

# Dados textuais agregam valor na previsão da curva de juros?

Jhonatan Goncalves dos Santos<sup>†</sup>. <sup>a</sup>  
Prof. João Frois Caldeira, Dr.<sup>‡</sup>. <sup>a</sup>

<sup>a</sup>Universidade Federal de Santa Catarina

**Resumo** A previsão da curva de juros é um dos principais desafios da macroeconomia e das finanças, com implicações para a política monetária, precificação de ativos e gestão de riscos. Este estudo investiga a previsão da curva de juros brasileira com o uso de dados textuais extraídos das atas do Copom e do FOMC. Utiliza-se o modelo dinâmico de Nelson-Siegel, estimado via Filtro de Kalman, incorporando medidas de sentimento obtidas por meio do dicionário financeiro de Loughran e McDonald (2011). As previsões fora da amostra adota uma janela em expansão, para análise da performance dos modelos. Os resultados apontam que os dados textuais melhoram o desempenho preditivo dos modelos no curto e médio prazo. A análise reforça a importância das informações qualitativas presentes nos comunicados dos bancos centrais, contribuindo para a literatura ao aplicar técnicas de processamento de linguagem natural na previsão da taxa de juros.

**Palavras-chave:** Previsão da curva de juros, modelo de Nelson-Siegel, análise de sentimento, dados textuais, comunicação dos bancos centrais.

**Códigos JEL:** E43, E52, C53.

## 1. Introdução

A estrutura a curva de juros, é uma representação gráfica de títulos de um mesmo risco de crédito, mas com diferentes maturidades. Ela é uma ferramenta importante para entender como o mercado precifica o tempo e o risco de um título, sendo um dos elementos essenciais na formulação de modelos para tomada de decisão de agentes econômicos como instituições financeiras, investidores e bancos centrais (Vaz e Raad, 2022).

Compreender os movimentos da curva de juros é fundamental para análises de conjuntura econômica e previsões, sendo um tema de grande interesse para formuladores de políticas públicas e investidores. A literatura destaca que fatores macroeconômicos desempenham um papel crucial na determinação da estrutura a termo da taxa de juros. (Andrade Alves et al., 2023).

---

Submetido no dia 06 de abril de 2025.

<sup>†</sup>jhonatangoncalves.sa@gmail.com

<sup>‡</sup>joao.caldeira@ufsc.br

Os autores [Ang e Piazzesi \(2003\)](#) incorporaram variáveis macroeconômicas em modelos multifatoriais da estrutura a termo livre de arbitragem, utilizando fatores como inflação e atividade real para explicar os movimentos na curva de juros. Seus resultados indicam que choques relacionados à atividade econômica têm um impacto significativo sobre a curvatura da curva de juros, enquanto os choques inflacionários geram efeitos predominantes no nível de toda a curva, refletindo a influência das condições macroeconômicas nas diferentes partes da estrutura a termo.

Segundo [Diebold et al. \(2006\)](#), a interação entre a curva de juros e as variáveis macroeconômicas apresentam um efeito bidirecional significativo. Ao empregar uma modelagem autorregressiva para as variáveis de atividade econômica, inflação e um instrumento de política monetária, os autores investigaram as dinâmicas entre a macroeconomia e a curva de juros. Os resultados indicam que as variáveis macroeconômicas impactam os movimentos futuros da curva de juros. Além disso, os autores também encontraram evidências de uma influência reversa, onde as alterações na curva de juros afetam as variáveis macroeconômicas, evidenciando uma relação interdependente entre ambos.

Essa interação entre a curva de juros e as variáveis macroeconômicas revela a complexidade do sistema econômico, onde tanto os fatores macroeconômicos quanto os movimentos na curva de juros exercem influência mútua. À medida que os modelos tradicionais tentam capturar essas dinâmicas, os agentes econômicos recorrem cada vez mais a novas fontes de informação para auxiliar na tomada de decisão. Com o avanço tecnológico e o acesso a informação, a disponibilidade de dados textuais tem se expandido significativamente. Segundo [Lima e Godeiro \(2022\)](#) esses dados oferecem uma rica base para a análise das expectativas e comportamentos do mercado financeiro e macroeconômico, possibilitando a criação de novos indicadores preditivos de variáveis financeiras e econômicas.

Diversos estudos argumentam que a análise textual de documentos publicados pelo Banco Central é uma ferramenta eficaz para estudar a curva de juros ([Boukus e Rosenberg, 2006](#); [Lucca e Trebbi, 2009](#); [Chague et al., 2015](#)). Isso ocorre porque as comunicações da autoridade monetária fornecem informações que os agentes econômicos utilizam na precificação de ativos. Nesse contexto, a análise de sentimento aplicada a esses documentos se mostra relevante para compreender e explicar os movimentos da curva de juros, refletindo como as expectativas do mercado são moldadas pelo conteúdo dessas mensagens ([Boukus e Rosenberg, 2006](#); [Chague et al., 2015](#)).

Os autores [Andrade Alves et al. \(2023\)](#) propuseram uma abordagem para a previsão da curva de juros brasileira, utilizando o modelo Dinâmico de Nelson-

Siegel, que incorpora tanto variáveis macroeconômicas quanto fatores de sentimento derivados das comunicações do Banco Central do Brasil, presentes nas atas do Comitê de Política Monetária (COPOM). A pesquisa conclui que o sentimento expresso pelo Banco Central melhora a precisão previsão da estrutura a termo da curva de juros, influenciando tanto as taxas de juros de curto quanto de longo prazo.

De maneira semelhante, [Boukus e Rosenberg \(2006\)](#) analisaram a reação do mercado às políticas do Federal Reserve (Fed), com base nas atas das reuniões do Comitê Federal de Mercado Aberto (FOMC). O estudo teve como objetivo entender como o mercado interpreta as comunicações qualitativas presentes nas atas e as converte em medidas quantitativas. Utilizando a técnica de Análise Semântica Latente (LSA), foi possível identificar que as flutuações nos juros dos títulos estavam relacionadas aos temas abordados nos documentos.

As atas do FOMC, assim como as atas do COPOM no Brasil, são amplamente monitoradas pelo mercado e frequentemente citadas por analistas como um indicador essencial das políticas monetárias adotadas pelo Fed. Além de apresentar resumos das opiniões dos membros do comitê sobre as condições econômicas, essas atas também discutem a fundamentação das decisões de política monetária ([Danker e Luecke, 2005](#)).

## 1.1 Perguntas da Pesquisa

O sentimento negativo e o tom expressos nas atas do COPOM e do FOMC possuem informações para contribuir para a previsão da curva de juros no Brasil?

## 1.2 Justificativa

Dentre os vários motivos que leva os agentes econômicos a estudarem os movimentos da curva de juros, [Piazzesi \(2010\)](#) cita quatro razões principais, considerando a hipótese das expectativas. A primeira é a previsão, que serve como base para decisões de investimento das empresas, para a economia dos consumidores e para a elaboração da política monetária. Os juros de títulos de longo prazo representam os valores esperados das médias dos juros futuros de títulos de curto prazo, levando em conta o risco. Portanto, a curva de juros atual fornece informações sobre o futuro da economia.

O segundo motivo para estudar a curva de juros é a política monetária, com ela o banco central busca intervir na taxa de juros de curto prazo, que por sua vez pode impactar os juros de longo prazo, e assim influenciar na demanda agregada. Logo, um modelo de curva de juros que explique como funciona esse mecanismo de transmissão é muito importante para a economia.

A política de endividamento do governo é a terceira razão, pois à forma como o estado financia seu déficit orçamentário, decidindo se vai emitir mais ou menos títulos e em qual vencimento, pode influenciar movimentos das curvas.

A precificação de derivativos e estratégias de hedge representam quarta razão para estudar a estrutura a termo da taxa de juros. A precificação de instrumentos financeiros complexos, depende de modelos da curva de juros.

### 1.3 Objetivo

#### 1.3.1 Objetivo Geral

Investigar se o sentimento negativo e o tom expressos nas atas do Copom e do FOMC contêm informações relevantes para a predição da estrutura a termo das taxas de juros brasileiras. Para isso, utilizou-se o modelo dinâmico de Nelson-Siegel (DNS), amplamente empregado na literatura voltada à previsão da curva de juros. O modelo foi estimado por meio do filtro de Kalman, o que permite a estimação conjunta de todos os parâmetros em uma única etapa.

#### 1.3.2 Objetivos Específicos

Considerando o desenvolvimento do trabalho e o objetivo geral apresentado, destacam-se os seguintes objetivos específicos:

- Desenvolver uma análise de sentimento baseada no dicionário de Loughran e McDonald, categorizando os textos das atas em termos positivos, negativos e de incerteza;
- Estimar a curva de juros brasileira utilizando o modelo dinâmico de Nelson-Siegel, capturando a evolução dos fatores nível, inclinação e curvatura;
- Incorporar as variáveis textuais das atas do Copom e do FOMC ao modelo dinâmico de Nelson-Siegel para testar sua capacidade preditiva;
- Avaliar a performance do modelo ampliado (com variáveis textuais) em relação a versão tradicional, utilizando métricas de precisão, como RMSE, CSFE e teste Diebold-Mariano modificado, usando como *benchmark* o passeio aleatório;
- Investigar se o impacto das variáveis textuais varia entre diferentes prazos da curva de juros (curto, médio e longo prazo) e entre as atas do Copom e do FOMC.

## 2. Revisão da Literatura

### 2.1 Dados textuais

A previsão da curva de juros é um desafio central na economia e nas finanças, pois sua dinâmica reflete a interação entre expectativas de mercado, políticas monetárias e condições macroeconômicas. Tradicionalmente, modelos baseados em variáveis macroeconômicas, como inflação, PIB e taxa de juros, têm sido amplamente utilizados para capturar esses movimentos. No entanto, a crescente disponibilidade de dados textuais, como atas de reuniões de bancos centrais e comunicados oficiais, oferece uma nova dimensão para análise preditiva.

As medidas quantitativas da economia oferecem um importante indicador da política atual do banco central. No entanto, também existe muita informação qualitativas nas declarações, atas, discursos de funcionários e relatórios publicados pela instituição. Isso tem levado a um interesse tanto nas ações quanto nas palavras do banqueiro central, como uma ferramenta complementar para entender as decisões de política monetária futura.

Estudos recentes têm demonstrado que a comunicação dos bancos centrais, especialmente através de seus comunicados oficiais e atas de reuniões, exerce uma influência significativa sobre as expectativas do mercado, chegando a influenciar as taxas de juros no dia de sua publicação, sugerindo que uma comunicação mais clara e transparente pode tornar a política monetária mais previsível para os agentes econômicos [Costa Filho e Rocha \(2010\)](#).

[Woodford \(2005\)](#) e [Bernanke \(2004\)](#) destacam que a comunicação da autoridade monetária é um instrumento essencial da política monetária, pois influencia as expectativas do mercado, que por sua vez afetam decisões de consumo, poupança e investimento. Como a política monetária impacta diretamente as taxas de juros de curto prazo, enquanto as variáveis macroeconômicas relevantes dependem das taxas de juros de longo prazo, a comunicação dos bancos centrais desempenha um papel crucial na formação dessas expectativas. Isso ocorre porque as taxas de longo prazo refletem a trajetória esperada das taxas de curto prazo, tornando a transparência e previsibilidade da política monetária fatores determinantes na condução eficaz da política econômica.

Esses textos contêm informações qualitativas sobre a visão das autoridades monetárias, suas preocupações com a economia e potenciais mudanças na política monetária. A incorporação dessas informações aos modelos tradicionais permite explorar o impacto do tom e do sentimento expressos nesses documentos sobre a estrutura a termo da taxa de juros. Dessa forma, ao utilizar dados textuais, busca-se capturar os sinais qualitativos transmitidos pelos

formuladores de política monetária, aprimorando a capacidade de previsão da curva de juros.

Além disso, a análise de sentimentos aplicada aos comunicados do Banco Central permite mensurar o grau de incerteza ou confiança transmitido, o que pode impactar diretamente as expectativas dos agentes econômicos e a dinâmica da curva de juros. Estudos como o de [Silva et al. \(2020\)](#), mostram que a comunicação do Banco Central tem a capacidade de afetar variáveis macroeconômicas e influenciar a postura dos agentes econômicos, estando interligada ao contexto político.

O estudo de [Boukus e Rosenberg \(2006\)](#) identificou que a comunicação do *Federal Reserve* desempenha um papel essencial na formação das expectativas de mercado e na determinação da estrutura a termo da taxa de juros. Para quantificar essa influência, os autores utilizaram técnicas estatísticas, como a Análise Semântica Latente (LSA), que permite extrair temas latentes das atas do FOMC por meio da decomposição singular de matrizes de frequência de palavras. Esses temas são interpretados a partir dos termos que os compõem e de sua correlação com indicadores macroeconômicos e financeiros.

A análise da reação do mercado de *Treasuries* no momento da divulgação das atas indica que as variações nas taxas de juros estão associadas aos temas expressos nos documentos, ao nível de incerteza da política monetária e às condições econômicas vigentes. Esses resultados sugerem que os participantes do mercado conseguem extrair um sinal informacional complexo e multifacetado das comunicações do FOMC, impactando diretamente a precificação dos ativos financeiros.

Nos estudos em finanças, a análise textual tem sido amplamente utilizada para examinar o tom e o sentimento em diversas fontes de informação, como relatórios corporativos, artigos de jornais, comunicados de imprensa e discussões entre investidores. Uma das abordagens mais relevantes nesse campo foi proposta por [Loughran e McDonald \(2011\)](#), que desenvolveram um dicionário financeiro específico para o contexto de análises de sentimento. Onde foi adaptado um dicionário de sentimentos originalmente desenvolvido para o campo da psicologia, com o objetivo de categorizar de maneira mais apropriada o sentimento de textos financeiros.

Ao analisar relatórios da *Securities and Exchange Commission* (SEC) entre 1994 e 2008, o estudo criou um dicionário composto por 85.131 palavras, classificadas em diversas categorias de sentimento, como positivo, negativo, incerto, litigioso e restritivo, oferecendo uma abordagem mais sofisticada para o entendimento do conteúdo dos documentos.

O dicionário de Loughran e McDonald se distingue de outros modelos

por permitir que uma palavra seja classificada simultaneamente em múltiplas categorias de sentimento. Por exemplo, palavras como "*anomaly*", "*doubt*," e "*deviate*" podem ser vistas como negativas e incertas ao mesmo tempo, refletindo a complexidade do discurso financeiro. Esse modelo possibilita uma análise mais rica e nuançada, onde 2.355 palavras são identificadas como negativas, 354 como positivas e 297 como relacionadas à incerteza. Essa flexibilidade na classificação das palavras permite capturar a ambiguidade presente nos relatórios financeiros e na comunicação de empresas, oferecendo insights mais profundos sobre como os participantes do mercado podem interpretar tais documentos.

Ao aplicar o dicionário de Loughran e McDonald, é possível realizar uma análise mais precisa da linguagem utilizada em textos financeiros, capturando sentimentos que influenciam as decisões de mercado. Essa ferramenta não só permite interpretar o tom das mensagens, mas também oferece informações quantitativas que podem ser usadas para modelar comportamentos de mercado e prever reações a eventos corporativos e econômicos. Quando utilizada para classificar e analisar as atas dos bancos centrais e outros comunicados, essa abordagem se torna uma ferramenta para entender como as mudanças na política monetária e a incerteza econômica são transmitidas e interpretadas pelos investidores, moldando a formação de expectativas e impactando a precificação dos ativos financeiros.

Diversos estudos demonstram que o sentimento negativo possui maior relevância na análise de textos relacionados a assuntos econômicos e financeiros. Por exemplo, [Tetlock \(2007\)](#) mostrou que o sentimento negativo extraído de fontes de mídia tem um forte impacto nas expectativas dos investidores, evidenciando que componentes negativos são particularmente poderosos na explicação dos movimentos do mercado. De forma semelhante, [Bholat et al. \(2015\)](#) apontam, em seu estudo sobre a comunicação dos bancos centrais, que a análise de sentimento – especialmente o componente negativo – apresenta elevada capacidade preditiva para captar os efeitos econômicos das mensagens divulgadas. Além disso, [Loughran e McDonald \(2011\)](#), embora tenham se concentrado em divulgações financeiras, ressaltam que os termos negativos exercem um efeito preponderante na interpretação textual, sendo, portanto, passíveis de extrapolação para contextos de comunicação econômica.

Portanto, integrar dados textuais provenientes da comunicação oficial dos bancos centrais pode aprimorar os modelos de previsão da curva de juros, proporcionando uma compreensão mais abrangente das expectativas do mercado e auxiliando na implementação de políticas econômicas mais eficazes.

## 2.2 Processamento de Linguagem Natural

O Processamento de Linguagem Natural (PLN), também conhecida como mineração de texto, é empregada para compreender, interpretar e simular a linguagem natural humana por meio de técnicas que incorporam algoritmos, métodos estatísticos e aprendizado de máquina. Embora não seja uma tecnologia nova, o PLN tem evoluído significativamente devido ao interesse em aprimorar a interação entre humanos e máquinas (Vajjala et al., 2020).

O PLN é uma ferramenta computacional que utiliza técnicas estatísticas para quantificar textos. Semelhante à leitura humana, busca extrair significado de sequências de palavras. No entanto, diferencia-se principalmente por sua capacidade de processar grandes volumes de informação com muito mais rapidez do que uma pessoa e por identificar padrões sutis que poderiam passar despercebidos por um ser humano devido a crenças e expectativas prévias.

Em diversos setores, PLN tem sido fundamental para otimizar processos e melhorar a interação com o usuário. Exemplos dessa aplicação incluem:

- Plataformas de e-mail, que utilizam PLN para classificação de spam, caixa de entrada prioritária, extração de eventos de calendário, preenchimento automático, entre outros.
- Assistentes de voz, que dependem de uma variedade de técnicas de PLN para interagir com o usuário, compreender comandos e responder adequadamente.
- Motores de busca modernos, que fazem uso intensivo de PLN para diversas subtarefas, como compreensão de consulta, expansão de consulta, resposta a perguntas, recuperação de informações, e classificação e agrupamento de resultados.
- Serviços de tradução automática.
- Análise de sentimento, usada para identificar o sentimento de um trecho de texto (por exemplo, se é positivo, negativo ou neutro).

O PLN aplicado a análise de sentimentos é amplamente utilizada em áreas como ciência política e *marketing* e tem ganhado cada vez mais destaque na economia, especialmente em análises realizadas por bancos centrais.

segundo Bholat et al. (2015) a análise textual como dado quantitativo não é algo intuitivo, e a abundância de dados naturalmente numéricos sempre favoreceu métodos tradicionais, dificultando a consolidação da mineração de texto como uma ferramenta amplamente aceita para análises macroeconômicas.

