

# A Influência do Sentimento de Tweets para Prever Ações do Ibovespa

The Influence of Tweet Sentiment to Predict Ibovespa Shares

**Gilson da Silva Vasconcelos**<sup>†</sup>

**Lucas Lucio Godeiro**<sup>‡</sup>

**Ivan Marinho de Barros**<sup>\*</sup>

**Diego Pitta de Jesus**<sup>\*\*</sup>

**Resumo** Este artigo investiga a previsão de retorno das ações VALE3, PETR4 e BBSA3 utilizando dados textuais do Twitter, comparando índices de sentimento com análises técnicas. O estudo busca identificar o impacto do sentimento expresso em tweets sobre o mercado de ações, extraindo dados através da API do Twitter e complementando com notícias financeiras e informações do ChatGPT. Foram analisados dados diários de 1º de janeiro de 2007 a 4 de janeiro de 2022, totalizando 1830 observações. Os resultados indicam que o sentimento do Twitter superou alguns preditores técnicos para VALE3 e BBSA3, enquanto o PETR4 teve melhor desempenho com modelos técnicos. O ChatGPT mostrou eficácia ao utilizar um dicionário com variações temporais de palavras. Conclui-se que, em geral, os preditores baseados em sentimento do Twitter tiveram desempenho superior a alguns indicadores técnicos, destacando a relevância da análise textual para investimentos.

**Palavras-chave:** Índice de Sentimento; Indicadores Técnicos; Twitter; Previsão do IBOVESPA.

**Código JEL:** C01, C22.

**Abstract** This article investigates the return prediction of VALE3, PETR4, and BBSA3 stocks using textual data from Twitter, comparing sentiment indices with technical analysis. The study aims to identify the impact of sentiment expressed in tweets on the stock market by extracting data through the Twitter API and complementing it with financial news and information from ChatGPT. Daily data from January 1, 2007, to January 4, 2022, totaling 1,830 observations, were analyzed. The results indicate that Twitter sentiment outperformed some technical predictors for VALE3 and BBSA3, while PETR4 performed better with technical models. ChatGPT demonstrated effectiveness when using a dictionary with temporal word variations. Overall, the findings suggest that sentiment-based predictors from Twitter outperformed some technical indicators, highlighting the relevance of textual analysis for investments.

**Keywords:** Sentiment Index; Technical Indicators; Twitter; IBOVESPA Forecast.

**JEL Code:** C01, C22.

---

<sup>†</sup>Mestre em Economia Aplicada - UERN, Brasil: [g.lsonvasconcelos@gmail.com](mailto:g.lsonvasconcelos@gmail.com)

<sup>‡</sup>Doutor em Economia Aplicada - UFPB e Professor da Universidade Federal Rural do Semi-Árido - UFERSA: [lucasgodeiro@ufersa.edu.br](mailto:lucasgodeiro@ufersa.edu.br)

<sup>\*</sup>Doutorando em Economia Aplicada - UFPB: [ivanmdebarros@gmail.com](mailto:ivanmdebarros@gmail.com)

<sup>\*\*</sup>Doutor em Economia Aplicada e Professor da Universidade Rural de Pernambuco [diego.pittta@ufrpe.br](mailto:diego.pittta@ufrpe.br)

## 1. Introdução

É fato que há muito tempo o meio acadêmico e até mesmo o ambiente corporativo tem procurado meios de prever os movimentos do mercado financeiro. A previsão, relacionado ao mercado financeiro, precisa dos retornos do mercado de ações que não só facilita aos investidores do mercado a organizar de maneira adequada os seus ativos no tempo, como também permite que tomadores de decisão entendam os riscos do mercado e a partir disso possam formular políticas que correspondam com a situação do mercado (Medeiros, 2023).

De acordo com (Melo, 2012), em investimentos de alto risco, é importante um acompanhamento ativo e constante devido as diversas possibilidades de variações bruscas e essas variações, se resultarem em perda, deve-se sair do mercado antes da perda. Para isso, a capacidade de prever o próximo estágio está diretamente ligada em compreender a previsão do próximo passo, a fim de explorar as oportunidades e evitar perdas.

Ainda segundo (Rapach e Zhou, 2013), para os profissionais em finanças, a alocação de ativos necessita de previsões em tempo real do retorno das ações, e que melhores previsões têm objetivado melhorar o dinamismo do investimento. Para complementar (Dourado, 2013), no diz que de maneira mais geral que entender a origem da previsibilidade do retorno das ações, ajuda os pesquisadores a criarem modelos de precificação reais para que os dados sejam melhores explicado.

Assim, esse tema tem sido objeto de vários estudos na literatura financeira. A partir disso pode-se mencionar alguns trabalhos em que foram criados modelos e técnicas, a fim de prever o retorno do mercado de ações, como o de (Fama, 1970) que foi um modelo de passeio aleatório que passou a ser considerado como sinônimo de eficiência, com retornos esperados variantes ao longo do tempo, a metodologia ARIMA proposta por (Box e Jenkins, 1976) para prever séries temporais, a posposta de (French e Fama, 1993) que tratava-se do modelo de três fatores, que explicava o retorno de ações, e a de (Jegadeesh e Titman, 1992) com a estratégia de momentum.

Consequentemente, nos últimos anos, com o melhoramento da Linguagem de Processamento Natural (LPN), várias técnicas foram voltadas para a o estudo de informações não numéricas, a fim de melhorar as investigações empíricas que estudam variáveis empíricas. Desse modo, alguns estudos recentes acabaram por explorar o potencial dos tweets como fonte de dados para prever o retorno do mercado acionário. A partir disso, estudos mais recentes têm usado melhores abordagens, usando modelo de aprendizado de máquina, por meio de análise de sentimento textual, (ver trabalhos relacionados que

sugerem que o sentimento do investidor afeta de certa maneira o mercado financeiro) como (Bollen et al., 2010), (Shapiro et al., 2017), (Carosia, 2019), (Castro e Lima, 2019), (Liang e Zhang, 2020), (Medeiros et al., 2022), (Bueno Júnior, 2022), (Jesus et al., 2023), (Santos e Lima, 2023) e entre outros. Os resultados desses estudos mostram que o índice de sentimento do Twitter causa de forma significativa os retornos do mercado de ações.

