Monlevade, 2023. Disponível em: <https://monografias.ufop.br/handle/35400000/6146>. Acesso em: 1 dez. 2024.
- CONFEDERAÇÃO NACIONAL DO TRANSPORTE (CNT).** Custo logístico consome 12% do PIB do Brasil. Disponível em: <https://www.cnt.org.br/agencia-cnt/custo-logistico-consome-12-do-pib-do-brasil>. Acesso em: 6 dez. 2024.
- CARVALHO, J. E. S.** Desenvolvimento de uma ferramenta para automatização e monitorização de indicadores de desempenho em processos de controlo da produção. Dissertação de Mestrado – Universidade de Coimbra, 2020. Disponível em: <https://estudogeral.uc.pt/handle/10316/92550>. Acesso em: 1 dez. 2024.
- CORRÊA, A. de A.** Pré-Processamento de Dados para Análise de Séries Temporais na Previsão de Valores de Criptomoedas, Utilizando ARIMA e *PROPHET*. 2024. Trabalho de Conclusão de Curso – Universidade Franciscana, Santa Maria, 2024. Disponível em: [https://www.tfgonline.lapinf.ufn.edu.br/media/midias/Adriano\\_Correa.pdf](https://www.tfgonline.lapinf.ufn.edu.br/media/midias/Adriano_Correa.pdf). Acesso em: 1 dez. 2024.
- CUNHA, W. L. M.** A Comprehensive Exploitation of Instance Selection Methods for Automatic Text Classification. 2024. Tese (Doutorado) – Universidade Federal de Minas Gerais, Belo Horizonte, 2024. Disponível em: <https://repositorio.ufmg.br/handle/1843/76441>. Acesso em: 1 dez. 2024.
- DAMODARAN, A.** Avaliação de Investimentos: Ferramentas e Técnicas para Determinar o Valor de Qualquer Ativo. 2. ed. São Paulo: Pearson, 2007.
- DAMODARAN, Aswath.** Avaliação de investimentos: ferramentas e técnicas para a determinação do valor de qualquer ativo. Tradução de Bazán Tecnologia e Linguística (Carlos Henrique Trieschmann e Ronaldo de Almeida Rego). Rio de Janeiro: Qualitymark, 1997.
- ETEMADIFAR, Shayan; AFSHAR, Mohamad; AMRA, Mohsen.** Modelling a Logistics and Financial Supply Chain Network during the COVID-19 Era. *Logistics*, [s.l.], v. 8, n. 1, p. 32, mar. 2024. Disponível em: <https://doi.org/10.3390/logistics8010032>. Acesso em: 1 dez. 2024.

**JIYA, Tilimbe.** Ethical Implications of Predictive Risk Intelligence. Core, 2019. Disponível em: <https://core.ac.uk/download/228181605.pdf>. Acesso em: 14 nov. 2024.

**KAHNEMAN, Daniel; TVERSKY, Amos.** Choices, Values, and Frames. SSRN, 1979. Disponível em: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=1105499](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1105499). Acesso em: 1 dez. 2024.

**KUHN, Max; JOHNSON, Kjell.** Applied Predictive Modeling. 5th ed. New York: Springer, 2013. ISBN 978-1-4614-6848-6. DOI: 10.1007/978-1-4614-6849-3. Disponível em: [https://www.ic.unicamp.br/~wainer/cursos/1s2021/432/2013\\_Book\\_AppliedPredictiveModeling.pdf](https://www.ic.unicamp.br/~wainer/cursos/1s2021/432/2013_Book_AppliedPredictiveModeling.pdf). Acesso em: 2 dez. 2024.

**MAALLA, Allam; WU, Guang-Yu; LI, Shaojie.** Research on Application and Development of Financial Big Data. DEStech Transactions on Social Science, Education and Human Science, 2019. Disponível em: <https://www.semanticscholar.org/paper/5caa35987b5df145a5bdc8dd4766dbeff952ebe2>. Acesso em: 14 nov. 2024.

**MENDES, T. P.** Modelo de Inteligência Artificial para Previsão do Índice S&P500. 2023. Trabalho de Conclusão de Curso – Universidade Federal do Pampa, Bagé, 2023. Disponível em: [https://dspace.unipampa.edu.br/bitstream/riu/8127/1/Trabalho\\_de\\_Conclusao\\_de\\_Curso\\_Tiago\\_Mendes.pdf](https://dspace.unipampa.edu.br/bitstream/riu/8127/1/Trabalho_de_Conclusao_de_Curso_Tiago_Mendes.pdf). Acesso em: 1 dez. 2024.