O avanço e a consolidação dessa técnica enfrentam desafios, pois muitos economistas e profissionais de bancos centrais não estão acostumados a tratar textos como dados quantitativos. Mesmo quando conhecem a técnica, podem preferir dados numéricos tradicionais, já que a conversão de textos exige o aprendizado de novas ferramentas e pode, à primeira vista, parecer pouco vantajosa.

No entanto, a mineração de texto tem avançado no campo econômico, pois essas técnicas permitem o processamento de uma grande quantidade de dados essenciais para avaliar a estabilidade monetária e financeira. Fontes textuais podem incluir artigos de notícias, contratos financeiros, mídias sociais, pesquisas de mercado e diversos tipos de relatórios. Esses documentos podem ser analisados individualmente ou como parte de um conjunto maior (*corpus*), proporcionando uma visão mais abrangente das informações.

### 3. Metodologia

#### 3.1 Modelo de Nelson-Siegel Dinâmico

Na versão estática do modelo de [Nelson e Siegel \(1987\)](#), a curva de juros  $y(\tau)$  pode ser vista como uma combinação linear das variáveis  $(1, \frac{1-e^{-\lambda\tau}}{\lambda\tau}, \frac{1-e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau})$ , onde os coeficientes  $\beta_1, \beta_2, \beta_3$  e o parâmetro  $\lambda$  são fixados para um dado instante  $t$ . No entanto, para capturar a dinâmica temporal da estrutura a termo das taxas de juros, adotamos uma formulação em que os fatores latentes  $\beta_1, \beta_2, \beta_3$  evoluem ao longo do tempo e o parâmetro  $\lambda$  permanece fixo, conforme proposto por [Diebold e Li \(2006\)](#). Assim, considerando que para cada maturidade  $\tau$  há uma série temporal observada, a equação pode ser representada como:

$$y_t(\tau) = \beta_{1t} + \beta_{2t} \left( \frac{1 - e^{-\lambda_t \tau}}{\lambda_t \tau} \right) + \beta_{3t} \left( \frac{1 - e^{-\lambda_t \tau}}{\lambda_t \tau} - e^{-\lambda_t \tau} \right). \quad (1)$$

Dessa forma, enquanto no modelo estático os coeficientes  $\beta_1, \beta_2$  e  $\beta_3$  são tratados como constantes, no modelo dinâmico eles passam a variar ao longo do tempo. Ao combinar essa evolução temporal com a estrutura espacial da curva de juros, obtém-se o modelo Nelson-Siegel Dinâmico (DNS), conforme descrito por [Diebold e Rudebusch \(2013\)](#).

No modelo de [Diebold e Li \(2006\)](#), o parâmetro  $\lambda$  é mantido constante, enquanto os coeficientes  $\beta_{1t}, \beta_{2t}$  e  $\beta_{3t}$  são ajustados por meio do método de mínimos quadrados ordinários em cada período. Esse procedimento simplifica

a aplicação do modelo, possibilitando uma estimativa das taxas de juros em diferentes maturidades, desde que haja dados disponíveis em quantidade suficiente para o período analisado. Já em [Diebold et al. \(2006\)](#), o parâmetro  $\lambda$  é estimado junto com os demais coeficientes. Isso aumenta a flexibilidade do modelo para ajustar melhor a curva de juros.

Neste trabalho, utilizamos a estrutura autoregressiva proposta por [Diebold e Li \(2006\)](#), sendo estimada por meio da abordagem clássica. O estimador de máxima verossimilhança é aplicado utilizando a decomposição do erro de predição obtido por meio do Filtro de Kalman, conforme sugerido por [Diebold et al. \(2006\)](#).

Além disso, o parâmetro  $\lambda$  foi inicialmente fixado em 0.0609 para a construção da base de fatores da estrutura a termo. Durante o processo de estimação, os coeficientes  $\beta_{1t}$ ,  $\beta_{2t}$  e  $\beta_{3t}$  e o parâmetro  $\lambda$  foram estimados dentro do modelo de espaço de estados por meio do filtro de Kalman, permitindo sua adaptação às dinâmicas da estrutura a termo ao longo do tempo de forma eficiente. Essa abordagem garante maior flexibilidade na modelagem da curva de juros, incorporando variações tanto nos fatores quanto na taxa de decaimento  $\lambda$ .

### 3.1.1 Modelo de fatores

O modelo DNS pode ser considerado um modelo de fatores dinâmicos, onde um grande número de variáveis (taxas de juros para diferentes maturidades) é explicado por um número reduzido de variáveis de estado latentes (nível, inclinação e curvatura). Além disso, devido à semelhança entre os pesos  $\left(1, \frac{1-e^{-\lambda\tau}}{\lambda\tau}, \frac{1-e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau}\right)$  que multiplicam os parâmetros  $\beta_1, \beta_2, \beta_3$  e os autovetores dos três primeiros componentes principais do trabalho do [Litterman e Scheinkman \(1991\)](#), é possível inferir que os coeficientes  $\beta_{1t}$ ,  $\beta_{2t}$  e  $\beta_{3t}$  controlam, respectivamente, o nível, a inclinação e a curvatura da curva de juros.

Podemos reformular o modelo DNS destacando a interpretação dos fatores de nível, inclinação e curvatura, conforme a notação proposta por [Diebold et al. \(2006\)](#):

$$y_t(\tau) = L_t + S_t \left( \frac{1 - e^{-\lambda\tau}}{\lambda\tau} \right) + C_t \left( \frac{1 - e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau} \right), \quad (2)$$

$$t = 1, \dots, T \text{ e } \tau = 1, \dots, N.$$

Incluindo um termo de erro estocástico, chega-se à equação de medida,

que relaciona estocasticamente o conjunto de taxas de juros observáveis com os três fatores latentes do modelo. Assim, a equação que conecta  $N$  curvas de juros aos três fatores não observáveis é dada por:

$$\begin{bmatrix} y_t(\tau_1) \\ y_t(\tau_2) \\ \vdots \\ y_t(\tau_N) \end{bmatrix} = \begin{bmatrix} 1 & \frac{1-e^{-\lambda-\tau_1}}{\lambda\tau_1} & \frac{1-e^{-\lambda-\tau_1}}{\lambda\tau_1} - e^{-\lambda-\tau_1} \\ 1 & \frac{1-e^{-\lambda-\tau_2}}{\lambda\tau_2} & \frac{1-e^{-\lambda-\tau_2}}{\lambda\tau_2} - e^{-\lambda-\tau_2} \\ \vdots & \vdots & \vdots \\ 1 & \frac{1-e^{-\lambda-\tau_N}}{\lambda\tau_N} & \frac{1-e^{-\lambda-\tau_N}}{\lambda\tau_N} - e^{-\lambda-\tau_N} \end{bmatrix} \begin{bmatrix} L_t \\ S_t \\ C_t \end{bmatrix} + \begin{bmatrix} \varepsilon_t(\tau_1) \\ \varepsilon_t(\tau_2) \\ \vdots \\ \varepsilon_t(\tau_N) \end{bmatrix}. \quad (3)$$

Os parâmetros  $L_t$ ,  $S_t$  e  $C_t$ , representam os parâmetros variáveis no tempo  $\beta_1, \beta_2, \beta_3$  e sua dinâmica pode ser modelada por um processo autorregressivo de primeira ordem, formando um sistema de espaço de estado. A equação de transição descreve a evolução do vetor de estado:

$$\begin{bmatrix} L_t - \mu_L \\ S_t - \mu_S \\ C_t - \mu_C \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \begin{bmatrix} L_{t-1} - \mu_L \\ S_{t-1} - \mu_S \\ C_{t-1} - \mu_C \end{bmatrix} + \begin{bmatrix} \eta_t^L \\ \eta_t^S \\ \eta_t^C \end{bmatrix}, \quad (4)$$

$$t = 1, \dots, T$$

Em notação vetorial/matricial, o sistema de espaço de estados pode ser escrito da seguinte forma:

Equação de medida:

$$y_t = \Lambda f_t + \varepsilon_t, \quad (5)$$

com:

$$y_t = \begin{bmatrix} y_t(\tau_1) \\ y_t(\tau_2) \\ \vdots \\ y_t(\tau_N) \end{bmatrix}, \quad f_t = \begin{bmatrix} l_t \\ s_t \\ c_t \end{bmatrix}, \quad \varepsilon_t = \begin{bmatrix} \varepsilon_t(\tau_1) \\ \varepsilon_t(\tau_2) \\ \vdots \\ \varepsilon_t(\tau_N) \end{bmatrix}, \quad \Lambda = \begin{bmatrix} 1 & \frac{1-e^{-\lambda\tau_1}}{\lambda\tau_1} & \frac{1-e^{-\lambda\tau_1}}{\lambda\tau_1} - e^{-\lambda\tau_1} \\ 1 & \frac{1-e^{-\lambda\tau_2}}{\lambda\tau_2} & \frac{1-e^{-\lambda\tau_2}}{\lambda\tau_2} - e^{-\lambda\tau_2} \\ \vdots & \vdots & \vdots \\ 1 & \frac{1-e^{-\lambda\tau_N}}{\lambda\tau_N} & \frac{1-e^{-\lambda\tau_N}}{\lambda\tau_N} - e^{-\lambda\tau_N} \end{bmatrix},$$

onde  $\Lambda$  é a matriz de parâmetros.

Equação de transição:

$$(f_t - \mu) = A(f_{t-1} - \mu) + \eta_t, \quad (6)$$

onde:

$$f_t = \begin{bmatrix} L_t \\ S_t \\ C_t \end{bmatrix}, \quad \eta_t = \begin{bmatrix} \eta_t^L \\ \eta_t^S \\ \eta_t^C \end{bmatrix}, \quad \mu = \begin{bmatrix} \mu_L \\ \mu_S \\ \mu_C \end{bmatrix}, \quad A = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}.$$

Onde  $f_t$  é um vetor de variáveis latentes (composto por  $L_t$ ,  $S_t$  e  $C_t$ ),  $\eta_t$  é um vetor de erros estocásticos que afetam a evolução dos fatores, e  $\mu$  e  $A$  são parâmetros do processo de transição.

Para finalizar a formulação do sistema, é necessário definir a estrutura de covariância das equações 5 e 6. A abordagem tradicional assume que os erros nas equações de medição e transição são ruído branco, sendo ortogonais tanto entre si quanto em relação ao estado inicial. No contexto da otimização linear de mínimos quadrados do filtro de Kalman, essa suposição garante que o ruído branco de transição e os distúrbios de medição sejam independentes entre si e também ortogonais ao estado inicial.

$$\begin{bmatrix} \varepsilon_t \\ \eta_t \end{bmatrix} \sim \text{WN} \left( \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} Q & 0 \\ 0 & H \end{bmatrix} \right), \quad (7)$$

$$E(f_0 \varepsilon_t') = 0, \quad (8)$$

$$E(f_0 \eta_t') = 0. \quad (9)$$

### 3.1.2 Modelo de curva de juros com dados textuais das atas do COPOM e da FOMC

O modelo com dados textuais utilizou duas variáveis para capturar a informação com potencial preditivo presente nas atas dos bancos centrais analisados. A primeira variável corresponde ao sentimento negativo, que reflete a incidência de termos com conotação desfavorável nos documentos. A segunda variável considera o tom do documento, uma métrica agregada que busca capturar a orientação geral da comunicação dos bancos centrais, permitindo uma avaliação mais ampla do conteúdo textual.

De acordo com [Vajjala et al. \(2020\)](#), a análise de sentimento, também conhecida como mineração de opinião, é uma área da inteligência artificial e processamento de linguagem natural que se concentra em identificar, extrair e

entender as emoções, opiniões e atitudes expressas em texto. Essa técnica é comumente aplicada a grandes volumes de dados textuais, como avaliações de produtos, comentários em redes sociais, análises de notícias e outras formas de textos.

A abordagem utilizada para a análise de sentimento é a heurística, que utiliza dicionários e enciclopédias. Um exemplo é a análise de sentimento baseada em léxico. Ela utiliza contagens de palavras positivas, negativas ou neutras no texto para deduzir o sentimento do texto. Além disso, esses dicionários contém as palavras e as relações semânticas entre elas, como sinônimos, hipônimos e merônimos.

Para a análise de sentimento dos comunicados da autoridade monetária, adotamos o método empregado em [Andrade Alves et al. \(2023\)](#). Esse método consiste na classificação de todas as palavras de cada comunicação do Banco Central com base no dicionário financeiro de [Loughran e McDonald \(2011\)](#), seguida do cálculo do sentimento do documento.

O sentimento de cada documento é determinado pela proporção de palavras em cada categoria em relação ao total de palavras no texto:

$$s_{\ell,t} \equiv \frac{\text{Palavras da categoria}}{\text{Total de palavras}}, \quad (10)$$

onde  $\ell \in$  positivo, negativo, neutro.

Para a previsão, utilizou-se apenas o sentimento negativo, em linha com a literatura [tetlock2007giving](#), [bholat2015centre](#), [loughran2011liability](#), que aponta esse componente como o mais relevante na interpretação do sentimento dos textos e o que apresenta maior poder explicativo sobre o impacto das comunicações nas expectativas econômicas.

A segunda variável utilizada é o Tom do documento, conforme a definição de ([Cannon, 2015](#)):

$$\tau_t = \frac{\text{Palavras positivas} - \text{Palavras negativas}}{\text{Palavras positivas} + \text{Palavras negativas}}, \quad (11)$$

onde, se  $\tau_t > 0$ , o documento apresenta um tom positivo; se  $\tau_t < 0$ , o tom é negativo; e, caso contrário, o tom é considerado neutro.

A estimativa do sentimento foi realizada tanto para as comunicações do COPOM quanto para as do FOMC, permitindo avaliar se o tom das atas do Banco Central do Brasil e do *Federal Reserve* contribui para a previsão da curva de juros brasileira.

O modelo de fatores com dados textuais que foi utilizado é uma adaptação do modelo de [Diebold e Rudebusch \(2013\)](#) que além do fatores latentes da curva — nível, inclinação e curvatura — foi incluído fatores macroeconômicos, como a inflação, a atividade econômica e o instrumento de política monetária.

A incorporação de variáveis macroeconômicas ao modelo é realizada por meio de uma modificação na equação de transição dos estados, permitindo a inclusão de variáveis exógenas além do componente autorregressivo. Essa abordagem possibilita capturar a influência de fatores econômicos sobre a dinâmica dos componentes latentes da curva de juros. A equação de transição ajustada é dada por:

$$(f_t - \mu) = A(f_{t-1} - \mu) + BX_{t-1} + \eta_t, \quad (12)$$

onde  $X$  representa um vetor contendo as  $n$  variáveis macroeconômicas disponíveis no instante  $t - 1$ , enquanto  $B$  é uma matriz de coeficientes de dimensões  $3 \times n$ , que quantifica o impacto dessas variáveis sobre os fatores latentes. A equação de medição e a matriz de covariância dos erros permanecem inalteradas em relação à formulação original, garantindo a consistência do modelo na estimativa da estrutura a termo da taxa de juros.

Para incorporar as variáveis textuais ao modelo, é necessário modificar novamente a equação de transição dos estados proposta por [diebold2013yield](#), substituindo as variáveis macroeconômicas por variáveis exógenas extraídas dos dados textuais, além dos componentes autorregressivos. Assim, a equação ajustada é dada por:

$$(f_t - \mu) = A(f_{t-1} - \mu) + CS_{t-1} + \eta_t, \quad (13)$$

onde  $S_{t-1}$  representa as variáveis textuais extraídas das atas, e  $C$  é a matriz de coeficientes que mede seu impacto sobre os fatores latentes. Essas modificações permitem que o modelo integre informações dos textos das comunicações do COPOM e do FOMC, possibilitando avaliar sua influência na dinâmica da estrutura a termo da taxa de juros.

#### 4. Especificação do modelo

Foi utilizado o modelo dinâmico de Nelson e Siegel para a previsão da curva de juros, com base nos fatores latentes de nível, inclinação e curvatura, representados por  $\beta_{1,t}$ ,  $\beta_{2,t}$  e  $\beta_{3,t}$ , respectivamente. O rendimento no vencimento  $m$ , no período  $t$ , pôde ser aproximado por:

$$y_t(m) = \beta_{1,t} + \beta_{2,t} \left( \frac{1 - e^{-\lambda m}}{\lambda m} \right) + \beta_{3,t} \left( \frac{1 - e^{-\lambda m}}{\lambda m} - e^{-\lambda m} \right) + \eta_t, \quad (14)$$

onde  $\eta_t$  tem uma distribuição normal com média zero e variância dado por  $\sigma_\eta^2$ .

Como  $\beta_{it}$ , para  $i \in \{1, 2, 3\}$ , não é observável, precisamos encontrar a melhor estimativa possível desses fatores latentes para prever com precisão a curva de juros. Além da estrutura autorregressiva proposta por Diebold e Li (2006), incluiremos as variáveis textuais das comunicações do COPOM e do FOMC conforme [Andrade Alves et al. \(2023\)](#).

$$\beta_{i,t} = c_i + \phi_i \beta_{i,t-1} + \alpha_i S_t + \varepsilon_{i,t}, \quad (15)$$

onde  $\varepsilon_{i,t}$  tem uma distribuição normal com média zero e variância dado por  $\sigma_i^2$ ,  $S_t$  é o vetor de variáveis dos dados textuais, podendo ser o sentimento negativo do COPOM, sentimento negativo do FOMC, tom do COPOM ou tom do FOMC.

Para avaliar o impacto dos dados textuais na previsão da curva de juros, estimamos diferentes especificações do modelo, incluindo versões sem variáveis textuais e outras que incorporam diferentes medidas de sentimento extraídas das comunicações do COPOM e do FOMC. A Tabela 1 apresenta os modelos considerados.

**Tabela 1**  
**Especificações dos modelos concorrentes**

Modelo	Dados textuais
<i>Random Walk</i>	Sem dados textuais
Modelo I	Sem dados textuais
Modelo II	Sentimento negativo — Copom
Modelo III	Sentimento negativo — FOMC
Modelo IV	Tom — Copom
Modelo V	Tom — FOMC

Fonte: Elaborada pelo autor.

Dada a reconhecida competitividade do modelo de passeio aleatório, especialmente em previsões de curto prazo, conforme destacado por [Joslin et al. \(2011\)](#), ele será utilizado como benchmark na análise para comparar os modelos propostos. O passeio aleatório é considerado um concorrente desafiador na previsão da curva de juros, como afirmam [Diebold e Li \(2006\)](#) e [Vicente e Tabak \(2008\)](#), que destacam que o modelo DNS tende a apresentar melhor

desempenho apenas em horizontes mais longos. De forma similar, [Caldeira e Torrent \(2017\)](#) constatam que o DNS superou o passeio aleatório apenas para vencimentos superiores a 36 meses na previsão da curva de juros dos EUA.