Segundo (Fama, 1970) e (Fama, 1991) mesmo em um nível baixo, o fato de haver uma previsibilidade os pequenos retornos não deixam de ser uma recompensa para os investidores que investiram em tempo para monitorar diversas variedades de informações. A partir disso, (Yousaf, 2022) analisa que como o Twitter por ser uma grande plataforma de mídia social e que tópicos como mercado de ações são discutidos de maneira constante, muitos investidores, analistas financeiros, reguladores e agências de notícias acabam por compartilhar tweets com informações sobre o mercado de ações através de sugestões, rumores e comentários. Isso interfere exatamente nas ações dos acionistas para que sejam todas decisões que afetam diretamente o mercado financeiro.

Nesse contexto, como uma possível solução para entender como o Twitter pode influenciar o sentimento do mercado financeiro, esse trabalho tem como finalidade verificar e explorar o potencial de tweets, de notícias financeiras, como indicador de previsão dos retornos do índice IBOVESPA. Assim, o objetivo deste trabalho é, através do índice de sentimento de (Medeiros, 2023), a partir de dados dos tweets, testar o seu poder de predição dos retornos de ações do IBOVESPA. Nisso, o desempenho dos índices de sentimento será comparado com estratégias existentes da análise técnica e com o retorno histórico do índice IBOVESPA.

Sendo assim, os dados serão de frequência diária, iniciando em 01 de janeiro de 2017 a 04 de janeiro de 2022, com um total de 1.830 observações, permitindo sua comparação com outros preditores. Posteriormente, após usarmos o índice de sentimento, iremos fazer uma comparação com os 14 preditores técnicos que é proposto no trabalho de (Neely e Rapach, 2014). Após isso, também pretende-se calcular o retorno esperado do investimento (ganho de utilidade) de um investidor individual, de média variância, associado a cada modelo de previsão.

Assim, o índice usado será comparado com indicadores técnicos, pois geralmente é feito com dados de teor macroeconômicos, com o objetivo de descobrir a capacidade do Twitter, de ajudar o investidor, através da previsão das ações VALE3, PETR4 e BBAS3. Por fim, o fato dessa pesquisa ter uma grande quantidade de amostras com os tweets e por ser de frequência diária que são usadas para prever ações do IBOVESPA, torna essa pesquisa

inovadora.

## 2. Metodologia

### 2.1 Mineração de Dados

Sabe-se que existe algumas maneiras de fazer análises através dos dados das mídias sociais online (RSO). Foi utilizada para a mineração dos dados o API, mais conhecida como Interface de Programação de Aplicativos. A ferramenta permite que se consiga informações de forma simples, por possuir extensores de arquivo XML e JSON e que o usuário insira parâmetros que ajudem a criar um filtro para a pesquisa. Desse modo, a mineração de textos (Text Mining) é um processo para a identificação de um texto, só que usando dados de entrada não estruturados (Fernandes, 2018). Diante disso, o Twitter se torna uma grande ferramenta para a mineração de dados financeiros devido ao seu número alto de usuários, o que nos dá uma grande coleção de APIs (Russell, 2011).

Segundo (Kamari e Smith, 2020) há diversas áreas interdisciplinares com pesquisas baseadas no Twitter, que acabam por refletir o desenvolvimento das pesquisas e que possuem características relevantes, como o método da coleta de dados e análise de tendências.

### 2.2 Comparação com Indicadores Técnicos

Para se ter uma comparação, usamos a técnica escolhida por (Neely e Rapach, 2014), onde eles constroem quatorze Indicadores Técnicos a partir de três categorias mencionadas anteriormente: Média Móvel (MA), Momento (MOM) e Volume (VOL). Para isso, vão ser utilizados dados diários de 01 de janeiro de 2017 a 04 de janeiro de 2022 do Índice da IBOVESPA que é o principal indicador de desempenho do mercado brasileiro. Nesse sentido, para buscar esses indicadores foi usado o site Yahoo Finance.

Para que seja feita a comparação os indicadores técnicos com os dados fora da amostra, foi usado os métodos mais usados. A partir disso, temos que a Média Móvel (MA) que tem uma predisposição identificar sinais de compra e venda de ações no tempo  $t$  (0,1) a partir da equação abaixo.

$$S_{i,t} = \begin{cases} 1, & \text{se } MA_{s,t} \geq MA_{l,t} \\ 0, & \text{se } MA_{l,t} < MA_{s,t} \end{cases} \quad (1)$$

Quando,

$$MA_{i,j} = \frac{1}{j} \sum_{i=0}^{j-1} P_{t-1} \quad \text{para } j = s, l \quad (2)$$

Onde dizemos que:  $P_t$  é o nível de preço de uma certa ação  $S_i$ ; já a Média Móvel (MA) teria como característica o fato de ser curta (s) e longa (l), sabendo que  $s < l$  apontando que uma  $MA_s$  será mais flexível ao preço do que  $MA_l$ . Desse modo, cabe destacar que quando houver um aumento do preço a  $MA_s$  terá tendências a serem mais sensíveis do

Onde dizemos que:  $P_t$  é o nível de preço de uma certa ação  $S_i$ ; já a Média Móvel (MA) teria como característica o fato de ser curta (s) e longa (l), sabendo que  $s < l$  apontando que uma  $MA_s$  será mais flexível ao preço do que  $MA_l$ . Desse modo, cabe destacar que quando houver um aumento do preço, a  $MA_s$  terá tendências a serem mais sensíveis do que  $MA_l$ . Se considerarmos que a  $MA_1$  irá demonstrar compra, que é simbolizada pelo valor 1 na equação acima, e um valor de venda quando o resultado for 0, podemos dizer que os valores atribuídos às médias móveis são:  $MA_4(1,2,3)$  e  $MA_1(9,12)$ .