**NASCIMENTO, H. A. do; FERREIRA, C. B. R.** Visualização de Informações - Uma Abordagem Prática. In: XXV Congresso da Sociedade Brasileira de Computação. Rio Grande do Sul: UNISINOS, 2005. Disponível em: [https://www.researchgate.net/profile/Hugo-Nascimento-7/publication/267403645\\_Visualizacao\\_de\\_Informacoes\\_-\\_Uma\\_Abordagem\\_Pratica/links/5510a6940cf2ba84483f9704/Visualizacao-de-Informacoes-Uma-Abordagem-Pratica.pdf](https://www.researchgate.net/profile/Hugo-Nascimento-7/publication/267403645_Visualizacao_de_Informacoes_-_Uma_Abordagem_Pratica/links/5510a6940cf2ba84483f9704/Visualizacao-de-Informacoes-Uma-Abordagem-Pratica.pdf). Acesso em: 1 dez. 2024.

**NOVAES, Antônio Galvão.** Logística e Gerenciamento da Cadeia de Distribuição. 2. ed. Rio de Janeiro: Elsevier, 2001.

**NUNES, B. P. G.; FONSECA, I. R.; FRANÇA, J. P.; ABBADE, R. H. S.; BIANCHINI, C. P.** Identificando Sentimentos de Textos Referentes a Investimentos com Processamento de Linguagem Natural. Faculdade de Computação e Informática Mackenzie, Universidade Presbiteriana Mackenzie, São Paulo, 2021. Disponível em: <https://dspace.mackenzie.br/items/aa7b09f3-460a-4070-88a5-ce12bfde38d3>. Acesso em: 2 dez. 2024.

**PINHEIRO, Juliano Lima.** Mercados de capitais: fundamentos e técnicas. São Paulo: Atlas, 2001.

**ROLNICK, David; DONTI, Priya L.; KAACK, Lynn H.; et al.** Tackling Climate Change with Machine Learning. ACM Computing Surveys, 2022, v. 55, p. 1-96. Disponível em: <https://doi.org/10.1145/3485128>. Acesso em: 14 nov. 2024.

**SINGH, Harmanjeet; MALHOTRA, Manisha.** A Comparative Analysis of Share Price Prediction and Trend Direction Using Sentiment Analysis of Financial News Articles. 2023 Global Conference on Information Technologies and Communications (GCITC), 2023. Disponível em: <https://www.semanticscholar.org/paper/44627074c65f6bf5068459be0a0ced968fe3922d>. Acesso em: 14 nov. 2024.

**VACCARO, Davide.** Enhancement of business intelligence platforms through artificial intelligence: applications to supply chain and logistics management. Core, 2024. Disponível em: <https://core.ac.uk/download/613217049.pdf>. Acesso em: 14 nov. 2024.

**WILLMOTT, C. J.; MATSUURA, K.** Advantages of the Mean Absolute Error (MAE) over the Root Mean Square Error (RMSE) in Assessing Model Performance. *Climatic Change*, v. 51, n. 3, p. 255-276, 2005. DOI: 10.1007/s10584-001-0366-5. Disponível em: [https://www.researchgate.net/publication/235710066\\_Avantages\\_of\\_the\\_Mean\\_Absolute\\_Error\\_MAE\\_over\\_the\\_Root\\_Mean\\_Square\\_Error\\_RMSE\\_in\\_Assessing\\_Average\\_Model\\_Performance](https://www.researchgate.net/publication/235710066_Avantages_of_the_Mean_Absolute_Error_MAE_over_the_Root_Mean_Square_Error_RMSE_in_Assessing_Average_Model_Performance). Acesso em: 2 dez. 2024.

**YENDURI, Gokul; RAMALINGAM, M.; SELVI, G. Chemmalar; et al.** GPT (Generative Pre-Trained Transformer)—A Comprehensive Review on Enabling Technologies, Potential Applications, Emerging Challenges, and Future Directions. *IEEE Access*, 2024, v. 12, p. 54608-54649. Disponível em: <https://doi.org/10.1109/access.2024.3389497>. Acesso em: 14 nov. 2024.