Os Modelos I a V foram estimados por meio do filtro de Kalman, seguindo a abordagem de [Diebold et al. \(2006\)](#). Essa metodologia permite uma estimação eficiente dos fatores latentes da estrutura a termo da taxa de juros.

## 4.1 Aplicação empírica

Utilizamos dados mensais da estrutura a termo da taxa de juros brasileira, com taxas de rendimento para diferentes maturidades. O período analisado compreende 252 observações de janeiro de 2004 até dezembro de 2024, divididas em 181 observações para treinamento, de janeiro de 2004 até janeiro de 2019 e 71 observações para teste, de fevereiro de 2019 até dezembro de 2024.

Foi utilizado o método Spline Cúbico — um tipo de spline polinomial — para interpolar os dados e calcular as taxas não observadas em determinados dias. Essa técnica é amplamente empregada quando se busca uma transição suave entre os pontos de dados conhecidos, utilizando funções de terceiro grau para conectar cada par de pontos consecutivos. A principal vantagem dos splines cúbicos é que eles garantem a continuidade das primeiras e segundas derivadas da função interpoladora, o que resulta em uma curva suave e sem quebras abruptas entre os pontos ([Mishra et al., 2024](#)).

Esse método é particularmente útil na interpolação de curvas de juros, permitindo estimar taxas de juros para maturidades não observadas, mas que seguem uma tendência contínua. Em termos práticos, dada uma série de taxas de juros observadas em algumas maturidades específicas, o spline cúbico ajusta uma função polinomial que passa por esses pontos e permite a estimativa de taxas para as maturidades intermediárias.

### 4.1.1 Modelo de Nelson-Siegel Dinâmico (DNS)

O modelo de Nelson e Siegel Dinâmico foi estimado seguindo a abordagem em dois passos proposta por [Diebold et al. \(2006\)](#). Primeiramente, os fatores latentes da estrutura a termo ( $\beta_1$ ,  $\beta_2$  e  $\beta_3$ ) foram estimados por meio de regressões lineares múltiplas, conforme representado na equação (14), com  $\eta_t$  representando o termo de erro. Para tal, construiu-se a matriz de regressores  $X$ , cuja forma depende da maturidade  $m$  e de um parâmetro de decaimento fixado inicialmente em  $\lambda_0 = 0,0609$ .

A matriz  $X$  possui a seguinte estrutura para cada período  $t$ :

$$X = \begin{bmatrix} 1 & \frac{1-e^{-\lambda_0 m_1}}{\lambda_0 m_1} & \left( \frac{1-e^{-\lambda_0 m_1}}{\lambda_0 m_1} - e^{-\lambda_0 m_1} \right) \\ 1 & \frac{1-e^{-\lambda_0 m_2}}{\lambda_0 m_2} & \left( \frac{1-e^{-\lambda_0 m_2}}{\lambda_0 m_2} - e^{-\lambda_0 m_2} \right) \\ \vdots & \vdots & \vdots \\ 1 & \frac{1-e^{-\lambda_0 m_n}}{\lambda_0 m_n} & \left( \frac{1-e^{-\lambda_0 m_n}}{\lambda_0 m_n} - e^{-\lambda_0 m_n} \right) \end{bmatrix}$$

onde  $m_1, m_2, \dots, m_n$  representam as diferentes maturidades utilizadas na estimação.

Essa matriz foi utilizada como base para estimar os coeficientes  $\beta_t = (\beta_{1,t}, \beta_{2,t}, \beta_{3,t})'$  em cada período  $t$ , o que permitiu acompanhar a dinâmica temporal dos fatores latentes da estrutura a termo da taxa de juros.

No segundo estágio, a dinâmica temporal dos fatores latentes foi modelada por meio de um modelo Vetorial Autorregressivo de primeira ordem, VAR(1), de forma a capturar a evolução conjunta dos fatores ao longo do tempo:

$$\beta_t = c + \Phi \beta_{t-1} + \varepsilon_t, \quad (16)$$

onde  $c$  é o vetor de interceptos,  $\Phi$  é a matriz de coeficientes do modelo VAR, e  $\varepsilon_t$  representa o erro residual do processo. O modelo foi estimado utilizando o pacote `varm` do MATLAB.

As estimativas do modelo VAR forneceram os parâmetros iniciais para a formulação do modelo espaço-estado, conforme proposto por [Diebold e Li \(2006\)](#). Essa estrutura permite incorporar as incertezas associadas tanto à dinâmica dos fatores quanto aos erros de medição dos rendimentos, sendo os resíduos do primeiro estágio utilizados como proxy para a matriz de covariância  $H$  do componente de medição.

A estimação foi realizada por meio do Filtro de Kalman, que possibilita a extração de estados latentes não observáveis a partir da série de rendimentos. Essa abordagem refinou a modelagem dinâmica dos fatores latentes da estrutura a termo, permitindo a suavização dos betas e contribuindo para a melhora na acurácia das previsões da curva de juros.

#### 4.1.2 Definição do Modelo Espaço-Estado

O modelo espaço-estado é composto por duas equações principais: a equação de transição, que descreve a evolução dos fatores latentes ao longo do tempo, e a equação de observação, que relaciona os fatores latentes com as taxas de juros observadas.

**Equação de Transição:** A evolução dos fatores latentes ao longo do tempo é descrita por um processo autorregressivo, onde a matriz de transição  $A$  governa a dinâmica dos estados:

$$\alpha_t = A\alpha_{t-1} + B\eta_t, \quad \eta_t \sim \mathcal{N}(0, Q), \quad (17)$$

onde:

- $\alpha_t$  representa o vetor de fatores latentes no instante  $t$ ;
- $A$  é a matriz de transição de estados, obtida a partir da estimação do modelo VAR(1);
- $B$  é a matriz que captura a variância dos choques nos fatores latentes;
- $\eta_t$  é um vetor de perturbações normalmente distribuídas com covariância  $Q$ .

A matriz de transição  $A$  foi estimada por meio da matriz de coeficientes do modelo VAR ajustado aos fatores latentes obtidos na primeira etapa da estimação.

**Equação de Observação:** A relação entre os fatores latentes e as taxas de juros observadas é dada pela equação de medição:

$$y_t = C\alpha_t + D\varepsilon_t, \quad \varepsilon_t \sim \mathcal{N}(0, H), \quad (18)$$

onde:

- $y_t$  representa o vetor de taxas de juros observadas para diferentes maturidades no instante  $t$ ;
- $C$  é a matriz de carga (*loadings*), que define como os fatores latentes afetam as taxas de juros;
- $D$  é uma matriz diagonal que captura a variância dos erros de medição;
- $\varepsilon_t$  representa o erro de medição, assumido como normalmente distribuído com variância  $H$ .

A matriz de carga  $C$  foi definida de acordo com a formulação do modelo de Nelson-Siegel, enquanto a matriz de covariância dos erros  $H$  foi estimada a partir dos resíduos do modelo de regressão OLS da primeira etapa.

Os parâmetros iniciais do modelo espaço-estado foram definidos a partir das estimativas do modelo VAR(1), que capturam a dinâmica temporal dos fatores latentes. A maximização da verossimilhança do modelo foi realizada utilizando o algoritmo de otimização `fminunc` do MATLAB, com método *quasi-Newton*, garantindo maior precisão na estimação.

A estimação dos parâmetros iniciais do modelo espaço-estado foi realizada por meio da maximização da função de verossimilhança. Para isso, utilizamos o algoritmo de máxima verossimilhança para encontrar os parâmetros que melhor explicam os dados observados. A função de verossimilhança mede a probabilidade de observar os dados dos parâmetros do modelo, e sua maximização permite estimar os parâmetros com maior probabilidade de gerar os dados.

A otimização foi feita com o algoritmo `fminunc` no MATLAB, que minimiza funções não-lineares sem a necessidade de derivadas explícitas. Esse algoritmo é adequado para a maximização de verossimilhança em modelos não-lineares como o espaço-estado. A escolha do método *quasi-Newton*, especificamente o algoritmo BFGS, deve-se à sua eficiência em aproximar derivadas segundas de funções de alta dimensão.

Ajustamos as tolerâncias de convergência para garantir a precisão da solução, controlando quando o algoritmo considera que a otimização foi concluída. Isso evita que o algoritmo pare prematuramente ou continue a iterar desnecessariamente.

Ao final, os parâmetros do modelo foram ajustados para maximizar a verossimilhança, gerando uma estimativa precisa que foi utilizada para a filtragem e suavização dos estados latentes com o Filtro de Kalman. Esse processo garantiu que as estimativas dos parâmetros fossem consistentes com os dados e que o modelo capturasse adequadamente as dinâmicas dos fatores latentes na previsão da curva de juros.

Para a estimação dos estados latentes, utilizamos o Filtro de Kalman, que consiste em duas etapas principais:

**Passo de Previsão:** Antes da observação da nova taxa de juros, o estado latente é projetado para o próximo período:

$$\hat{\alpha}_{t|t-1} = A\hat{\alpha}_{t-1|t-1}, \quad (19)$$

e a incerteza associada ao estado é atualizada conforme:

$$P_{t|t-1} = AP_{t-1|t-1}A' + BQB' \quad (20)$$

Passo de Atualização: Após a observação das taxas de juros no período  $t$ , o estado latente é atualizado para incorporar a nova informação:

$$\hat{\alpha}_{t|t} = \hat{\alpha}_{t|t-1} + K_t(y_t - C\hat{\alpha}_{t|t-1}), \quad (21)$$

onde  $K_t$  é o ganho de Kalman, calculado como:

$$K_t = P_{t|t-1}C'(CP_{t|t-1}C' + H)^{-1}. \quad (22)$$

A matriz de covariância do estado latente também é atualizada:

$$P_{t|t} = (I - K_tC)P_{t|t-1}. \quad (23)$$

Após a aplicação do Filtro de Kalman, utilizamos o suavizador de Kalman para melhorar a estimação dos estados passados, reduzindo a variância da estimativa e aprimorando as previsões.

#### 4.1.3 Previsões fora da amostra

As previsões fora da amostra foram realizadas com a metodologia de origem rolante (*rolling-origin*) com janela em expansão, que ajusta o modelo a cada nova observação, capturando a dinâmica temporal e a incerteza das previsões de longo prazo (Tashman, 2000). O modelo foi treinado com um conjunto de dados atualizado a cada iteração, gerando previsões para 13 maturidades de 12 meses subsequentes, ao longo de 60 origens.

A base de dados, com 252 observações, foi dividida em 181 observações para treino e 71 para teste. A cada iteração, um novo ponto de origem foi selecionado, expandindo os dados de treinamento com uma nova observação, e o modelo foi reestimado. Esse processo gerou previsões dinâmicas para as 13 maturidades.

Os estados suavizados do modelo espaço-estado, obtidos pelo Filtro de Kalman, foram usados para projetar a curva de juros futura, incorporando as informações mais recentes. Esses estados ajustam os fatores latentes que determinam a estrutura a termo das taxas de juros, aprimorando a precisão das previsões.

Desse modo, a estratégia de origem rolante com janela em expansão permitiu gerar previsões adaptativas e consistentes com as mudanças nas condições econômicas, refletindo as variações temporais dos dados e a evolução da curva de juros ao longo do tempo.

#### 4.1.4 Cálculo do RMSE

A raiz do erro quadrático médio (RMSE) foi calculado para avaliar a precisão das previsões da estrutura a termo para diferentes maturidades e horizontes de previsão. O cálculo do RMSE foi realizado para as combinações de maturidade e horizonte de previsão definidos conforme [Andrade Alves et al. \(2023\)](#). O procedimento foi implementado conforme descrito a seguir:

1. Definição dos Horizontes de Previsão e Maturidades: Para a avaliação do modelo, foram considerados quatro horizontes de previsão: 1, 3, 6 e 12 meses. Além disso, foram analisadas 13 maturidades distintas, cobrindo uma ampla gama de prazos: 3, 6, 9, 12, 15, 18, 21, 24, 30, 36, 42, 48 e 60 meses, com o objetivo de representar tanto os títulos de curto prazo quanto os de médio e longo prazos. A base de dados utilizada para treinamento abrangeu o período de janeiro de 2004 a janeiro de 2019, enquanto a base de teste foi composta pelos dados de fevereiro de 2019 a dezembro de 2024. O número de origens de previsão foi fixado em 60, permitindo a análise de uma sequência robusta de previsões para cada maturidade e horizonte de previsão.

2. Cálculo do RMSE: Para cada modelo  $l$ , a raiz do erro quadrático médio foi calculado para cada combinação de maturidade e horizonte de previsão, considerando todas as origens de previsão. O erro foi obtido pela diferença entre o valor previsto ( $\hat{y}$ ) e o valor real observado ( $y$ ). A fórmula do RMSE foi aplicada da seguinte forma:

$$RMSE_l(m, h) = \sqrt{\frac{1}{N} \sum_{i=1}^N [\hat{y}_{i+h|t, l}(m) - y_{i+h}(m)]^2}, \quad (24)$$

onde  $N$  é o número de origens de previsão,  $\hat{y}_{i+h|t, l}(m)$  é o valor previsto para o tempo  $t + h$  para a maturidade  $m$  e  $y_{i+h}(m)$  é o valor real observado no horizonte de previsão para a maturidade  $m$ .

Esses procedimentos garantem uma análise abrangente da precisão das previsões geradas pelo modelo, utilizando o RMSE como principal métrica de avaliação de desempenho.

#### 4.1.5 Cálculo do erro quadrático acumulado de previsão (CSFE)

O CSFE foi utilizado como uma métrica adicional para avaliar a precisão das previsões geradas pelos diferentes modelos de previsão. O CSFE compara o desempenho de cada modelo em relação a um modelo benchmark, que neste caso foi um modelo de passeio aleatório (*random walk*), conforme proposto por [Welch e Goyal \(2008\)](#).

Foram considerados os cinco modelos de previsão distintos, que incluem variações baseadas em diferentes dados textuais, tanto das atas do Copom quanto do FOMC conforme tabela 1. Onde para cada modelo, os horizontes de previsão de 1, 3, 6 e 12 meses foram considerados. Além disso, foram analisadas 13 maturidades de títulos, representando diferentes prazos de vencimento, de forma a cobrir títulos de curto, médio e longo prazo, variando de 3 meses a 60 meses.

Para cada combinação de maturidade e horizonte de previsão, o erro quadrático acumulado foi calculado para cada origem de previsão. O erro quadrático foi obtido pela diferença entre o valor previsto e o valor real observado para cada horizonte de previsão, considerando tanto o modelo de previsão quanto o modelo benchmark. A fórmula utilizada para o cálculo do CSFE foi:

$$CSFE_{l,T}(m,h) = \sum_{t=1}^N \left\{ \left[ \hat{y}_{t+h|t, \text{benchmark}}(m) - y_{t+h}(m) \right]^2 - \left[ \hat{y}_{t+h|t,l}(m) - y_{t+h}(m) \right]^2 \right\}, \quad (25)$$

onde  $N$  é o número de origens de previsão,  $\hat{y}_{t+h|t,l}(m)$  representa o valor previsto para o tempo  $t+h$  para a maturidade  $m$  do modelo  $l$ , e  $y_{t+h}(m)$  é o valor real observado. O cálculo foi realizado para todas as origens, sendo o CSFE acumulado ao longo do tempo.

Após o cálculo do CSFE, foram gerados gráficos para cada combinação de maturidade e horizonte de previsão, apresentando o CSFE para todos os modelos analisados. A visualização permite comparar o desempenho dos modelos ao longo das origens de previsão, com destaque para o modelo de passeio aleatório como benchmark.

Essa análise do CSFE fornece uma visão clara do desempenho relativo dos modelos de previsão, permitindo identificar o modelo que mais se aproxima da realidade e oferece menores erros acumulados ao longo do tempo.

## 4.2 Teste Diebold-Mariano Modificado

O presente estudo emprega o teste modificado de Diebold-Mariano (DM) para comparar a acurácia preditiva de diferentes modelos. O teste original de [Diebold e Mariano \(1995\)](#) foi desenvolvido para avaliar a igualdade de precisão entre previsões concorrentes. No entanto, devido a problemas de tamanho amostral finito e autocorrelação dos erros, [Harvey et al. \(1997\)](#) propuseram uma versão modificada do teste, que aprimora a estimação da variância dos resíduos por meio do estimador de Newey-West.

### 4.2.1 Definição da Estatística do Teste

Sejam  $e_{1,t}$  e  $e_{2,t}$  os erros de previsão de dois modelos concorrentes em um instante  $t$ , sendo o primeiro o modelo benchmark e o segundo o modelo alternativo. Define-se a série das diferenças dos erros quadráticos como:

$$d_t = e_{1,t}^2 - e_{2,t}^2, \quad (26)$$

onde  $d_t$  representa a perda diferencial entre os modelos. A média dessa diferença ao longo do tempo é calculada como:

$$\bar{d} = \frac{1}{T} \sum_{t=1}^T d_t, \quad (27)$$

onde  $T$  é o tamanho da amostra.

A variância ajustada da série  $d_t$  é estimada utilizando o estimador heterocedástico e autocorrelacionado consistente de Newey-West, dado por:

$$\hat{\sigma}^2 = \gamma_0 + 2 \sum_{l=1}^L \left(1 - \frac{l}{L+1}\right) \gamma_l, \quad (28)$$

onde  $\gamma_0$  é a variância de  $d_t$ , e  $\gamma_l$  são as autocovariâncias amostrais de  $d_t$ , calculadas como:

$$\gamma_l = \frac{1}{T} \sum_{t=1}^{T-l} (d_t - \bar{d})(d_{t+l} - \bar{d}). \quad (29)$$

O parâmetro de truncamento  $L$  do estimador de Newey-West é definido como:

$$L = \lfloor T^{1/4} \rfloor. \quad (30)$$

#### 4.2.2 Cálculo da Estatística do Teste e P-Valor

A estatística de teste Diebold-Mariano Modificada é dada por:

$$DM = \frac{\bar{d}}{\sqrt{\hat{\sigma}^2/T}}. \quad (31)$$

Sob a hipótese nula de que os modelos apresentam desempenho preditivo equivalente, a estatística  $DM$  segue aproximadamente uma distribuição normal padrão  $N(0,1)$ . Assim, o p-valor bilateral é calculado como:

$$p = 2(1 - \Phi(|DM|)). \quad (32)$$

onde  $\Phi(\cdot)$  representa a função de distribuição acumulada da normal padrão.

#### 4.2.3 Aplicação Empírica

O teste foi aplicado para comparar a precisão preditiva de cinco modelos alternativos em relação ao modelo benchmark para diferentes maturidades. A análise considerou um horizonte de previsão de 1, 3, 6 e 12 meses, com a estatística de teste sendo calculada separadamente para cada maturidade.