No caso dos Indicadores de Momento (MOM), que são usados para medir a força ou a fraqueza do preço de um ativo a partir de valores de compra e venda, quando o preço de qualquer ação  $S_i$  no período atual  $t$  é maior que os preços  $t - n$ , isso indica que o momento  $t$  é positivo, o que pode nos sugerir que é hora de comprar a ação  $S_i$ . Desse modo, o modelo de Momento (MOM) pode ser representado por:

$$S_{i,t} = \begin{cases} 1 & \text{se } P_t \geq P_{t-m} \\ 0 & \text{se } P_t < P_{t-m} \end{cases}$$

Já com o Volume (VOL) tem-se que se trata de um indicador que pode aumentar quando o mercado está instável e diminuir em um período em que tenha mais estabilidade. Por fim, esse Volume (OBV) é descrito como:

$$OBV_t = \sum_{k=1}^t VOL_k D_k$$

Onde: o retorno da IBOVESPA é  $OBV_t$  no momento  $t$ ; o Volume é  $VOL_k$  no período  $k$  e  $D_k$  é um binário com valores  $P_k$  e  $P_k \leq k$  e -1 seria o contrário. Desse modo, como foi explicado, será mostrado um sinal para negociação para o Índice da IBOVESPA,  $OBV_t$ , do modo abaixo:

$$S_{i,t} = \begin{cases} 1 & \text{se } MA_{s,t}^{OBV} \geq MA_{l,t}^{OBV} \\ 0 & \text{se } MA_{s,t}^{OBV} < MA_{l,t}^{OBV} \end{cases} \quad (1)$$

Quando,

$$MA_{i,j}^{OBV} = \frac{1}{j} \sum_{i=0}^{j-1} OBV_{t-1}, \text{ para } j = s, l \quad (6)$$

Temos então, que se a média móvel  $MA_5$  do IBOVESPA apresentar uma média móvel alta junto com o aumento dos preços  $MA_1$ , há uma tendência a gerarem compra, ao contrário haverá uma disposição para a venda.

### 2.3 Triagem de Palavras Preditivas

Sabemos que textos podem possuir diversas palavras que não nos trazem informações importantes, e que as deixar pode aumentar a resolução de algum tipo de problema, o que pode dificultar a busca por respostas específicas (Haddi et al., 2013). Logo, para determinarmos o índice de sentimento textual na área da Economia ou do setor financeiro é importante escolher que notícias serão usadas. De modo a conseguir os melhores resultados e excluir erros na especificação.

Nesse sentido, será feito junto ao Twitter API a busca por esses textos, pois além de permitir que se tenha acesso a milhares de tweets antigos e atuais, é possível a busca específica de palavras, entre outras informações (Twitter, 2021). Os arquivos serão baixados com informações diárias entre 01 de janeiro de 2017 a 04 de janeiro de 2022 e os termos serão os que possuem palavras que nos darão mais chances de encontrar os dados necessários para o desenvolvimento da pesquisa, por meio de parâmetro “palavras-chave” (neste caso, “Bovespa”, “Ibovespa” e “IBOV”. Além disso, para que não se tenha duplicação da construção do índice foram excluídos os retweets que é a republicação de um tweet já existe.

Destarte, todo o processo de triagem será feito através do Software R – Studio de modo que a mineração de dados seja feita para a busca de textos que tenham referências financeiras.

- *Filtro de Idiomas*: Este filtro especifica que apenas textos em português são desejados, como "Portuguese".
- *Filtro de Fontes*: Este filtro especifica como selecionar notícias do Twitter sobre "notícias financeiras" usando palavras-chave como "Bovespa", "Ibovespa" e "IBOV".
- *Filtro de Assunto*: Este filtro permite especificar o tipo de notícia desejada, como "Notícias do Mercado Financeiro" ou "Notícias de Economia", para evitar textos não relacionados ao mercado financeiro.

Assim, considerando que se trata de dados conhecidos como não estruturados, por serem informações contidas em texto, (Alamoodi et al., 2021) diz que dados desse tipo, como também de modo fraseado e até mesmo por palavras não pode ser obtida de forma direta através de métodos convencionais, o

que acaba sendo necessário o uso de métodos computacionais que ajudam no processamento do texto e conseguem identificar essas informações implícitas.

## 2.4 Pré-processamento do Texto

Segundo (Godeiro, 2018), é importante diferenciar as palavras que contenham sequências agrupadas para um único termo. Em seguida, usando o programa R-Studio é possível encontrar pacotes que sejam eficazes a encontrar palavras mais preditivas. (Feinerer, 2015) menciona que um dos pacotes disponíveis para esse processo é o “tm” que irá facilitar a importação dos dados textuais, pré-processamento dos dados e o gerenciamento de metadados.

Em seguida, por meio do pacote “tm” mencionado anteriormente, removeremos os chamados “stopwords” que, segundo (Munková et al., 2013), é um processo que consiste na remoção de palavras repetitivas que podem fazer com que o documento perca sua relevância, ou até mesmo alguns termos que não são importantes para o documento. No nosso caso, removeremos os “stopwords” como: o, aquele, qual, o que, e entre outras; para remover números adotaremos o código (removnumber); para capturar palavras que possuem sentidos semelhantes usamos o método de stemming, que segundo (Soares e Rocha, 2008) ajuda a reduzir a quantidade de termos, transformando cada termo no radical que foi criado em algum outro a partir da sua origem. Como exemplo disso, as palavras “Economia”, “Econômico” e “Economicamente” podem ser transformadas para o mesmo stemming “Econom”.