A interpretação dos resultados seguiu o critério usual de significância estatística, adotando um nível de confiança de 90% ( $\alpha = 0,10$ ). P-valores inferiores a 0,10 indicaram diferenças estatisticamente significativas na precisão preditiva entre os modelos comparados.

### 5. Resultados e discussão

Este trabalho utilizou a curva DI x PRÉ para representar a estrutura a termo da taxa de juros no Brasil, construída a partir dos preços de ajuste do Contrato Futuro de Taxa Média de Depósitos Interfinanceiros de Um Dia (DI1), negociado na B3.

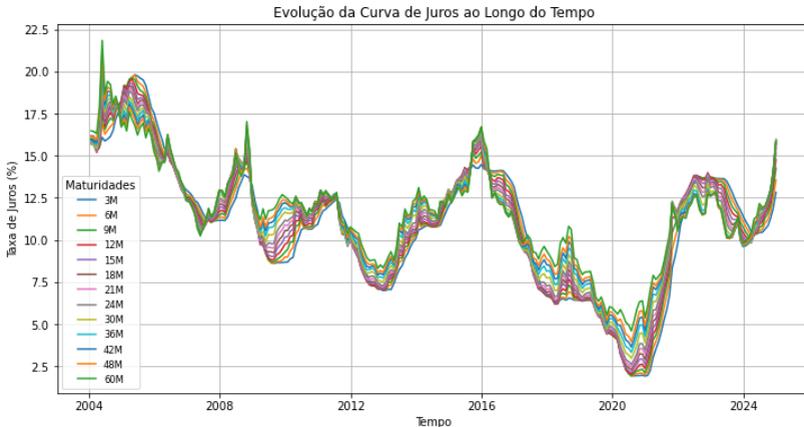
A taxa de juros empregada na construção da curva é expressa em termos anuais (% a.a.), e a interpolação é realizada considerando um ano composto por 252 dias úteis. Essa curva reflete as expectativas do mercado em relação

às taxas de juros futuras e desempenha um papel fundamental na precificação de ativos, gestão de riscos e formulação de estratégias de investimento.

Embora as taxas extraídas dessa curva acompanhem em grande parte o comportamento dos títulos públicos do Tesouro Nacional, elas se destacam por apresentar maior liquidez, em razão da intensa negociação dos contratos futuros de DII.

A curva DI x PRÉ é um dos principais instrumentos utilizados na análise das expectativas de juros futuros no Brasil. Sua dinâmica é influenciada por diversos fatores, incluindo decisões de política monetária, expectativas inflacionárias, riscos fiscais e eventos externos. Além disso, essa curva é amplamente aplicada em estratégias de hedge, precificação de derivativos e modelagem da estrutura a termo da taxa de juros.

**Figura 1**



Fonte: Elaborada pelo autor.

A Figura 1 apresenta a evolução da estrutura a termo da taxa de juros, do título DI x PRÉ com vencimento no final de cada mês para os prazos de 3, 6, 9, 12, 15, 18, 21, 24, 30, 36, 42, 48 e 60 meses. As taxas foram estimadas a partir de derivativos negociados na B3. O período amostral abrange de janeiro de 2004 a dezembro de 2024.

A Tabela 2 apresenta as estatísticas descritivas das taxas de juros para diferentes maturidades, incluindo a média, o desvio padrão, os valores mínimo e máximo, além das autocorrelações de primeira, décima-segunda e vigésima-quarta defasagem ( $\rho(1)$ ,  $\rho(12)$  e  $\rho(24)$ , respectivamente).

Observa-se que a média das taxas de juros aumenta à medida que a ma-

**Tabela 2**  
**Estatísticas descritivas e autocorrelações das maturidades**

Maturidade	Média	Desvio Padrão	Mínimo	Máximo	$\rho(1)$	$\rho(12)$	$\rho(24)$
3M	10.8232	3.9661	1.9251	19.8079	0.9955	0.6297	0.1623
6M	10.8737	3.9364	1.9158	19.7815	0.9944	0.6238	0.1588
9M	10.9222	3.8993	1.9427	19.6213	0.9929	0.6173	0.1587
12M	10.9644	3.8527	2.0346	19.5338	0.9913	0.6127	0.1631
15M	11.0095	3.7966	2.1330	19.3023	0.9898	0.6106	0.1718
18M	11.0574	3.7327	2.3049	19.1598	0.9882	0.6105	0.1848
21M	11.1087	3.6686	2.4567	19.1722	0.9866	0.6116	0.1993
24M	11.1598	3.6012	2.6146	19.4033	0.9852	0.6141	0.2153
30M	11.2604	3.4691	2.9773	19.8586	0.9823	0.6200	0.2464
36M	11.3560	3.3523	3.3328	20.2702	0.9797	0.6236	0.2720
42M	11.4423	3.2543	3.6448	20.6855	0.9769	0.6255	0.2922
48M	11.5200	3.1711	3.9659	21.0961	0.9745	0.6259	0.3054
60M	11.6619	3.0391	4.6002	21.8402	0.9707	0.6240	0.3192

Fonte: Elaborada pelo autor.

turidade cresce, variando de 10,82% para maturidades de 3 meses a 11,66% para maturidades de 60 meses. Esse comportamento reflete o prêmio de termo, indicando que os investidores exigem retornos mais elevados para prazos mais longos, em função da maior incerteza e do risco de variação nas taxas de juros ao longo do tempo.

O desvio padrão segue uma tendência decrescente, sugerindo que as taxas de juros de longo prazo são menos voláteis do que as de curto prazo. Esse resultado está em linha com a teoria da estrutura a termo, que afirma que as taxas de curto prazo são mais sensíveis às flutuações das condições econômicas e políticas.

Os valores mínimo e máximo indicam a amplitude da variação das taxas de juros ao longo do período analisado. As menores taxas observadas ocorrem para maturidades curtas (por exemplo, 1,92% para 3 meses), enquanto os valores máximos tendem a crescer com a maturidade (21,84% para 60 meses), refletindo as mudanças nos ciclos econômicos e as decisões de política monetária ao longo do tempo.

As autocorrelações  $\rho(1)$ ,  $\rho(12)$  e  $\rho(24)$  indicam o grau de persistência das taxas de juros ao longo do tempo.

$\rho(1)$  (autocorrelação de primeira ordem): As taxas de juros apresentam alta persistência no curto prazo, com valores próximos de 1,0 para todas as maturidades. Esse resultado indica que os juros seguem um comportamento altamente inercial, ou seja, mudanças em um período tendem a se propagar para os próximos períodos.

$\rho(12)$  (autocorrelação anual, 12 meses): A persistência das taxas de juros diminui significativamente em relação à autocorrelação de primeira ordem, mas ainda se mantém elevada (cerca de 0,62 para as maturidades mais curtas e

levemente maior para prazos mais longos). Isso sugere que as taxas de juros possuem memória de longo prazo, ou seja, choques passados ainda influenciam os níveis atuais, mas essa influência diminui com o tempo.

$\rho(24)$  (autocorrelação bianual, 24 meses): A autocorrelação continua em declínio e atinge valores mais baixos (entre 0,16 e 0,32), indicando que a influência das taxas de juros passadas após dois anos já se torna bem mais fraca. Contudo, ainda há um grau de persistência considerável, o que pode refletir o impacto de ciclos econômicos mais longos e a condução da política monetária.

Os resultados reforçam a ideia de que as taxas de juros seguem um processo altamente persistente, especialmente no curto prazo. Essa característica é comum em séries financeiras e sugere que a curva de juros apresenta forte dependência temporal, sendo um fator essencial para a modelagem e previsão das taxas de juros.

A queda da autocorrelação de curto prazo indica que as taxas de juros de menor maturidade reagem mais rapidamente a novas informações. Já o aumento da autocorrelação de longo prazo sugere maior persistência nas taxas de maior maturidade, refletindo expectativas macroeconômicas mais estáveis. Esse comportamento é influenciado por fatores como política monetária, inflação e crescimento econômico, que afetam a convergência gradual das taxas para um nível de equilíbrio de longo prazo.

## 5.1 Dados textuais

### 5.1.1 Copom

O Comitê de Política Monetária (Copom) é o órgão do Banco Central do Brasil responsável por definir a taxa básica de juros da economia, a Selic, com o objetivo de manter a inflação alinhada à meta estabelecida pelo Conselho Monetário Nacional (CMN). Suas reuniões ocorrem a cada 45 dias, em dois dias consecutivos, conforme calendário previamente divulgado.

O processo decisório do Copom baseia-se em uma ampla análise do cenário macroeconômico, incluindo apresentações técnicas sobre a economia brasileira e global, condições de liquidez e comportamento dos mercados. Após essas exposições, os membros do Comitê debatem e votam a decisão sobre a taxa Selic, cuja divulgação ocorre no mesmo dia por meio de um Comunicado. A Ata da reunião, contendo a justificativa detalhada da decisão e a avaliação dos principais riscos econômicos, é publicada até quatro dias úteis após o encontro.

Para esta pesquisa, foram analisadas 177 atas do Copom, abrangendo o período de dezembro de 2003 a dezembro de 2024. A Tabela 3 apresenta as

estatísticas descritivas das variáveis analisadas: número de palavras, diversidade do vocabulário e densidade lexical nas atas do Copom. A análise dessas estatísticas permite compreender a complexidade e a evolução da linguagem utilizada ao longo do tempo.

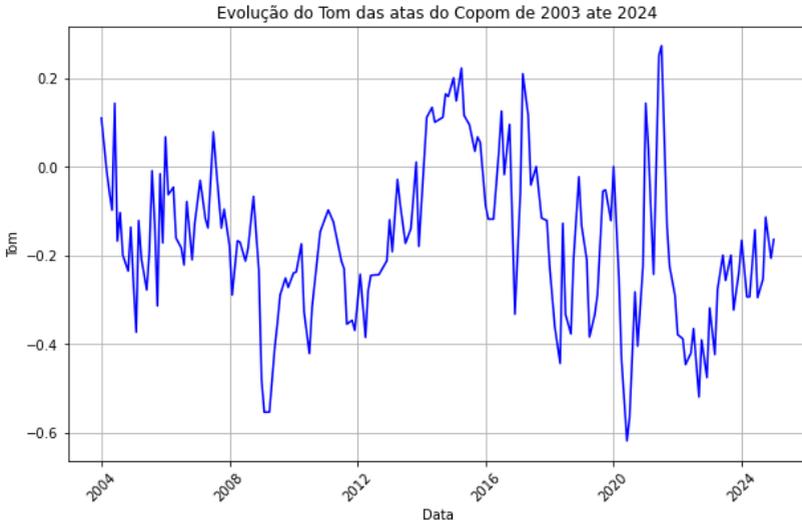
**Tabela 3**  
**Estatísticas descritivas das atas do Copom**

Estadística	Número de Palavras	Vocabulário	Densidade Lexical
Contagem	177	177	177
Média	4.391,72	849,46	0,22099
Desvio Padrão	2.285,32	261,48	0,05639
Mínimo	1.329	443	0,14745
1º Quartil (25%)	2.198	560	0,16280
Mediana (50%)	3.834	853	0,22387
3º Quartil (75%)	6.925	1.106	0,26366
Máximo	8.105	1.267	0,35162

Fonte: Elaborada pelo autor.

A análise do número de palavras nas atas do Copom revela uma média de 4.391,72 palavras, com um desvio padrão de 2.285,32, indicando uma considerável variação entre os documentos. O menor número registrado foi 1.329 palavras, enquanto o maior atingiu 8.105, evidenciando diferenças substanciais no tamanho das atas ao longo do tempo. A mediana foi de 3.834 palavras, e o intervalo interquartil, entre 2.198 e 6.925 palavras, reforça a heterogeneidade na extensão dos textos, com algumas atas sendo significativamente mais sucintas e outras mais extensas.

A variável vocabulário, que representa o número de palavras únicas em cada ata, apresenta uma média de 849,46 palavras distintas. O desvio padrão de 261,48 indica uma variação expressiva na diversidade vocabular entre os documentos. O menor número de palavras únicas registrado foi 443, enquanto o maior foi 1.267, sugerindo diferenças na complexidade lexical das atas ao longo do período analisado. A mediana foi de 853 palavras únicas, com um intervalo interquartil entre 560 e 1.106, o que indica que a maior parte das atas apresenta um vocabulário relativamente consistente dentro desse intervalo. Essa variação reflete a evolução do estilo de comunicação do Copom, influenciada por mudanças na abordagem discursiva e no contexto econômico ao longo do tempo.

**Figura 2**

Fonte: Elaborada pelo autor.

A densidade lexical, que representa a proporção de palavras únicas em relação ao total de palavras em cada ata, apresentou uma média de 0,22, indicando que aproximadamente 22% dos termos utilizados são distintos. O desvio padrão de 0,06 sugere uma variação moderada nessa métrica ao longo do período analisado. O valor mínimo registrado foi 0,15, enquanto o máximo atingiu 0,35, evidenciando que, em algumas atas, apenas 15% das palavras são únicas, ao passo que, em outras, essa proporção chega a 35%. A mediana de 0,22 reforça que, na maior parte dos documentos, a densidade lexical se mantém próxima desse patamar.

Essas estatísticas oferecem uma caracterização quantitativa da complexidade e diversidade lexical das atas do Copom, constituindo uma base para análises mais aprofundadas sobre a estrutura e a evolução da linguagem utilizada ao longo do tempo. A variação observada nos valores das três variáveis analisadas pode estar associada a diferentes fatores, como a natureza dos temas abordados, a abordagem discursiva adotada ou o contexto econômico vigente em cada período.

A Tabela 4 apresenta as estatísticas descritivas das variáveis relacionadas ao sentimento das atas do Copom: a porcentagem de palavras negativas, a porcentagem de palavras positivas e o tom geral do documento.

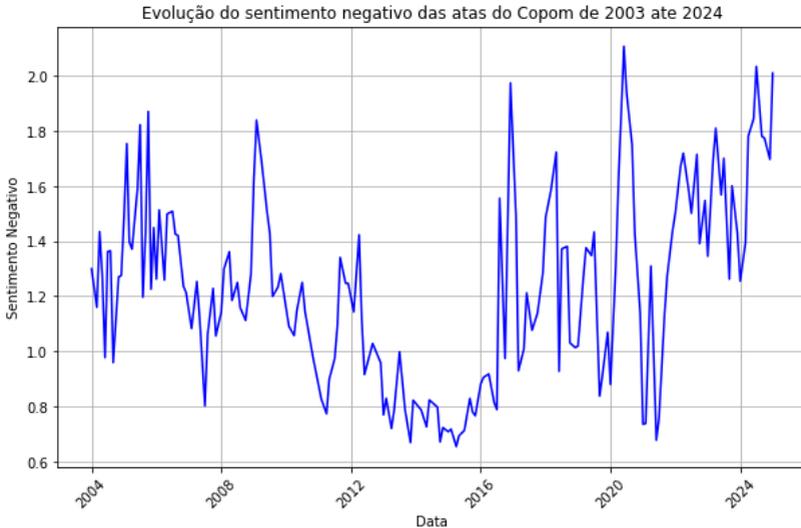
**Tabela 4**  
**Estatísticas descritivas das variáveis de sentimento das atas do Copom**

Estatística	% Negativo	% Positivo	Tom
Contagem	177	177	177
Média	1,2301	0,8638	-0,1669
Desvio Padrão	0,3443	0,2358	0,1782
Mínimo	0,6259	0,4821	-0,6190
25%	0,9593	0,6789	-0,2889
Mediana	1,2464	0,8246	-0,1736
75%	1,4346	1,0050	-0,0577
Máximo	2,1079	1,6180	0,2727

Fonte: Elaborada pelo autor.

A média da proporção de palavras negativas nas atas é de 1,23%, com um desvio padrão de 0,34. O valor mínimo registrado foi de 0,63%, enquanto o máximo alcançou 2,11%. O intervalo interquartil indica que 50% das atas possuem entre 0,96% e 1,43% de palavras negativas, sugerindo uma predominância moderada desse tipo de vocabulário ao longo do tempo.

Já a proporção de palavras positivas tem uma média de 0,86%, com desvio padrão de 0,23. A ata menos otimista apresentou apenas 0,48% de palavras positivas, enquanto a mais otimista atingiu 1,62%. O intervalo interquartil (0,68% a 1,01%) revela que a maioria das atas se concentra nessa faixa de variação, refletindo a utilização relativamente constante de termos positivos.

**Figura 3**

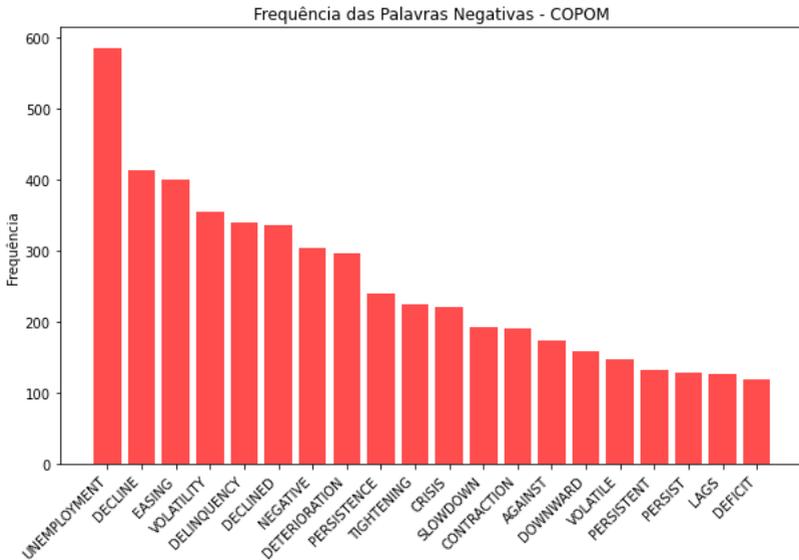
O tom geral das atas apresenta uma média negativa de  $-0,1669$ , o que indica que, em geral, a comunicação do Copom tende a ser mais cautelosa e conservadora. O desvio padrão de  $0,1782$  mostra uma variação significativa no tom das atas ao longo do tempo. O valor mínimo foi de  $-0,6190$ , refletindo a ata mais pessimista da série, enquanto o máximo foi de  $0,2727$ , indicando o documento mais positivo. O intervalo interquartil revela que a maioria das atas está entre  $-0,2889$  e  $-0,0577$ , reforçando uma tendência levemente negativa no tom predominante.

Essas estatísticas evidenciam que, ao longo do período analisado, as atas do Copom apresentam uma comunicação majoritariamente prudente, com momentos de maior pessimismo ou otimismo dependendo do contexto econômico. A variação no tom pode estar associada a diferentes ciclos econômicos, mudanças na condução da política monetária ou eventos externos que impactaram a economia brasileira.