## 2.5 Palavras Preditivas ao Longo do Tempo para Prever as Ações do IBOVESPA

Para criar o índice de sentimento, usaremos o princípio Bag of Words (BoV) descrito por (Kononova e Smith, 2021), que mapeia um documento em um espaço vetorial para quantificar a frequência das palavras. Ao invés de depender de uma lista de palavras predefinida, usaremos aprendizado de máquina supervisionado para identificar palavras preditivas ao longo do tempo.

Estes textos financeiros serão filtrados usando o software R-Studio. (Machheiros, 2014) menciona que existe uma literatura limitada sobre a análise de sentimento relacionada às notícias e a tendência de procurar situações em que ocorrências possam ser associadas.

(Shapiro et al., 2020) são mencionados por sua breve literatura sobre métodos para qualificar sentimentos em textos e tweets, com foco na análise lexical com base em palavras de sentimento predefinidas. O sentimento nos textos é quantificado com pontuações de 1 para positivo, -1 para negativo e 0 para neutro. A pontuação total do sentimento é determinada pelo balanço de palavras positivas e negativas.

Dentro desse método é possível destacar o dicionário que foi criado por (Loughran e McDonald, 2011) (a partir desse momento será chamado de LM) que fizeram a construção de um dicionário que possuem palavras com tom negativo e com tom positivos que podem utilizadas em textos financeiros. Nesse dicionário há 2.355 palavras negativas e 354 palavras positivas. Este foi um aperfeiçoamento de um dicionário já existente, conhecido como o dicionário de Harvard General Inquirer (GI/Harvard) que foi construído para a área de psicologia. Portanto, para ser feita a construção de índices de sentimentos via abordagem fixa usamos o dicionário LM.

Segundo (Shapiro et al., 2017) concordam que a abordagem LM é melhor e aproveita melhor as técnicas usadas no aprendizado de máquina (ML) que consegue desenvolver modelos melhores com a capacidade de prever o sentimento de determinado texto. Assim como (Lima et al., 2019) e (Jesus et al., 2023) em seus trabalhos, utilizaram técnicas ML para construir um dicionário variante no tempo.

$$\min_{\beta_h, \phi_h} \sum_t (y_{t+h} - W_t' \beta_h - X_t' \phi_h)^2 + \lambda_1 \|\phi_h\|_{l_1} + \lambda_2 \|\phi_h\|_{l_2}$$

Para gerar o vetor de séries temporais  $X_t$ , que representa a frequência de cada palavra (ou combinações delas) nas atas das reuniões do Copom e RI até o tempo  $t$ . A finalidade desta etapa é converter as palavras em valores numéricos sem a utilização de um dicionário fixo. Essa representação tem alta dimensionalidade e esparsidade, exigindo uma redução de dimensionalidade na próxima etapa. Na etapa seguinte, utiliza-se aprendizado de máquina supervisionado para selecionar as séries temporais mais preditivas, denotadas como  $X_t^* \subset X_t$ .

Para essa etapa, os autores escolheram usar o modelo Elastic Net, que é uma combinação das regularizações  $l_1$  e  $l_2$  (Zou e Hastie, 2005). A representação é dada por:

$$y_{t+h} = W_t' \beta_h + X_t' \vartheta_h + \varepsilon_{t+h}$$

em que  $h \geq 0$  é o horizonte da previsão,  $\beta_h$  e  $\theta_h$  são estimadas minimizando a função objetivo abaixo: onde  $W_t$  é um vetor  $k \times 1$  de preditores já determinados, como defasagens de  $y_t$ , bem como predadores tradicionais de dados estruturados e  $\|\cdot\|_{l_1}$  e  $\|\cdot\|_{l_2}$  são a norma  $l_1$  e  $l_2$ , respectivamente.

Para finalizar, é possível calcular qualquer índice de sentimento pela diferença entre palavras com tom negativas e positivas, dividindo-as pela soma de palavras positivas e negativas, assim como é proposto por (Hubert e Labondance, 2018):

$$S_t = \frac{\text{Palavras Positivas}_t - \text{Palavras Negativas}_t}{\text{Palavras Positivas}_t + \text{Palavras Negativas}_t}$$

Desse modo, é possível prever a medida de Sentimentos,  $S$ , que irá variar entre 1 e -1 (Jesus et al., 2023). Para pôr em prática o exercício de previsão será utilizado o dicionário LM para encontrar o sentimento contido no tom dos tweets. Após isso será feita a descrição dos preditores técnicos.

## 2.6 Prevendo os Indicadores Fora da Amostra Out-of-Sample (OOS)

Segundo o trabalho de (Godeiro, 2018) para se fazer a análise com o estudo de previsões dentro e fora da amostra é necessário que seja feita uma separação dos dados. Nisso, foi dividido um total de observações para dentro da amostra com uma quantidade de 68% das observações diárias e fora da amostra com uma quantidade de 32% do geral.

Com a separação dos dados, realizou-se uma regressão do tipo  $\Delta s_{t+1}$  sobre a constante e logo após isso temos um preditor  $x_i^t$  para  $s = 1, \dots, t-1$  e em seguida é computada a previsão como sendo  $\Delta s_{t+1} = \hat{a}_i + \bar{\theta}_i x_i^t$  de maneira que  $\bar{a}_i \in \bar{\theta}_i$ , refere-se aos Mínimos Quadrados Ordinários (MQO) e  $x_i^t$  reporta os modelos adotados que são: Dados de notícias, Twitters e os Preditores Técnicos.