As figuras 4 e 5 apresentam as 20 palavras negativas e positivas mais frequentes extraídas das atas do COPOM, no período de dezembro de 2003 a dezembro de 2024. Observa-se que termos como "*despite*" (apesar), "*favorable*" (favorável), "*stable*" (estável) e "*stability*" (estabilidade) aparecem com alta frequência, sugerindo uma ênfase recorrente do comitê em transmitir uma visão de resiliência e confiança em relação às condições econômicas. Por outro

lado, entre as palavras negativas, destacam-se a recorrência de termos como "*unemployment*" (desemprego), "*decline*" (declínio), "*volatility*" (volatilidade) e "*crisis*" (crise), refletindo preocupações com instabilidades e riscos macroeconômicos ao longo do período analisado.

**Figura 4**

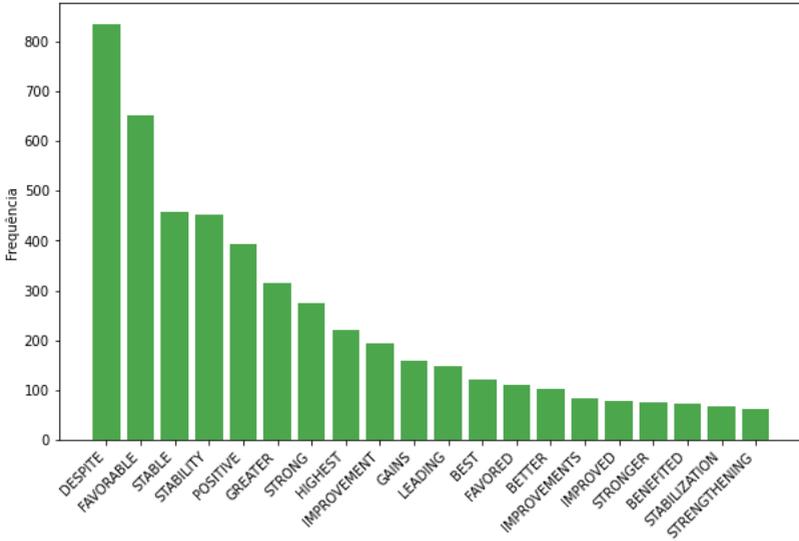


Fonte: Elaborada pelo autor.

Essa análise quantitativa do vocabulário utilizado nas atas possibilita uma avaliação preliminar do tom adotado pelo COPOM ao longo do tempo. A frequência mais alta de palavras negativas pode indicar momentos de maior incerteza econômica ou de alerta sobre possíveis adversidades, enquanto as palavras positivas, embora presentes, são menos destacadas. Esses resultados reforçam a importância de incorporar medidas de análise textual na previsão de variáveis financeiras, uma vez que o sentimento expresso nas comunicações do comitê pode influenciar as expectativas dos agentes de mercado.

**Figura 5**

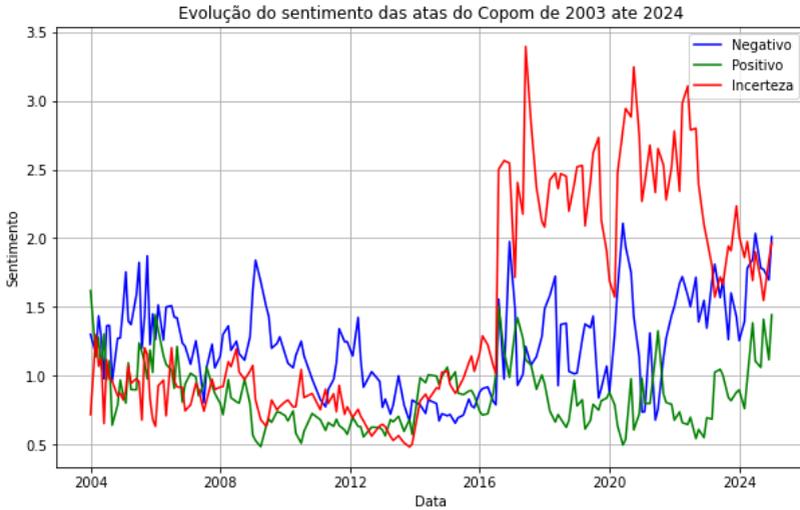
Frequência das Palavras Positivas - COPOM



Fonte: Elaborada pelo autor.

### 5.1.2 Evolução do Sentimento nas Atas do Copom

A Figura 6 apresenta a evolução dos sentimentos negativos, positivos e de incerteza extraídos das atas do Copom entre 12/2003 e 12/2024. A análise baseia-se no uso do dicionário financeiro de [Loughran e McDonald \(2011\)](#) para classificar a linguagem das atas, permitindo uma avaliação quantitativa da tonalidade do discurso ao longo do tempo.

**Figura 6**

Fonte: Elaborada pelo autor.

Observa-se que o sentimento de incerteza (linha vermelha) apresenta um crescimento expressivo a partir de 2015, atingindo picos notáveis entre 2016 e 2021. Esse aumento pode estar relacionado a eventos macroeconômicos e políticos, como a recessão econômica brasileira de 2015-2016, o impeachment presidencial de 2016 e as incertezas fiscais e monetárias dos anos subsequentes.

O sentimento negativo (linha azul) mostra variações ao longo do período, com aumentos perceptíveis em momentos de crise, como a crise financeira global de 2008-2009 e a pandemia de COVID-19 em 2020. Esses períodos coincidem com momentos de grande volatilidade no mercado financeiro e ajustes na condução da política monetária.

Já o sentimento positivo (linha verde) apresenta uma leve tendência de queda ao longo do tempo, indicando um tom mais cauteloso adotado pelo Banco Central nas suas comunicações. No início da série, observa-se maior oscilação entre os sentimentos, enquanto nos anos mais recentes há uma predominância maior do tom de incerteza e negatividade, refletindo um ambiente econômico mais desafiador.

De modo geral, a análise dos sentimentos das atas do Copom sugere uma forte correlação entre o tom do discurso e o contexto econômico e político vigente. A crescente incerteza nos últimos anos pode influenciar a percepção

dos agentes econômicos e impactar as expectativas de mercado, destacando a importância da comunicação do Banco Central na condução da política monetária.

### 5.1.3 Análise da ata do COPOM com o tom mais negativo

A ata do COPOM de 6 de maio de 2020 foi registrada como a mais negativa da série histórica, apresentando um tom geral de -0,6190. Esse índice reflete uma avaliação pessimista do comitê em relação ao cenário econômico, fortemente impactado pela crise decorrente da pandemia de COVID-19. Em resposta ao choque econômico e às expectativas de recessão, o Copom decidiu reduzir a taxa básica de juros em 0,75 pontos percentuais, de 3,75% para 3,00%, como parte das medidas para mitigar os efeitos adversos da crise.

A ata contém 1.613 palavras, das quais 2,1079% são classificadas como negativas, enquanto apenas 0,4960% possuem conotação positiva. A elevada proporção de termos negativos e o tom predominantemente desfavorável estão alinhados com o contexto econômico altamente incerto daquele período, marcado pelo aprofundamento da recessão global e pela deterioração das expectativas de crescimento.

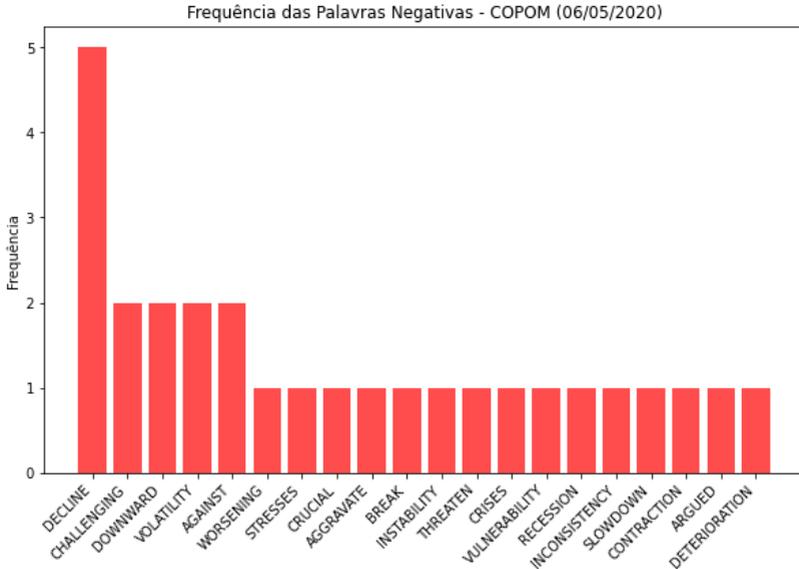
Além disso, o documento registra 545 palavras únicas, com uma densidade lexical de 0,33788, sugerindo um vocabulário relativamente diversificado. No entanto, a predominância de termos negativos evidencia a ênfase do comitê na gravidade do cenário econômico. A riqueza lexical observada indica que o Copom utilizou uma ampla variedade de expressões para descrever a complexidade da conjuntura, ressaltando os desafios de curto prazo e as incertezas que pautaram a condução da política monetária naquele momento.

Esses elementos — o tom predominantemente negativo, a decisão de redução da taxa de juros e a complexidade lexical da ata — evidenciam a necessidade do Copom de adotar uma postura mais cautelosa e responsiva diante da severa crise econômica provocada pela pandemia. A decisão de corte da taxa Selic refletiu a estratégia do comitê de flexibilizar as condições monetárias com o objetivo de estimular a economia e atenuar os impactos adversos da recessão iminente.

A análise das palavras extraídas das atas do COPOM revela que a ata datada de 06 de maio de 2020, a mais negativa entre as analisadas, contém uma série de palavras que refletem um tom de preocupação e incerteza econômica. As palavras mais frequentes entre as negativas incluem "*decline*"(declínio), com 5 ocorrências, e "*volatility*"(volatilidade), "*against*"(contra), "*challenging*"(desafiador), "*slowdown*"(desaceleração), entre outras. Esses termos indicam que o COPOM estava destacando um cenário econômico desfavorável,

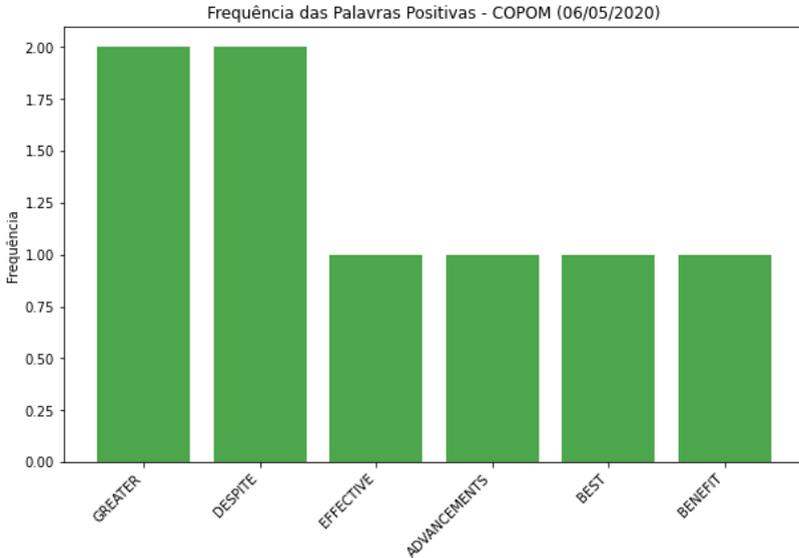
mercado por riscos de deterioração e instabilidade.

**Figura 7**



Fonte: Elaborada pelo autor.

Além disso, palavras como "*crisis*"(crise), "*recession*"(recessão), "*vulnerability*"(vulnerabilidade) e "*instability*"(instabilidade) aparecem com destaque, sugerindo que a ata refletia um período de elevada preocupação com as condições econômicas, possivelmente devido aos efeitos da pandemia de COVID-19, que estava afetando a economia global naquele momento. Termos como "*deterioration*"(deterioração) e "*harmed*"(prejudicado) reforçam a ideia de fragilidade e vulnerabilidade econômica, com o COPOM alertando sobre os impactos negativos em diversos setores.

**Figura 8**

Fonte: Elaborada pelo autor.

Essa predominância de palavras negativas indica que, durante o período analisado, o COPOM procurou enfatizar os riscos e as incertezas econômicas que poderiam afetar a estabilidade e o crescimento do Brasil. A comunicação do comitê, nesse contexto, pode ter influenciado as expectativas do mercado, transmitindo um tom de cautela e prudência. Tais mensagens são fundamentais para a formulação das políticas monetárias, já que os agentes econômicos frequentemente reagem a essas indicações de risco ao ajustar suas expectativas e decisões de investimento.

#### 5.1.4 Análise da ata do COPOM com o tom mais positivo

A ata do COPOM de 16 de junho de 2021 é registrada como a mais otimista da série histórica, apresentando um índice de 0,2727, que reflete a postura positiva do comitê em relação ao cenário econômico. Essa postura otimista se traduz na decisão de aumentar a taxa de juros em 0,75 pontos percentuais, passando de 3,50% para 4,25%. A elevação da taxa foi uma resposta às crescentes pressões inflacionárias, demonstrando a preocupação do COPOM em garantir a convergência da inflação para a meta estabelecida e preservar a estabilidade macroeconômica.

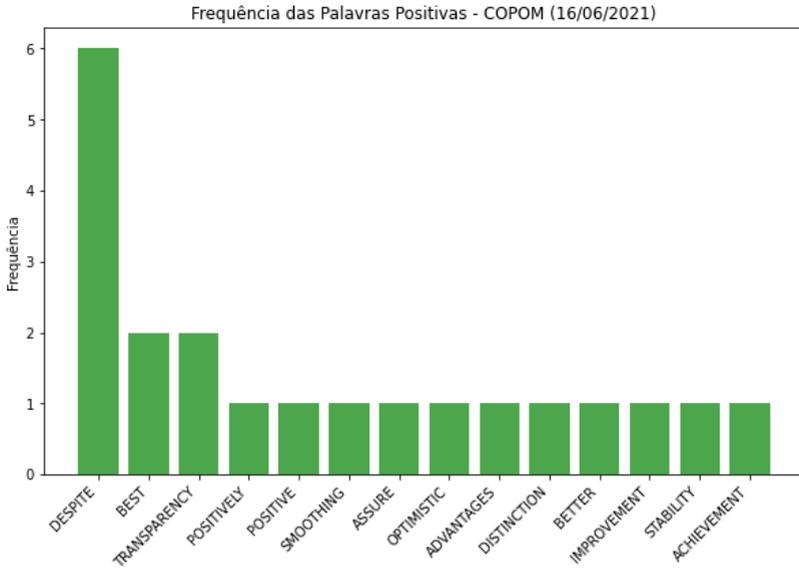
Contendo um total de 1.584 palavras, das quais 0,7576% são negativas

e 1,3258% são positivas, a ata de junho de 2021 tem uma predominância de palavras positivas, em relação às negativas, reforça o tom otimista da ata, que está em consonância com a decisão de aumento da taxa de juros. Esse uso de linguagem mais favorável pode ser interpretado como um reflexo da confiança do Copom nas perspectivas econômicas, considerando que a decisão foi tomada em um momento de preocupação com a inflação, mas também com a expectativa de que a economia estivesse se recuperando e poderia lidar com os ajustes necessários para o controle da inflação no médio prazo.

Além disso, o documento registrou 510 palavras únicas, com uma riqueza lexical de 0,32197, indicando um vocabulário relativamente diversificado. Esse valor sugere que o Copom adotou uma linguagem variada para expressar suas análises e justificar a decisão de aumentar a taxa de juros, evidenciando a complexidade do cenário econômico e as nuances envolvidas.

Esses elementos — o tom positivo, a decisão de aumento da taxa de juros e a riqueza lexical — refletem a postura do Copom diante de um cenário de crescente pressão inflacionária. Apesar das dificuldades, o Comitê adotou uma abordagem otimista, confiando que as medidas tomadas seriam eficazes para controlar a inflação e garantir a estabilidade econômica no médio prazo.

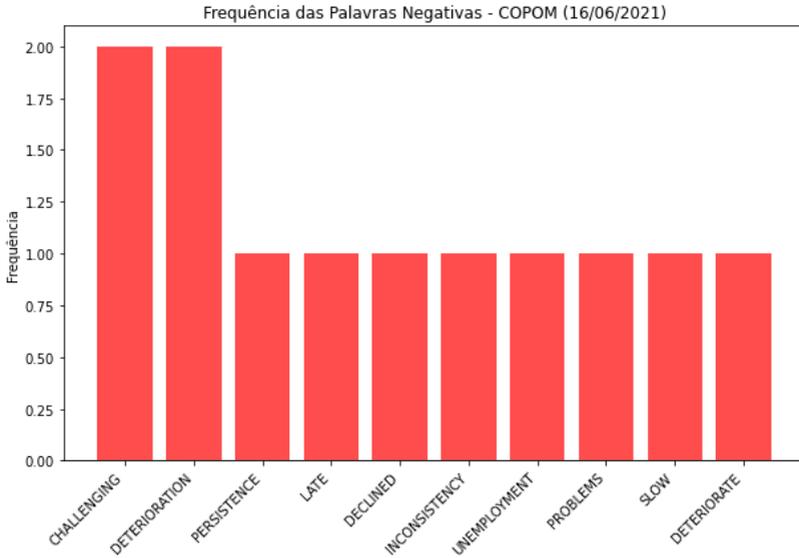
As palavras mais frequentes entre as positivas incluem "*despite*" (apesar), com 6 ocorrências, e "*best*" (melhor), "*transparency*" (transparência) e "*better*" (melhor), todas transmitindo uma mensagem de resiliência e progressos nas condições econômicas. O uso de termos como "*optimistic*" (otimista) e "*positive*" (positivo) indica uma abordagem mais favorável do comitê, sugerindo que o cenário econômico estava em recuperação, apesar dos desafios ainda presentes.

**Figura 9**

Fonte: Elaborada pelo autor.

Além disso, palavras como "*improvement*" (melhoria), "*advantages*" (vantagens) e "*stability*" (estabilidade) refletem a ênfase do COPOM em destacar os aspectos positivos da economia, incluindo a estabilidade e o aprimoramento nas condições econômicas. Termos como "*achievement*" (realização) e "*distinction*" (distinção) também reforçam essa visão otimista, sugerindo que o Brasil estava fazendo progressos em áreas-chave para a sua recuperação.

Embora a ata contenha algumas palavras negativas, como "*challenging*" (desafiador) e "*deterioration*" (deterioração), elas são mencionadas em menor frequência, o que indica que o COPOM estava mais focado em transmitir uma mensagem de otimismo e confiança. Esse tom positivo provavelmente visava fortalecer as expectativas do mercado, sinalizando que o Comitê via a economia em trajetória de recuperação e com perspectivas favoráveis no médio e longo prazo.