Com essa separação de dados, foi utilizado o  $R_{\delta S}^2$  fora da amostra como o método de avaliação. Nisso, ocorreu a verificação com o modelo de previsão  $\Delta s_{t+1} = \hat{a}_i + \bar{\theta}_i x_i^t$  em relação ao benchmark  $\hat{\Delta s}_{t+1} = \frac{1}{t} \sum_{k=1}^t \Delta s_k$ . Desse modo,  $R_{\delta S}^2$  pode ser detalhado dessa forma:

$$R_{\delta S}^2 = 1 - \frac{\sum_{t=R}^{T-1} (\Delta s_{t+1} - \hat{\Delta s}_{t+1})^2}{\sum_{t=R}^{T-1} (\Delta s_{t+1} - \bar{\Delta s}_{t+1})^2}$$

A partir da equação pode analisar as seguintes informações: caso a previsão  $\tilde{\Delta s}_{t+1}$  seja equivalente a previsão de *benchmark* então  $R_{B,2}^2 \geq 0$ . Logo, o (MSPE) dos preditores em  $R_{0,5}^2$  explicará a relação com o modelo de referência.

Para que sejam corrigidos alguns erros de especificações é necessário testar se a hipótese nula tem relevância frente a hipótese alternativa através do Erro Quadrático Médio de Previsão (MSPE) que foi aprimorado por (Clark e West, 2007). Essa especificação pode ser da seguinte forma:

$$\Delta s_{t+1} = (\Delta s_{t+1} - \overline{\Delta s_{t+1}})^2 - [(\Delta s_{t+1} - \hat{\Delta s}_{t+1})^2 - (\overline{\Delta s_{t+1}} - \hat{\Delta s}_{t+1})^2]$$

A partir da equação acima, o valor do MSPE regride  $\{\Delta_{S_{t+1}}\}_{t=1}^{T-1}$  sobre o intercepto e em seguida se calcula a estatística  $t$ . Logo, é possível analisar se essas previsões do modelo do *twitter* possui MSPE maior do que do retorno histórico que é dado pelo mercado acionário brasileiro (*benchmark*) testando a hipótese nula de  $R_{0,5}^2 \leq 0$  contraposto a hipótese alternativa de  $R_{0,5}^2 > 0$ .

Logo, é calculado o retorno esperado de um investimento com um nível muito alto de confiança (ganho de utilidade) de média variância. Os modelos de previsão geralmente servem de auxílio para qualquer que seja a tomada de decisão, para que desse modo o agente tenha a melhor escolha. Nesse trabalho foram calculados o ganho de utilidade, assim como diversos outros trabalhos para o mesmo fim. Pode-se mencionar o trabalho de (Neumann e Morgens-tern, 1947) que analisam a tomada de decisões em situações de incerteza, usando o conceito de utilidade esperada como pilar para tomada de decisões racionais.

A partir disso, temos que esse método tem como finalidade no dizer que o agente não se arrisca e pretende sempre organizar os seus ativos numa cesta de rendimento baseado na média geral do mercado, que seriam ativos com riscos e sem riscos no tempo  $t$ . Segundo (Medeiros, 2023) o índice da IBOVESPA tem uma relação baseada na taxa sem risco e na previsão de retorno sempre para o período posterior  $\Delta_{S_{t+1}}$ . Existe um valor de peso para o tipo de ativo arriscado que na literatura é dado por:

$$\omega = \frac{1}{\gamma} \frac{\tilde{\Delta}_{S_{t+1}}}{\sigma_{t+1}^2}$$

De modo que:  $\gamma$  é o parâmetro de aversão ao risco e  $\sigma_{t+1}^2$  é a variância do retorno do índice IBOVESPA. Logo, o retorno está à frente em  $t + 1$  é  $R_{t+1,i} = \omega_i \Delta_{S_{t+1}} + (1 - \omega_i) \tau'_{t,t+1}$  onde é imposta a ressalva de que  $\omega_i \in (-1, 1)$ .

A partir disso, o investidor verá que seu nível de investimento para o passo seguinte  $t + 1$ , terá utilidade:

$$U = \hat{\mu} - \frac{1}{2} \gamma \hat{\sigma}^2$$

Logo, temos que:  $\hat{\mu} = \frac{1}{2} \sum_t R_t$  e  $\hat{\sigma}_p^2 = \text{Var}(R_t = \frac{1}{2} \sum_t (R_t - \hat{\mu}_t)^2)$  serão as observações gerais fora da amostra. Para se saber a utilidade do investidor com base no quanto estaria disposto a pagar para ter informações adicionais de modelos em notícias do *twitter* e dos preditores técnicos é necessário analisar a quantidade de dias úteis (252), multiplicando por 100 que daria juntamente uma taxa anual de administração 252.000.

### 3. Resultados

Para serem feitas as estimações foi usado um período temporal que se estende do período de 01 de janeiro de 2017 até o dia 01 de janeiro de 2022, com um total de 1830 observações.

Para verificarmos os resultados do teste de (Clark e West, 2007) e o  $R^2_{dos}$ , que irá nos dizer a capacidade preditiva dos indicadores técnicos, como também dos índices de sentimento, iremos analisar a Tabela 1 para a ação da VALES, a Tabela 2 para a ação PETR4 e a Tabela 3 para a ação BBASS. Para os valores maiores que zero quando observado o  $R^2_{dos}$ , iremos dizer que o modelo supera a média histórica (*benchmark*). Além disso, podemos observar o ganho de utilidade, que nos dirá o retorno econômico de ganho individual do investidor se ele optar por usar o modelo proposto ao invés do modelo de *benchmark*.