**Figura 10**

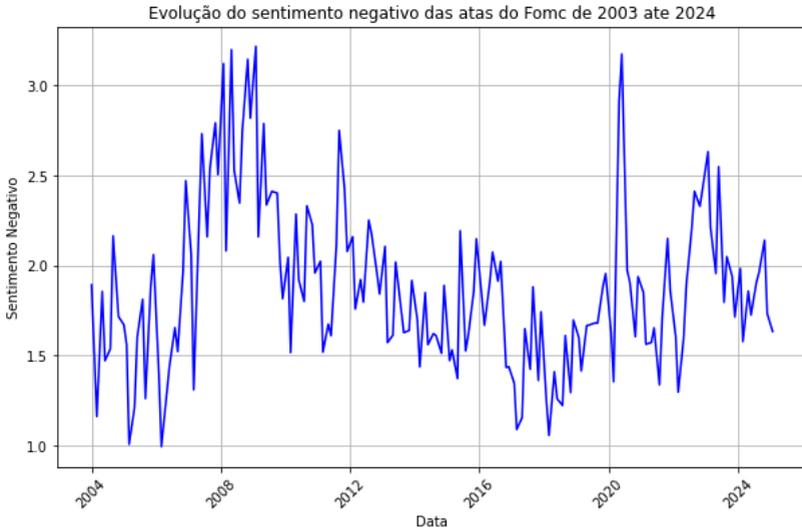
Fonte: Elaborada pelo autor.

Essa comunicação positiva do COPOM teve o potencial de influenciar as expectativas dos agentes econômicos, incentivando uma visão mais favorável sobre o futuro da economia brasileira, especialmente em um momento de transição pós-pandemia, no qual as medidas de estímulo fiscal e monetário estavam começando a surtir efeito.

### 5.1.5 FOMC

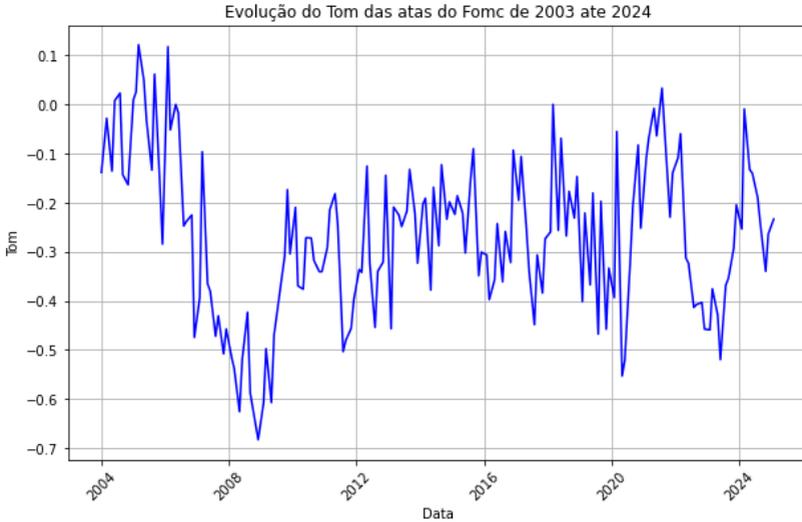
Nos Estados Unidos, a responsabilidade pela formulação e condução da política monetária cabe ao *Federal Reserve* (Fed), que opera por meio de instrumentos destinados a regular a oferta de moeda e crédito na economia, com o objetivo de promover a estabilidade macroeconômica. Entre esses instrumentos, destaca-se a taxa dos fundos federais (*federal funds rate*), que influencia diretamente as condições financeiras e econômicas do país.

**Figura 11**



Fonte: Elaborada pelo autor.

O órgão responsável por definir a trajetória da taxa de juros de curto prazo nos Estados Unidos é o FOMC. Esse comitê regula as operações de mercado aberto e, por meio de suas decisões, afeta a taxa dos fundos federais, que corresponde aos juros aplicados sobre empréstimos interbancários de reservas mantidas no *Federal Reserve*. Alterações nessa taxa geram um efeito cascata sobre outras taxas de juros, influenciando o mercado de crédito, a taxa de câmbio, o nível de investimento, a inflação e o crescimento econômico. Dessa forma, as decisões do FOMC possuem impacto não apenas sobre a economia norte-americana, mas também sobre os mercados financeiros globais.

**Figura 12**

Fonte: Elaborada pelo autor.

O Comitê reúne-se oito vezes ao ano para revisar as condições econômicas e financeiras, determinar a orientação da política monetária e avaliar os riscos para o cumprimento de seus objetivos de longo prazo, que incluem a estabilidade de preços e o crescimento econômico sustentável.

Dado seu papel central na política monetária, as decisões do FOMC são amplamente monitoradas por agentes do mercado financeiro, economistas e formuladores de políticas em todo o mundo. Suas deliberações influenciam variáveis macroeconômicas essenciais, tornando seus comunicados e atas documentos estratégicos para a interpretação das tendências futuras da política monetária e do comportamento dos mercados.

**Tabela 5**  
**Estatísticas descritivas das atas do FOMC**

Estatística	Número de Palavras	Vocabulário	Densidade Lexical
Contagem	169	169	169
Média	8265.23	1364.97	0.179319
Desvio Padrão	3069.80	258.35	0.040638
Mínimo	3013	829	0.113801
1º Quartil (25%)	6169	1207	0.145638
Mediana (50%)	7687	1383	0.176843
3º Quartil (75%)	11139	1555	0.199877
Máximo	15131	1922	0.279472

Fonte: Elaborada pelo autor.

A análise das atas do FOMC revela que os documentos possuem, em média, 8.265 palavras, com um desvio padrão de aproximadamente 3.070 palavras. Essa amplitude indica uma grande variabilidade no tamanho dos textos, com o número total de palavras oscilando entre 3.013 e 15.131. A mediana é 7.687 palavras, enquanto o intervalo interquartil (de 6.169 a 11.139 palavras) evidencia que a maioria dos documentos se concentra nessa faixa.

No que tange ao vocabulário, medido pelo número de palavras únicas, observa-se uma média de 1.365 palavras únicas, com um desvio padrão de 258,35. Os valores variam de um mínimo de 829 a um máximo de 1.922 palavras únicas. A mediana de 1.383 e o intervalo interquartil entre 1.207 e 1.555 sugerem que, apesar das variações no tamanho dos documentos, a diversidade lexical tende a se manter relativamente consistente, concentrando-se em torno desses valores centrais.

A densidade lexical, definida como a proporção de palavras únicas em relação ao total de palavras, apresenta uma média de 0,1793 – ou seja, cerca de 17,93% das palavras de um documento são únicas. O desvio padrão de 0,0406, juntamente com um valor mínimo de 0,1138 e um máximo de 0,2795, indica que essa proporção varia de forma moderada entre as atas. A mediana de 0,1768 e o intervalo interquartil (de 0,1456 a 0,1999) reforçam a ideia de que, independentemente do tamanho total do documento, a diversidade linguística, expressa pela densidade lexical, permanece em uma faixa relativamente estável.

Em síntese, embora as atas do FOMC demonstrem uma ampla variação no comprimento total, a diversidade lexical – tanto em termos absolutos (número de palavras únicas) quanto relativos (densidade lexical) – se mantém em uma faixa mais restrita. Esses resultados sugerem que, apesar das diferenças de extensão, os documentos tendem a utilizar um vocabulário consistente para

transmitir as informações, o que pode refletir um padrão de comunicação próprio desse órgão, similar ao observado na análise das atas do COPOM.

**Tabela 6**  
**Estatísticas descritivas do tom das atas do FOMC**

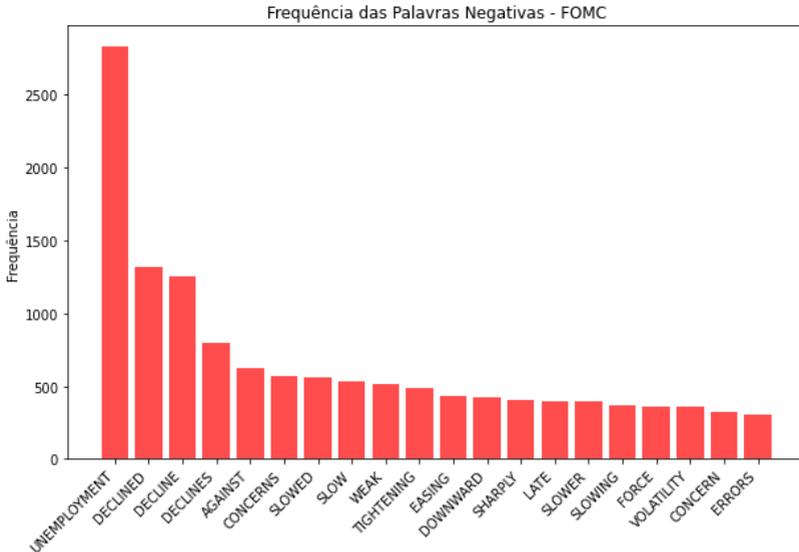
Estatística	% Negativo	% Positivo	Tom FOMC
Contagem	169	169	169
Média	1.8753	1.0623	-0.2685
Desvio Padrão	0.4563	0.2544	0.1642
Mínimo	0.9940	0.5308	-0.6829
1º Quartil (25%)	1.5774	0.8962	-0.3779
Mediana (50%)	1.8411	1.0197	-0.2596
3º Quartil (75%)	2.1151	1.2435	-0.1513
Máximo	3.2161	1.7582	0.1216

Fonte: Elaborada pelo autor.

A Tabela 6 apresenta as estatísticas descritivas das variáveis relacionadas ao tom das atas do FOMC. Observa-se que a proporção média de palavras negativas é de aproximadamente 1,88%, com um desvio padrão de 0,46%, indicando uma variação moderada ao longo do tempo. Em contraste, a proporção média de palavras positivas é 1,06%, apresentando um desvio padrão menor (0,25%), o que sugere maior estabilidade no uso de termos com conotação positiva. Essa assimetria evidencia uma tendência das comunicações do FOMC a apresentarem um tom mais negativo.

Ao analisar o tom agregado das atas, definido pela diferença entre a proporção de palavras positivas e negativas, verifica-se que a média é -0,2685, reforçando a predominância de um tom cauteloso ou pessimista nos comunicados. O tom mais negativo registrado foi -0,6829, enquanto o valor máximo foi 0,1216, indicando que, embora algumas atas apresentem um tom levemente positivo, a grande maioria se mantém dentro de uma faixa negativa. A mediana de -0,2596 sugere que mesmo o valor central da distribuição reflete um viés conservador na comunicação do FOMC.

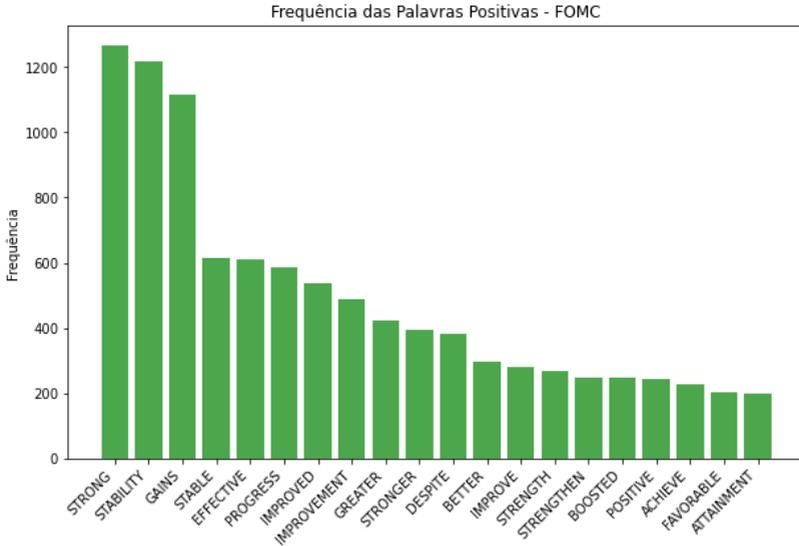
Adicionalmente, a análise dos quartis revela que 75% das atas possuem um tom inferior a -0,1513, demonstrando que os comunicados do Federal Reserve tendem a enfatizar riscos e incertezas ao longo do tempo. Esse padrão é consistente com a abordagem tradicional dos bancos centrais, que frequentemente utilizam um tom mais prudente para evitar reações exageradas dos mercados.

**Figura 13**

Fonte: Elaborada pelo autor.

Quando comparado às atas do COPOM, verifica-se que os comunicados do FOMC são mais negativamente carregados. A proporção de palavras negativas no FOMC (1,88%) é superior à observada nas atas do Banco Central do Brasil, enquanto a proporção de palavras positivas (1,06%) é menor, sugerindo que a comunicação do Federal Reserve tende a ser mais cautelosa.

As figuras 14 e 13 apresentam as 20 palavras positivas e negativas mais frequentes nas atas do FOMC entre dezembro de 2003 e dezembro de 2004. Ao analisar os dados, observa-se que as palavras negativas superam amplamente as positivas, tanto em frequência quanto em incidência geral. Entre as palavras negativas, *'unemployment'* (desemprego) lidera com 2.834 ocorrências, seguida por *'declined'* (declinou) com 1.317 e *'decline'* (diminuição) com 1.258. Esses termos refletem uma preocupação substancial com o desemprego e a deterioração econômica, caracterizando um período de dificuldades para a economia americana. Outras palavras, como *'against'* (contra) (626), *'concerns'* (preocupações) (570) e *'slowed'* (desacelerou) (556), também ressaltam um cenário de incerteza e desaceleração econômica.

**Figura 14**

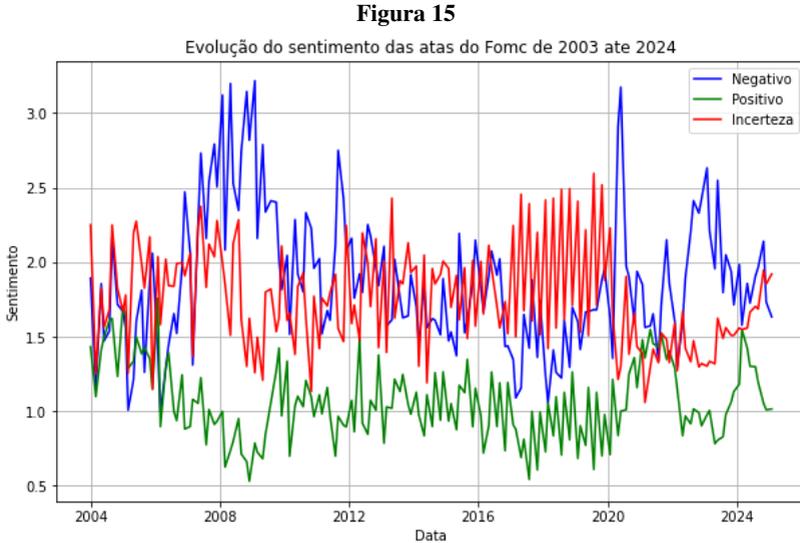
Fonte: Elaborada pelo autor.

Por outro lado, as palavras positivas mais frequentes incluem '*strong*' (forte) com 1.266 ocorrências, '*stability*' (estabilidade) com 1.218 e '*gains*' (ganhos) com 1.117. Embora essas palavras indiquem uma tentativa de transmitir uma imagem de força e estabilidade econômica, sua frequência não é suficiente para superar a quantidade de termos negativos. Outras palavras positivas, como '*progress*' (progresso) (584) e '*improved*' (melhorou) (539), também refletem uma intenção de enfatizar avanços, mas são ofuscadas pelas palavras que expressam desafios econômicos.

Esse desequilíbrio entre palavras negativas e positivas revela o tom geralmente cauteloso e preocupado das atas do FOMC durante esse período. Apesar das tentativas de destacar aspectos positivos da economia, como a força e a estabilidade, as palavras negativas dominam, evidenciando um contexto de desafios econômicos, incluindo desemprego elevado e desaceleração do crescimento econômico. Essa análise quantitativa do vocabulário das atas pode sugerir que o FOMC estava, em grande parte, focado em abordar questões econômicas adversas, o que pode ter influenciado a percepção do mercado sobre a saúde da economia dos Estados Unidos naquele período.

### 5.1.6 Evolução do Sentimento nas atas do FOMC

A Figura 15 ilustra a evolução dos sentimentos negativos, positivos e de incerteza extraídos das atas do FOMC entre 12/2003 e 12/2024. A análise se baseia na aplicação do dicionário financeiro de [Loughran e McDonald \(2011\)](#) para classificar a linguagem das atas, permitindo uma avaliação quantitativa da tonalidade do discurso ao longo do tempo.



Fonte: Elaborada pelo autor.

Observa-se que o sentimento negativo (linha azul) apresenta picos pronunciados durante períodos de crise econômica, notadamente entre 2007 e 2009, período correspondente à crise financeira global. Durante esse intervalo, a linguagem do FOMC tornou-se substancialmente mais negativa, refletindo a preocupação com a instabilidade do sistema financeiro e os desafios enfrentados pela política monetária. A pandemia de COVID-19, a partir de 2020, também marca um período de elevação do sentimento negativo, acompanhado por intervenções agressivas do Fed para mitigar os impactos da crise sanitária.

O sentimento de incerteza (linha vermelha) tem um comportamento mais errático ao longo da série, mas apresenta uma tendência de alta a partir de 2015, possivelmente refletindo desafios como a normalização da política monetária após a crise de 2008, disputas comerciais e incertezas fiscais nos Estados Unidos. A incerteza também aumenta significativamente durante a pandemia

de COVID-19, evidenciando o papel da comunicação do FOMC na gestão das expectativas do mercado.

Por outro lado, o sentimento positivo (linha verde) demonstra uma tendência de queda ao longo do tempo, indicando que a linguagem do comitê tem se tornado menos otimista. Essa mudança pode estar associada à crescente complexidade do ambiente econômico global e à maior ênfase em riscos e desafios na condução da política monetária.

No geral, a análise das atas do FOMC sugere que os sentimentos expressos no discurso do comitê estão fortemente associados ao contexto macroeconômico. Períodos de crise tendem a gerar um aumento na negatividade e na incerteza, enquanto momentos de estabilidade econômica apresentam um tom mais neutro. Essa relação destaca a importância da comunicação do banco central na formação das expectativas do mercado e na orientação da política monetária.