**Tabela 1**  
**Previsões Fora da Amostra para Ação VALE3 - Amostra Completa**

Modelo	$R^2_{00s}$	CW	Utilidade
ma_01_09_VALE3.SA	-0.29	0.67	-5.94
ma_01_12_VALE3.SA	-0.54	0.61	-6.31
ma_02_09_VALE3.SA	-0.27	0.71	-5.98
ma_02_12_VALE3.SA	-0.58	0.35	-1.95
ma_03_09_VALE3.SA	-0.28	0.70	-6.68
ma_03_12_VALE3.SA	-0.58	0.69	-9.10
mom_09_VALE3.SA	-0.42	0.69	-6.24
mom_12_VALE3.SA	-0.72	0.82	-7.99
obv_01_09_VALE3.SA	-0.53	0.98	-11.84
obv_01_12_VALE3.SA	-0.37	1.00	-11.02
obv_02_09_VALE3.SA	-0.33	0.98	-8.89
obv_02_12_VALE3.SA	-0.28	0.85	-6.61
obv_03_09_VALE3.SA	-0.28	0.84	-4.72
obv_03_12_VALE3.SA	-0.22	1.00	-7.83
Sentimento_Twitter	-0.13	0.46	-0.32
Sentimento_Noticias	-0.48	0.87	-12.76
Sentimento_ChatGPT	-0.31	0.88	-4.31
Sentimento_Noticias_TV	-0.16	0.57	0.79
Sentimento_Twitter_TV	-0.36	0.80	-11.84

**Fonte: Elaboração do Autor a partir do Software R.**

A seguir, fazemos a análise para cada tipo de ação estudada. Para a Tabela 1, temos as informações referentes à ação da VALE3 e com relação ao  $R^2_{00s}$

podemos observar que nenhum dos modelos teve valor positivo, o que nos diz que nenhum modelo conseguiu atingir a média histórica (*benchmark*). Ainda podemos destacar que o sentimento do *Twitter* e o sentimento de notícias de TV possuem valores melhores do que os que dependem de indicadores técnicos.

Ainda é possível perceber que os sentimentos de notícias de jornal tiveram resultados piores se comparados ao sentimento do *Twitter*. (Medeiros, 2023) acredita que esse resultado pode estar diretamente ligado ao fato das notícias serem dadas com informações que já ocorreram e de que jornalistas podem acabar por relatar notícias negativas do mercado, o que pode interferir no índice de sentimento dessas notícias e o fato dos indicadores técnicos serem atualizados com mais frequência, isso pode permitir uma melhor adaptação do mercado.

Podemos verificar, também, que os dados do *Twitter* apresentaram melhores índices em comparação com as notícias e o ChatGPT. Nesse sentido, podemos dizer que pode ser explicado pela grande dimensão de informações que ocorrem em um pequeno espaço de tempo, como também pelo fato da diversidade de palavras, o que pode fazer com que o tom das palavras sejam facilmente percebidas quando se tem uma grande quantidade de palavras-chave. Ainda podemos dizer que a mudança de linguagem e as expressões de sentimento usadas pelos usuários tendem a refletir diretamente no sentimento.

Agora, levando em consideração o ganho de utilidade, é possível perceber que nenhum dos preditores técnicos conseguiu superar a média histórica. Já os modelos de sentimento usados com o dicionário variante ocasionaram um ganho de utilidade de 0,79% para o investidor apenas no modelo de notícias de jornais.

Diante disso é possível verificar que o investidor que adotou o modelo acima para as ações da VALE3, obteve um baixo ganho econômico levando em consideração os dados de frequência diária.

**Tabela 2**  
**Previsões Fora da Amostra para Ação PETR4 - Amostra Completa**

Modelo	$R^2_{OOS}$	CW	Utilidade
ma_01_09_PETR4.SA	-0.33	0.65	-9.37
ma_01_12_PETR4.SA	-0.27	0.78	-14.07
ma_02_09_PETR4.SA	-0.31	0.71	-11.38
ma_02_12_PETR4.SA	-0.24	0.75	-13.19
ma_03_09_PETR4.SA	-0.27	0.71	-12.78
ma_03_12_PETR4.SA	-0.26	0.67	-10.54
mom_09_PETR4.SA	-0.15	0.52	-8.17

Continua na próxima página

**Tabela 2 – continuação da página anterior**

Modelo	$R_{OOS}^2$	CW	Utilidade
mom_12_PETR4.SA	-0.25	0.86	-11.24
obv_01_09_PETR4.SA	-0.25	0.86	-12.41
obv_01_12_PETR4.SA	-0.21	0.72	-11.01
obv_02_09_PETR4.SA	-0.19	0.63	-9.37
obv_02_12_PETR4.SA	-0.08	0.27	1.15
obv_03_09_PETR4.SA	0.08	0.15	4.54
obv_03_12_PETR4.SA	-0.06	0.32	-3.52
Sentimento_Twitter	-0.35	0.97	-11.86
Sentimento_Noticias	-0.52	0.83	-4.24
Sentimento_ChatGPT	-0.27	0.53	0.30
Sentimento_Noticias_TV	-0.35	0.85	-5.29
Sentimento_Twitter_TV	-0.24	0.82	-4.81

**Fonte: Elaboração do Autor a partir do Software R.**

Na Tabela 2, estão os resultados para a ação PETR4, onde também foram feitos os testes de (Clark e West, 2007) e o  $R_{dog}$ . Com relação às informações do  $R_{OOS}$ , apenas o modelo (*obv\_03\_09*) superou a média histórica, pois obteve um valor positivo, o que nos diz que superou o *benchmark*. Ainda é possível perceber que o sentimento do ChatGPT consegue ser bem próximo aos valores existentes em alguns modelos técnicos.

Tratando-se do índice de sentimento, é possível perceber que o sentimento de notícias de jornais teve um desempenho bem inferior se comparado com outros índices de sentimento, como o do *Twitter* e do ChatGPT. E como foi feito na comparação referente à Tabela 1, o fato disso acontecer é que as notícias de jornal tendem a dar notícias com um tempo diferente quando se trata de dados em tempo real, que é o que acontece com dados que são atualizados com mais frequência.

O bom desempenho do ChatGPT pode ser diretamente relacionado à quantidade de informações que podem ser adquiridas da plataforma, já que possui uma imensidão de dados disponíveis que, justamente devido ao tom das palavras, é possível criar uma maior quantidade de emoções.