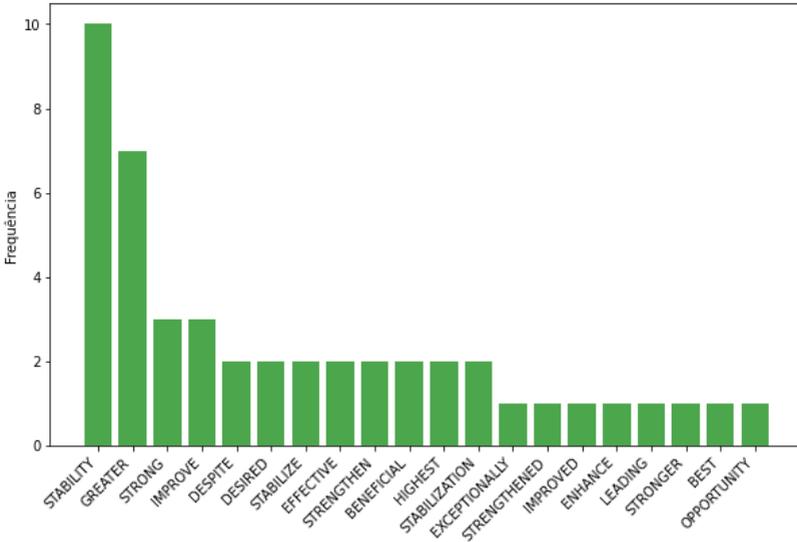
### **5.1.7 Análise da ata do FOMC com o tom mais negativo**

A ata do FOMC de 29 de outubro de 2008 destaca-se como a mais negativa de toda a série histórica analisada, apresentando um tom de -0,6829. Esse tom extremamente pessimista reflete o contexto de profunda incerteza econômica, pois essa reunião ocorreu no auge da Crise Financeira Global de 2008.

Essa ata contém 9.796 palavras, das quais 2,82% possuem conotação negativa, um valor significativamente acima da média histórica de 1,88%. Por outro lado, a proporção de termos positivos é 0,53%, bem inferior à média da série (1,06%), reforçando o tom cauteloso adotado pelo Comitê. A ata também apresenta um vocabulário relativamente amplo, com 1.581 palavras únicas e uma riqueza lexical de 0,1614, o que indica uma diversidade moderada no uso do vocabulário.

**Figura 16**

Frequência das Palavras Positivas - FOMC (29/10/2008)

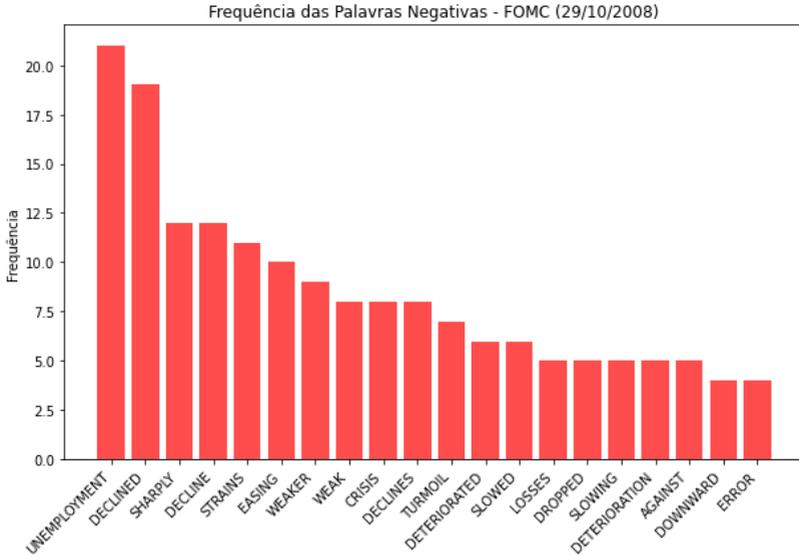


Fonte: Elaborada pelo autor.

Além do tom fortemente negativo do comunicado, a decisão tomada nessa reunião foi uma redução de 50 pontos-base na taxa de juros, que passou de 1,5% para 1%. Esse movimento agressivo na política monetária reflete a gravidade do momento econômico, no qual o Federal Reserve buscava estimular a economia em meio ao colapso dos mercados financeiros. O uso de uma linguagem mais negativa e a sinalização explícita dos riscos no comunicado foram essenciais para justificar essa decisão e alinhar as expectativas do mercado às ações do banco central.

A análise dessa ata confirma a relação entre o tom da comunicação do FOMC e o ambiente macroeconômico, evidenciando que, em períodos de crise, a linguagem se torna mais negativa e as decisões de política monetária mais agressivas.

A predominância de palavras negativas como "*unemployment*" (desemprego), que aparece 21 vezes, e "*declined*" (declinado), com 19 ocorrências, no documento, indica preocupações profundas com o aumento do desemprego e com a desaceleração acentuada da economia. Além disso, o uso de termos como "*decline*" (declínio) e "*sharply*" (acentuado) sugere que o Comitê estava preocupado com a velocidade da deterioração econômica e a possibilidade de uma recessão prolongada.

**Figura 17**

Fonte: Elaborada pelo autor.

Palavras como "*strong*"(forte) e "*stability*"(estabilidade) aparecem com uma frequência muito menor (3 e 10 ocorrências, respectivamente), evidenciando que, mesmo em meio a esse cenário negativo, o FOMC ainda destacava algumas áreas que se mostravam resilientes, embora o tom geral fosse de alerta sobre os riscos de uma desaceleração mais profunda. Termos como "*weak*"(fraco), "*weaker*"(mais fraco), "*dropped*"(despencou) e "*losses*"(perdas), com cinco a oito ocorrências cada, indicam uma percepção de que muitos indicadores econômicos estavam apresentando sinais claros de enfraquecimento.

O termo "*crisis*"(crise), que aparece oito vezes, é emblemático do tom alarmante da ata, refletindo o impacto da crise financeira e a necessidade de respostas urgentes para mitigar os danos econômicos. Além disso, palavras como "*turmoil*"(tumulto), "*deterioration*"(deterioração) e "*slowing*"(desaceleração) reforçam a imagem de um cenário instável e em declínio, sem sinais imediatos de recuperação. O uso de termos como "*strains*"(pressões) e "*easing*"(afrouxamento) sugere que o FOMC estava tentando identificar medidas para aliviar as tensões, embora as perspectivas para uma recuperação rápida parecessem remotas.

Esta ata reflete a gravidade da crise financeira, marcada por um alto grau

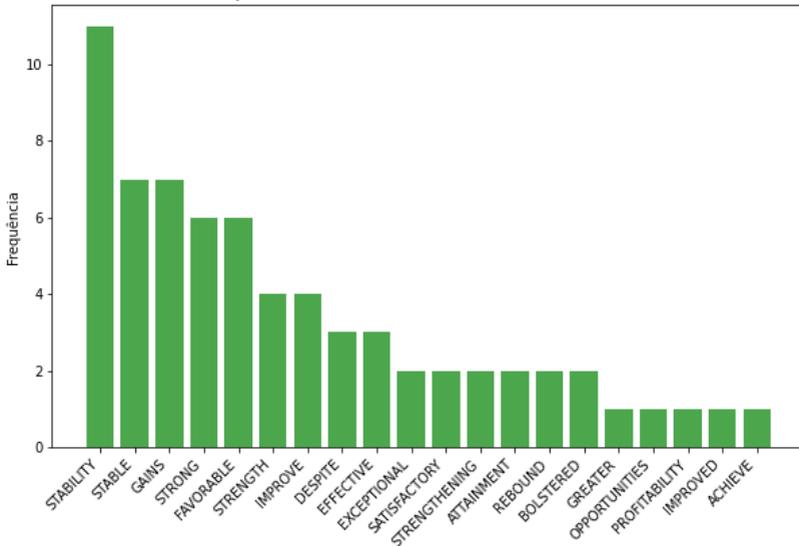
de incerteza e instabilidade, com um tom predominantemente negativo. Esse tom provavelmente teve um impacto significativo nas expectativas dos agentes de mercado e influenciou a formulação das políticas econômicas subsequentes. A ênfase no elevado desemprego, na acentuada desaceleração e nos riscos de uma crise financeira profunda sugere que o Comitê estava profundamente preocupado com os impactos de longo prazo dessa crise global, que afetava não apenas a economia dos Estados Unidos, mas também as perspectivas econômicas globais.

### 5.1.8 Análise da ata do FOMC com o tom mais positivo

A ata do FOMC de 1º de fevereiro de 2005 destaca-se como a mais positiva de toda a série histórica analisada, apresentando um tom de 0,1216. Esse otimismo reflete o ambiente econômico favorável da época, com a economia norte-americana demonstrando crescimento sólido e um mercado de trabalho em recuperação.

**Figura 18**

Frequência das Palavras Positivas - FOMC (01/02/2005)



Fonte: Elaborada pelo autor.

A ata contém 6.453 palavras, sendo 1,01% delas de conotação negativa e 1,29% positivas. A presença de um percentual maior de termos positivos do que negativos sugere uma avaliação otimista do cenário econômico pelo

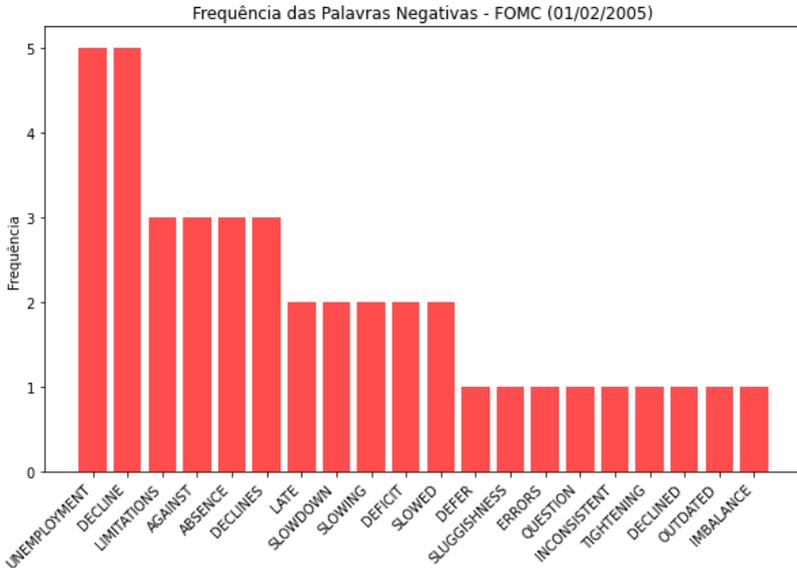
Comitê. Além disso, a ata apresenta 1.282 palavras únicas, resultando em uma riqueza lexical de 0,1987, um valor relativamente elevado que indica maior diversidade no vocabulário utilizado.

No que diz respeito à política monetária, o FOMC decidiu aumentar a taxa de juros em 25 pontos-base, elevando-a de 2,25% para 2,5%. Essa decisão estava alinhada ao ciclo de normalização da política monetária, iniciado após um período de juros baixos no início da década de 2000. O tom positivo da ata sugere que o Comitê via a economia em trajetória sustentável, permitindo ajustes graduais na taxa de juros para conter potenciais pressões inflacionárias sem comprometer o crescimento econômico.

A análise dessa ata reforça a relação entre o tom do comunicado do FOMC e o contexto macroeconômico. Em momentos de expansão econômica e otimismo, a linguagem utilizada pelo Comitê tende a ser mais positiva, acompanhando uma postura mais confiante na condução da política monetária.

As palavras mais frequentes entre as positivas incluem "*stability*" (estabilidade), com 11 ocorrências, e "*gains*" (ganhos), "*stable*" (estável) e "*favorable*" (favorável), todas transmitindo uma visão de confiança nas condições econômicas. O uso de termos como "*strong*" (forte) e "*strength*" (força) reforça a percepção de uma economia sólida, em um contexto de recuperação pós-recessão.

Além disso, palavras como "*improve*" (melhorar), "*effective*" (eficaz) e "*rebound*" (recuperação) demonstram que o FOMC via progressos significativos nas condições econômicas, refletindo um cenário em que as políticas monetárias estavam começando a dar frutos. A presença de termos como "*satisfactory*" (satisfatório) e "*excepcional*" (excepcional) indica que o Comitê estava satisfeito com os resultados alcançados até aquele momento e via perspectivas promissoras para o futuro.

**Figura 19**

Fonte: Elaborada pelo autor.

Em contraste, as palavras negativas presentes, como "*decline*" (declínio) e "*unemployment*" (desemprego), aparecem em menor frequência, sugerindo que, apesar de algumas preocupações com a desaceleração econômica e o desemprego, o foco do FOMC estava em destacar os aspectos positivos da recuperação. Termos como "*limitations*" (limitações) e "*slowdown*" (desaceleração) indicam que o Comitê reconhecia desafios, mas esses foram amplamente superados pela ênfase nas forças de recuperação da economia.

O tom geral da ata de fevereiro de 2005 sugere que o FOMC estava transmitindo uma mensagem de otimismo e confiança, o que provavelmente ajudou a moldar as expectativas do mercado e a incentivar uma visão mais positiva sobre o futuro da economia dos Estados Unidos. Esse tom positivo foi essencial para fortalecer a confiança do mercado, especialmente em um momento em que a economia estava saindo de uma recessão e entrando em um ciclo de crescimento.

## 5.2 Desempenho preditivo dos modelos

As Tabelas 7, 8, 9 e 10 apresentam o desempenho das previsões para todos os modelos listados na Tabela 1 nos horizontes de previsão de 1, 3, 6

e 12 passos à frente. Como o modelo de passeio aleatório (RW) é utilizado como referência, apenas suas colunas exibem o RMSE em pontos percentuais, enquanto as demais apresentam a raiz do erro quadrático médio de cada modelo em relação ao benchmark. Valores inferiores a um indicam que o modelo supera o benchmark, enquanto valores superiores a um indicam desempenho inferior. Adicionalmente, as tabelas destacam em negrito e com (\*) os modelos que apresentaram diferenças estatisticamente significativas em relação ao passeio aleatório.

**Tabela 7**  
**Horizonte de previsão de 1 mês**

Maturidade	RW	Modelo I	Modelo II	Modelo III	Modelo IV	Modelo V
3 meses	0.4491	<b>0.6087*</b>	<b>0.5361*</b>	<b>0.5331*</b>	<b>0.5250*</b>	<b>0.5498*</b>
6 meses	0.4668	<b>0.6146*</b>	<b>0.6297*</b>	<b>0.5914*</b>	<b>0.5895*</b>	<b>0.5863*</b>
9 meses	0.4958	<b>0.7487*</b>	<b>0.7716*</b>	<b>0.7410*</b>	<b>0.7378*</b>	<b>0.7284*</b>
12 meses	0.5331	<b>0.8391*</b>	<b>0.8528*</b>	<b>0.8351*</b>	<b>0.8325*</b>	<b>0.8225*</b>
15 meses	0.5551	<b>0.8808*</b>	<b>0.8853*</b>	<b>0.8783*</b>	<b>0.8751*</b>	<b>0.8668*</b>
18 meses	0.5735	<b>0.9069*</b>	<b>0.9009*</b>	<b>0.9027*</b>	<b>0.8957*</b>	<b>0.8901*</b>
21 meses	0.5889	0.9289	<b>0.9126*</b>	0.9216	<b>0.9119*</b>	0.9092
24 meses	0.5959	0.9552	0.9306	0.9442	0.9314	0.9317
30 meses	0.6046	1.0082	0.9688	0.9870	0.9667	0.9751
36 meses	0.6047	1.0330	0.9882	1.0054	0.9837	0.9947
42 meses	0.6057	1.0262	0.9837	0.9990	0.9801	0.9897
48 meses	0.6023	1.0095	0.9828	0.9942	0.9830	0.9879
60 meses	0.5874	1.0007	1.0241	1.0250	1.0345	1.0250

Fonte: Elaborada pelo autor.

A Tabela 7 apresenta os resultados da previsão para um horizonte de 1 mês, comparando o desempenho dos modelos em diferentes maturidades. Os resultados mostram que, para maturidades mais curtas (até 18 meses), todos os modelos propostos apresentam desempenho significativamente superior ao passeio aleatório, sugerindo ganhos preditivos robustos no curto prazo. Destaca-se que, para maturidades de 3 a 18 meses, os modelos IV e V que utilizam os dados do tom do COPOM e do FOMC respectivamente, obtêm os menores erros relativos ao RW, apontando para sua maior eficácia na previsão de curto prazo.

No entanto, à medida que a maturidade aumenta, a vantagem dos modelos sobre o RW diminui. A partir de 21 meses, os valores dos modelos se aproximam do benchmark, e para maturidades superiores a 24 meses, os modelos deixam de apresentar superioridade estatística em relação ao passeio aleatório. Além disso, observa-se que, para os prazos mais longos (acima de 36 meses), alguns modelos apresentam valores próximos ou ligeiramente superiores a 1, indicando que seu desempenho é equivalente ou inferior ao RW para previsões de longo prazo.

Esses resultados sugerem que os modelos baseados em fatores latentes são

mais eficazes na previsão da estrutura a termo de curto e médio prazo, mas sua vantagem preditiva tende a se dissipar conforme a maturidade aumenta.

**Tabela 8**  
**Horizonte de Previsão de 3 Meses**

Maturidade	RW	Modelo I	Modelo II	Modelo III	Modelo IV	Modelo V
3 meses	1.2768	<b>0.4758*</b>	<b>0.4702*</b>	<b>0.4512*</b>	<b>0.4398*</b>	<b>0.4308*</b>
6 meses	1.2925	<b>0.5900*</b>	<b>0.5925*</b>	<b>0.5750*</b>	<b>0.5603*</b>	<b>0.5466*</b>
9 meses	1.3088	<b>0.6798*</b>	<b>0.6833*</b>	<b>0.6696*</b>	<b>0.6517*</b>	<b>0.6376*</b>
12 meses	1.3228	<b>0.7412*</b>	<b>0.7431*</b>	<b>0.7328*</b>	<b>0.7131*</b>	<b>0.6995*</b>
15 meses	1.3216	<b>0.7791*</b>	<b>0.7786*</b>	<b>0.7724*</b>	<b>0.7502*</b>	<b>0.7387*</b>
18 meses	1.3075	<b>0.8155*</b>	<b>0.8099*</b>	<b>0.8073*</b>	<b>0.7820*</b>	<b>0.7725*</b>
21 meses	1.2935	<b>0.8471*</b>	<b>0.8339*</b>	<b>0.8357*</b>	<b>0.8065*</b>	0.8015
24 meses	1.2753	0.8776	0.8566	0.8625	0.8285	0.8292
30 meses	1.2381	0.9376	0.9042	0.9155	0.8728	0.8848
36 meses	1.2072	0.9744	0.9326	0.9474	0.9000	0.9202
42 meses	1.1921	0.9922	0.9470	0.9641	0.9155	0.9405
48 meses	1.1748	0.9919	0.9505	0.9674	0.9212	0.9476
60 meses	1.1363	0.9756	0.9521	0.9653	0.9294	0.9511

Fonte: Elaborada pelo autor.