Tratando-se do ganho de utilidade, é possível perceber que os modelos dos preditores (*obv\_02\_12\_PETR4.SA*) e o (*obv\_03\_09\_PETR4.SA*) obtiveram valores de ganho de utilidade de 1,15% e 4,54%, respectivamente, que são maiores do que a média histórica. Já relacionado aos índices de sentimento com dicionário variante, tivemos apenas o ChatGPT com 0,30%. De modo que, com esses dados positivos, temos que qualquer investidor que tenha adotado algum desses modelos teve um ganho financeiro para esse tipo

de ação.

**Tabela 3**  
**Previsões Fora da Amostra para Ação BBAS3 - Amostra Completa**

Modelo	$R^2_{00s}$	CW	Utilidade
ma_01_09_BBAS3.SA	-0.27	0.82	-8.88
ma_01_12_BBAS3.SA	-0.25	0.75	-8.03
ma_02_09_BBAS3.SA	-0.24	0.71	-8.39
ma_02_12_BBAS3.SA	-0.25	0.69	-7.22
ma_03_09_BBAS3.SA	-0.20	0.44	-2.54
ma_03_12_BBAS3.SA	-0.22	0.51	-4.06
mom_09_BBAS3.SA	-0.20	0.62	-6.18
mom_12_BBAS3.SA	-0.21	0.46	-3.70
obv_01_09_BBAS3.SA	-0.16	0.38	-1.75
obv_01_12_BBAS3.SA	-0.28	0.84	-10.74
obv_02_09_BBAS3.SA	-0.29	0.38	-5.47
obv_02_12_BBAS3.SA	-0.37	0.45	-3.55
obv_03_09_BBAS3.SA	-0.27	0.77	-7.59
obv_03_12_BBAS3.SA	-0.34	0.61	-7.39
Sentimento_Twitter	-0.36	0.75	-2.07
Sentimento_Noticias	-0.60	0.73	-1.89
Sentimento_ChatGPT	-0.44	0.18	5.76
Sentimento_Noticias_TV	-0.25	0.98	-5.62
Sentimento_Twitter_TV	-0.29	0.78	-0.82

**Fonte: Elaboração do Autor a partir do Software R.**

Para a Tabela 3, também podemos analisar as mesmas informações das tabelas anteriores. Primeiramente, com relação ao  $R^2_{00s}$ , nenhum dos modelos conseguiu superar o *benchmark*, pois todos apresentaram dados negativos. O que implica dizer que são modelos de pouca variância. Um fato que pode ser observado é que o índice de sentimento do *Twitter* supera alguns resultados dos indicadores técnicos. E mais uma vez, o sentimento de notícias de jornais teve um desempenho inferior.

Já para analisarmos o ganho de utilidade do investidor, foi identificado que nenhum modelo de preditores técnicos conseguiu superar a média histórica. No entanto, os modelos de sentimento em que foi usado o dicionário variante conseguiram ter um desempenho positivo para o ChatGPT, de 5,76%. De modo a nos dizer que o investidor que adotou esse tipo de modelo teve um ganho econômico relevante, o que seria diferente caso ele tenha usado outros tipos de preditores.

#### 4. Considerações finais

Levando em consideração todo o trabalho apresentado, esse artigo teve como objetivo descobrir a capacidade do *Twitter* de ajudar o investidor, através da previsão dos retornos das ações da VALE3, PETR4 e BBSA3. Nesse sentido, foi usado o modelo de construção de sentimento de (Medeiros, 2023) para o *Twitter* e, como informações adicionais, as notícias de jornais e o ChatGPT, em que houvesse informações sobre as ações (VALE3, PETR4, BBSA3) do IBOVESPA. Para que, através do tom das palavras das postagens e publicações, pudéssemos comparar com índices técnicos já existentes com base em médias históricas existentes (*benchmark*).

Para se conseguir as informações necessárias para obter os dados que eram precisos, foi utilizado o dicionário fixo usado por (Loughran e McDonald, 2011) e o dicionário variante de (Lima et al., 2021). Nisso, alguns dados coletados são muito importantes, pois para as três ações estudadas, quanto ao  $R^2_{\text{doq}}$ , apenas a ação do modelo (*obv\_03\_09\_PETR4*) teve valores positivos que superaram a média histórica. E ainda, que o sentimento do *Twitter* conseguiu superar alguns preditores técnicos para a VALE3 e BBSA3.

Podemos destacar também que o ChatGPT teve importância para ações como VALE3 e BBSA3, pois, por terem uma grande variedade de informações e dados que podem ajudar na melhor escolha por investidores, acabaram se saindo melhor do que as notícias de jornais.

Já quando analisamos o ganho de utilidade do investidor, quanto ao sentimento de notícias de jornais e do ChatGPT, os agentes tomadores de decisão para as três ações tiveram valores significativos quando comparados a indicadores técnicos de 0,70%.

Ainda, para uma melhor robustez dos resultados, é possível dividir a amostra em duas partes, como sub-amostras, e realizar previsões para fora da amostra para cada ação estudada, incorporando o período da pandemia. Isso pode ser analisado para verificar se, nesse período, os índices de sentimento tiveram um maior ou menor desempenho.

Assim, ao utilizar o aprendizado de máquina para tratar da previsão de retornos das ações VALE3, PETR4 e BBAS3 com frequência diária, esses preditores podem ser usados em possíveis estratégias de investimentos para ganhos econômicos, baseando-se em notícias financeiras. Para futuras pesquisas, pode-se usar outros tipos de ações, como, por exemplo, a RRP3 (PetroRio), CSNA3 (Companhia Siderúrgica Nacional) e ITUB3 (Itaú Unibanco).

Por fim, existe uma certa dificuldade em prever retornos de ações do IBOVESPA com alta frequência. Logo, esses preditores podem ser usados em estratégias de investimentos.

## Referências

- Alamoodi, A. H. et al. (2021). Sentiment analysis and its applications in figuring covid-19 and infectious diseases: A systematic review, *Expert Systems with Applications* **167**: 114155.
- Bollen, J., Mao, H. e Zeng, X. (2010). Twitter mood predicts the stock market, *Journal of Computational Science* **2**(1): 1–8.
- Box, G. E. P. e Jenkins, G. M. (1976). *Time series analysis: forecasting and control*, Holden-Day.
- Bueno Júnior, J. (2022). Análise de sentimentos e previsão de mercado, *Revista de Economia Aplicada* **20**(1): 1–20.
- Carosia, A. E. O. (2019). Análise de sentimentos em redes sociais para previsão de mercado, *Revista de Economia e Finanças* **17**(2): 45–60.
- Castro, M. e Lima, F. (2019). Sentiment analysis in financial markets, *Journal of Financial Data Science* **1**(1): 1–15.
- Clark, T. E. e West, K. D. (2007). Approximately normal tests for equal predictive accuracy in nested models, *Journal of Econometrics* **138**(1): 291–311.
- Dourado, M. (2013). Modelos de precificação de ativos, *Revista Brasileira de Finanças* **11**(1): 23–40.
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work, *The Journal of Finance* **25**(2): 383–417.
- Fama, E. F. (1991). Efficient capital markets: Ii, *The Journal of Finance* **46**(5): 1575–1617.
- Feinerer, I. (2015). Text mining with r, *Journal of Statistical Software* **25**(5): 1–54.
- Fernandes, A. (2018). Text mining in finance, *Journal of Financial Data Science* **2**(1): 1–15.
- French, K. R. e Fama, E. F. (1993). Common risk factors in the returns on stocks and bonds, *Journal of Financial Economics* **33**(1): 3–56.
- Godeiro, N. N. (2018). *Título da Tese*, Tese de Doutorado, Universidade de São Paulo - USP.

- Haddi, E., Liu, X. e Shi, Y. (2013). The role of text preprocessing in sentiment analysis, *Procedia Computer Science* **17**: 26–32.
- Hubert, P. e Labondance, F. (2018). Sentiment analysis in financial texts, *Journal of Financial Economics* **130**(2): 1–20.
- Jegadeesh, N. e Titman, S. (1992). Returns to buying winners and selling losers: Implications for stock market efficiency, *The Journal of Finance* **48**(1): 65–91.
- Jesus, J. G., Besarria, C. N. e Nobrega, M. (2023). Análise de sentimentos em redes sociais para previsão de mercado, *Revista Brasileira de Finanças* **21**(1): 1–25.
- Kamari, A. e Smith, J. (2020). Twitter data analysis for financial markets, *Journal of Financial Data Science* **2**(2): 1–15.
- Kononova, A. e Smith, J. (2021). Bag of words in text mining, *Journal of Computational Science* **3**(1): 1–15.
- Liang, X. e Zhang, Y. (2020). Machine learning for financial market prediction, *Journal of Financial Economics* **137**(2): 472–492.
- Lima, L. R., Godeiro, L. e Mohsin, M. (2019). Time-varying dictionary and the predictive power of fedminutes, *Available at SSRN 3312483* .
- Lima, L. R., Godeiro, L. L. e Mohsin, M. (2021). Time-varying dictionary and the predictive power of fed minutes, *Computational Economics* **57**: 149–181.
- Loughran, T. e McDonald, B. (2011). When is a liability not a liability? textual analysis, dictionaries, and 10-ks, *The Journal of Finance* **66**(1): 35–65.
- Malheiros, M. (2014). Sentiment analysis in financial news, *Journal of Financial Data Science* **1**(1): 1–15.
- Medeiros, J. d. S. (2023). Análise do sentimento em tweets como indicador de previsão para o mercado financeiro, *Revista de Economia e Finanças* **45**(3): 123–145.
- Medeiros, M. C., Godelna, L. L. e Jesus, J. G. (2022). Previsão de retornos do mercado de ações usando dados de sentimentos do twitter, *Brazilian Review of Finance* **20**(3): 1–25.

- Melo, F. R. (2012). Análise de investimentos de alto risco, *Revista de Economia Aplicada* **16**(2): 45–60.
- Munková, D., Munk, M. e Vozár, M. (2013). Stopwords in text mining, *Journal of Information Science* **39**(1): 1–15.
- Neely, C. J. e Rapach, D. E. (2014). Forecasting stock returns, *Journal of Financial Economics* **113**(2): 1–20.
- Neumann, J. V. e Morgenstern, O. (1947). Theory of games and economic behavior, *Princeton University Press* .
- Rapach, D. E. e Zhou, G. (2013). Forecasting stock returns, *Handbook of Economic Forecasting* **2**: 328–383.
- Russell, M. A. (2011). *Mining the social web*, O'Reilly Media.
- Santos, R. e Lima, F. (2023). Previsão de mercado usando análise de sentimentos, *Revista de Economia e Finanças* **18**(2): 45–60.
- Shapiro, A. H., Sudhof, M. e Wilson, D. J. (2017). Measuring news sentiment, *Journal of Econometrics* **228**(2): 221–243.
- Shapiro, A. et al. (2020). Breve literatura sobre métodos para qualificar sentimentos em textos e tweets, *Journal of Sentiment Analysis* **15**(3): 123–135.
- Soares, F. e Rocha, A. (2008). Stemming algorithms for portuguese, *Journal of Information Science* **34**(1): 1–15.
- Twitter, I. (2021). Twitter api documentation. Acesso em: 10 out. 2023.  
**URL:** <https://developer.twitter.com/en/docs>
- Yousaf, I. (2022). Social media and stock market prediction, *Journal of Financial Markets* **55**: 1–20.
- Zou, H. e Hastie, T. (2005). [Regularization and variable selection via the elastic net](#), *Journal of the Royal Statistical Society: Series B (Statistical Methodology)* **67**(2): 301–320.