A Tabela 8 apresenta os resultados da previsão para um horizonte de 3 meses, os resultados indicam que todos os modelos propostos superam significativamente o passeio aleatório para maturidades de até 21 meses. Em particular, os Modelos IV e V apresentam os menores erros relativos ao RW em praticamente todas as maturidades dentro desse intervalo, reforçando sua superioridade preditiva para horizontes de curto e médio prazo.

A partir de 24 meses, observa-se uma redução no desempenho relativo dos modelos, com alguns valores próximos ou acima de 1, indicando que a vantagem preditiva em relação ao passeio aleatório se torna menos evidente. Para maturidades superiores a 30 meses, nenhum modelo se destaca estatisticamente em relação ao RW, sugerindo que a capacidade preditiva dos modelos baseados em fatores latentes se dissipa gradualmente no longo prazo.

Esses resultados confirmam a robustez dos modelos para previsões de curto e médio prazo, mas também apontam para desafios na previsão de maturidades mais longas, onde o passeio aleatório se mostra um competidor difícil de superar.

**Tabela 9**  
**Horizonte de Previsão de 6 Meses**

Maturidade	RW	Modelo I	Modelo II	Modelo III	Modelo IV	Modelo V
3 meses	2.453	<b>0.5576*</b>	<b>0.5638*</b>	<b>0.5510*</b>	<b>0.5394*</b>	<b>0.5188*</b>
6 meses	2.457	<b>0.6350*</b>	<b>0.6464*</b>	<b>0.6346*</b>	<b>0.6209*</b>	<b>0.5992*</b>
9 meses	2.452	<b>0.6922*</b>	<b>0.7077*</b>	<b>0.6958*</b>	<b>0.6815*</b>	<b>0.6585*</b>
12 meses	2.436	<b>0.7348*</b>	<b>0.7518*</b>	<b>0.7400*</b>	<b>0.7256*</b>	<b>0.7017*</b>
15 meses	2.393	<b>0.7649*</b>	<b>0.7815*</b>	<b>0.7700*</b>	<b>0.7550*</b>	<b>0.7308*</b>
18 meses	2.330	<b>0.7956*</b>	<b>0.8100*</b>	<b>0.7996*</b>	<b>0.7825*</b>	<b>0.7596*</b>
21 meses	2.268	<b>0.8237*</b>	<b>0.8339*</b>	<b>0.8250*</b>	<b>0.8058*</b>	<b>0.7852*</b>
24 meses	2.197	0.8515	0.8568	0.8493	0.8277	0.8097
30 meses	2.048	0.9069	0.9018	0.8974	0.8713	0.8586
36 meses	1.922	0.9523	0.9358	0.9345	0.9052	0.8973
42 meses	1.823	0.9888	0.9636	0.9649	0.9331	0.9296
48 meses	1.740	1.0068	0.9754	0.9779	0.9458	0.9443
60 meses	1.610	1.0210	0.9835	0.9865	0.9568	0.9547

Fonte: Elaborada pelo autor.

A Tabela 9 apresenta os resultados da previsão para um horizonte de 6 meses, onde todos os modelos superaram significativamente o RW para maturidades de até 21 meses com os Modelos IV e V apresentando os menores erros relativos ao RW em quase todas essas maturidades, reforçando sua robustez para previsões de curto e médio prazo.

A partir de 24 meses, observa-se um enfraquecimento da superioridade preditiva dos modelos, com os valores se aproximando de 1. Para maturidades superiores a 30 meses, os erros dos modelos começam a convergir para os valores do passeio aleatório, sugerindo que a capacidade preditiva se dissipa no longo prazo.

Esses achados indicam que, embora os modelos consigam fornecer previsões mais precisas para horizontes de até 21 meses, sua vantagem preditiva diminui progressivamente conforme o horizonte se estende, tornando o passeio aleatório uma alternativa mais competitiva para previsões de longo prazo.

**Tabela 10**  
**Horizonte de Previsão de 12 Meses**

Maturidade	RW	Modelo I	Modelo II	Modelo III	Modelo IV	Modelo V
3 meses	4.4341	<b>0.6864*</b>	<b>0.7281*</b>	<b>0.7183*</b>	<b>0.7085*</b>	<b>0.6899*</b>
6 meses	4.4267	<b>0.7298*</b>	<b>0.7806*</b>	<b>0.7699*</b>	<b>0.7604*</b>	<b>0.7411*</b>
9 meses	4.4095	<b>0.7605*</b>	<b>0.8176*</b>	<b>0.8062*</b>	<b>0.7968*</b>	<b>0.7774*</b>
12 meses	4.3697	<b>0.7819*</b>	<b>0.8422*</b>	<b>0.8309*</b>	<b>0.8209*</b>	<b>0.8024*</b>
15 meses	4.2933	<b>0.7976*</b>	<b>0.8594*</b>	<b>0.8484*</b>	<b>0.8374*</b>	<b>0.8201*</b>
18 meses	4.1816	<b>0.8130*</b>	0.8758	0.8651	0.8528	0.8370
21 meses	4.0650	0.8259	0.8887	0.8784	0.8648	0.8506
24 meses	3.9327	0.8387	0.9011	0.8914	0.8765	0.8640
30 meses	3.6564	0.8644	0.9257	0.9167	0.8993	0.8900
36 meses	3.4177	0.8855	0.9448	0.9361	0.9171	0.9101
42 meses	3.2118	0.9028	0.9603	0.9519	0.9316	0.9264
48 meses	3.0454	0.9133	0.9688	0.9608	0.9395	0.9354
60 meses	2.7911	0.9237	0.9762	0.9686	0.9456	0.9430

Fonte: Elaborada pelo autor.

A Tabela 10 apresenta os resultados da previsão para um horizonte de 12 meses e para as previsões de maturidades menores (até 15 meses), todos os modelos apresentam um desempenho significativamente melhor que o RW. Os Modelos IV e V continuam demonstrando um desempenho superior, destacando-se na redução do erro de previsão.

A partir de 18 meses, observa-se que os modelos ainda mantêm uma performance levemente melhor que o RW, mas a vantagem começa a se reduzir. Para maturidades acima de 21 meses, os valores dos modelos convergem gradualmente para os do RW, indicando que a capacidade preditiva dos modelos diminui à medida que o horizonte de previsão se alonga.

Esse comportamento reforça a ideia de que os modelos são eficazes na previsão da curva de juros para horizontes de curto e médio prazo, mas sua vantagem preditiva em relação ao RW se dissipa no longo prazo. Isso pode estar associado ao aumento da incerteza e à dificuldade de capturar corretamente os efeitos dinâmicos que influenciam a estrutura a termo da taxa de juros em períodos mais longos.

### 5.3 Impacto das variáveis textuais na previsão da curva de juros

A análise dos resultados para os horizontes de previsão de 1, 3, 6 e 12 meses revela padrões distintos no desempenho dos modelos concorrentes em relação ao passeio aleatório (RW). Os modelos que incorporam informações textuais das atas do COPOM e do FOMC demonstraram capacidade preditiva superior, reduzindo os erros de previsão e destacando a relevância das comunicações dos bancos centrais para a formação da curva de juros.

O Modelo I, que não utiliza dados textuais, já supera o RW, indicando que a estrutura do modelo dinâmico de Nelson-Siegel captura bem a dinâmica da curva de juros. Trabalhos como os de [Diebold e Li \(2006\)](#) sobre a curva de juros destacam que previsões de curto prazo são mais precisas quando utilizam fatores dinâmicos, enquanto previsões de longo prazo se beneficiam de modelos mais simples e robustos.

No entanto, ao incluir variáveis textuais, observa-se uma redução adicional nos erros, reforçando o valor informacional contido nos textos das atas dos comitês de política monetária. Esse resultado está em conformidade com os achados de [Bholat et al. \(2015\)](#), que demonstram que o tom das comunicações dos bancos centrais exerce influência sobre as expectativas de mercado. Segundo os autores, a análise textual dessas comunicações pode fornecer sinais relevantes para antecipar movimentos econômicos, sugerindo que a incorporação de dados textuais em modelos preditivos melhora a capacidade de capturar nuances do comportamento econômico.

Dentre os modelos com dados textuais, os Modelos IV e V, que utilizam o tom das atas do Copom e do FOMC, respectivamente, apresentam os menores erros preditivos ao longo dos diferentes horizontes, sugerindo que o tom geral do discurso dos bancos centrais é um forte preditor da curva de juros. Isso é corroborado pela literatura, que destaca que o tom das discussões nas atas do FOMC, está relacionado de forma significativa com a atividade econômica real. A análise de [Cannon \(2015\)](#) sobre como agentes econômicos com racionalidade limitada simplificam o processo decisório também sugere que o tom nas discussões pode refletir uma visão simplificada e eficiente da realidade econômica, o que contribui para previsões mais robustas.

Os Modelos II e III, que utilizam o sentimento negativo das atas, também melhoram a previsão, mas de forma menos expressiva, refletindo uma abordagem mais restrita ao focar apenas em emoções negativas, em contraste com a análise mais ampla do tom nas discussões do COPOM e do FOMC.

À medida que o horizonte de previsão aumenta, a vantagem dos modelos sobre o RW e sobre o Modelo I persiste, mas diminui gradualmente. No horizonte de 12 meses, os modelos ainda apresentam desempenho superior, mas as diferenças entre eles se tornam menos significativas, indicando que a influência das variáveis textuais se concentra no curto e médio prazo. Resultado que são bem parecidos com os obtidos no trabalho de [Andrade Alves et al. \(2023\)](#), onde incorporar o sentimento de Banco Central do Brasil melhora as previsões de curto prazo e torna as previsões de longo prazo mais competitivas.

Em síntese, os resultados mostram que a inclusão de dados textuais melhora a previsão da curva de juros, especialmente em horizontes mais curtos. Além disso, o tom das atas parece conter mais informações relevantes do que a simples contagem de termos negativos, sugerindo que a forma como os bancos centrais comunicam suas decisões desempenha um papel importante na formação das expectativas do mercado.

#### 5.4 Análise dos Resultados do CSFE

Para investigar o comportamento das previsões ao longo do período de previsão, analisamos o erro quadrático cumulativo de previsão (CSFE). Essa medida de precisão foi calculada utilizando o modelo *Random Walk* (RW) como referência. No apêndice, apresentamos os resultados para os horizontes de previsão de 1, 3, 6 e 12 meses.

Os gráficos apresentados ilustram a evolução do CSFE ao longo do tempo para diferentes maturidades da curva de juros. Os cinco modelos avaliados são representados por diferentes cores nos gráficos, permitindo uma comparação direta do desempenho preditivo de cada um. A inclinação das curvas fornece

informações importantes sobre o desempenho dos modelos: uma inclinação positiva indica um desempenho superior do modelo em relação ao benchmark, enquanto uma inclinação negativa representa um desempenho inferior.

Previsões 1 passo a frente:

Curto Prazo (1 a 12 meses de maturidade): O CSFE cresce de forma relativamente estável nos primeiros 20 meses, mas apresenta um aumento expressivo a partir do mês 30. Todos os modelos seguem trajetórias similares, com pequenas diferenças entre eles. A diferença de desempenho entre os modelos é menos pronunciada nesta faixa de maturidade, porém é perceptivo que o modelo V apresenta um resultado superior aos demais, seguido do modelo IV.

Médio Prazo (15 a 30 meses de maturidade): Um padrão semelhante ao observado no curto prazo é identificado, com um aumento acentuado do CSFE após o mês 30. Pequenas discrepâncias entre os modelos tornam-se evidentes, especialmente após os choques identificados. O Modelo I apresenta desempenho levemente inferior em alguns pontos, enquanto os Modelos V e IV tendem a apresentar valores mais elevados de CSFE.

Longo Prazo (36 a 60 meses de maturidade): O CSFE é significativamente menor em relação às maturidades mais curtas, indicando que o benchmark apresenta melhor desempenho para previsões de longo prazo. Nos primeiros 20 meses, observa-se maior volatilidade, o que sugere uma dificuldade maior dos modelos em prever corretamente esses horizontes. A partir do mês 30, é possível identificar um aumento acentuado no CSFE, o que pode refletir um período de instabilidade econômica ou mudanças estruturais no mercado. O Modelo I apresenta um CSFE mais baixo em algumas maturidades (36 a 48 meses), enquanto o Modelo IV tende a registrar os maiores valores. Contudo, na maturidade de 60 meses, as posições dos modelos se invertem, com o Modelo I apresentando um desempenho ligeiramente melhor.

Previsões 3 passo a frente:

Curto Prazo (1 a 12 meses de maturidade): As curvas seguem o mesmo padrão observado no horizonte de 1 passo à frente, com um crescimento relativamente estável nos primeiros 20 meses, mas apresentando um aumento expressivo a partir do mês 24. As diferenças de desempenho entre os modelos tornam-se mais acentuadas a partir do mês 32, quando fica evidente que os Modelos V e IV apresentam resultados superiores aos demais.

Médio Prazo (15 a 30 meses de maturidade): Os modelos começam com uma performance levemente inferior ao benchmark, mas apresentam uma melhora por volta do mês 24. A partir do mês 32, o Modelo I, II e III exibem desempenhos levemente inferiores, enquanto os Modelos V e IV tendem a

registrar valores mais elevados de CSFE.

Longo Prazo (36 a 60 meses de maturidade): O CSFE é menor para as previsões de curto prazo, com os primeiros 20 meses apresentando desempenho inferior ao benchmark, seguido por uma melhora entre os meses 24 e 32. Após esse período, observa-se uma estabilização, sem inclinação significativa. No longo prazo, ocorre uma inversão nas posições, com o Modelo IV apresentando desempenho superior ao Modelo V. O Modelo I, por sua vez, exibe o pior desempenho entre todos os modelos.

Previsões 6 passo a frente:

Curto Prazo (1 a 12 meses de maturidade): As curvas apresentam um crescimento relativamente estável nos primeiros 20 meses, com um aumento expressivo a partir do mês 24. A partir do mês 32, as diferenças entre os modelos tornam-se mais acentuadas, com os Modelos V e IV apresentando, respectivamente, resultados superiores aos demais.

Médio Prazo (15 a 30 meses de maturidade): A performance nos primeiros 20 meses é abaixo do benchmark, com um aumento do CSFE por volta do mês 20. A partir do mês 32, os Modelos I, II e III apresentam desempenhos levemente inferiores, enquanto os Modelos IV e V tendem a registrar valores mais elevados de CSFE.

Longo Prazo (36 a 60 meses de maturidade): O CSFE é menor nos primeiros 20 meses, apresentando desempenho inferior ao benchmark, seguido por uma melhora entre os meses 24 e 32. Após esse período, observa-se uma estabilização, sem inclinação significativa. No longo prazo, os Modelos IV e V apresentam desempenhos muito semelhantes, enquanto o Modelo I exibe o desempenho mais baixo entre todos os modelos.

Previsões 12 passo a frente:

Curto Prazo (1 a 12 meses de maturidade): As curvas apresentam um crescimento relativamente baixo nos primeiros 20 meses, a partir dos quais começa a haver um aumento. Até esse ponto, os modelos exibem desempenhos semelhantes, mas o Modelo I começa a apresentar um desempenho ligeiramente superior aos demais.

Médio Prazo (15 a 30 meses de maturidade): Com a performance nos primeiros 20 meses abaixo do benchmark e um aumento do CSFE por volta do mês 20, o Modelo I começa a apresentar um desempenho superior aos outros modelos nos períodos médio e longo.

Longo Prazo (36 a 60 meses de maturidade): As maturidades mais longas apresentam um CSFE menor nos primeiros 15 meses, com desempenho inferior ao benchmark, seguido por uma melhora entre os meses 15 e 32. Após

esse período, observa-se uma diminuição na precisão. Contudo, o Modelo I apresenta um desempenho superior aos outros modelos a partir do mês 15.

## 5.5 Discussão dos principais achados do CSFE

Esses resultados evidenciam que, embora o passeio aleatório se apresente como um concorrente desafiador – conforme indicado pelos estudos de [Diebold e Li \(2006\)](#), [Vicente e Tabak \(2008\)](#) e [Caldeira e Torrent \(2017\)](#) – a incorporação de variáveis textuais ao modelo DNS modifica a dinâmica preditiva de maneira significativa. Em particular, os modelos exibem comportamentos distintos ao longo dos diferentes horizontes de previsão. Para as previsões de 1, 3 e 6 passos, os modelos apresentaram resultados semelhantes nos primeiros 20 meses, com um desempenho ligeiramente superior ao benchmark. No entanto, observou-se uma melhora significativa entre os períodos de 20 a 32 meses, com os Modelos V (Tom do FOMC) e IV (Tom do COPOM) apresentando as melhores performances, enquanto o Modelo I (sem dados textuais) obteve o pior desempenho. Esse comportamento reflete a capacidade dos modelos baseados em dados textuais de capturar dinâmicas mais sutis, principalmente no médio prazo.

Para a previsão de 12 passos, o cenário revelou uma dinâmica particular: o benchmark se destacou nos primeiros 15 meses e o Modelo I (sem dados textuais) superou os demais nesse período, sugerindo que a simplicidade inerente a esse modelo pode ser vantajosa em cenários de longo prazo. De forma complementar, enquanto modelos mais complexos tendem a captar com maior precisão os padrões sutis no curto e médio prazo, eles podem se tornar menos robustos para previsões em horizontes mais longos, especialmente em contextos de elevada incerteza. Estudos, como os de [Green e Armstrong \(2015\)](#) e [Stock e Watson \(2007\)](#), reforçam essa perspectiva ao demonstrar que, embora modelos sofisticados apresentem desempenho superior em horizontes curtos, sua capacidade preditiva decai conforme o horizonte se expande, o que indica que abordagens mais simples podem ser mais eficazes para previsões de longo prazo.

De maneira geral, em todos os horizontes de previsão, observa-se um padrão consistente: o benchmark apresenta um desempenho superior nos primeiros meses, com um resultado inferior no médio prazo e um desempenho mais equilibrado no longo prazo, por vezes até melhor do que os modelos. A variabilidade dos resultados aumenta à medida que o horizonte de previsão se estende, o que reflete a maior incerteza associada a previsões de longo prazo.

Esses achados sugerem que a inclusão de dados textuais melhora as previsões em horizontes mais curtos, mas que modelos mais simples, como o

Modelo I, podem ser mais eficazes a longo prazo devido à sua robustez.

## 6. Conclusão

Este trabalho investigou a previsão da curva de juros utilizando dados textuais, com ênfase na análise das atas do COPOM e do FOMC. Para isso, foram utilizados modelos econométricos baseados na estrutura de Nelson-Siegel e suas extensões dinâmicas, incorporando informações extraídas das atas por meio de métodos de análise de sentimento e estatísticas descritivas do texto. O objetivo principal foi avaliar se a inclusão dessas variáveis textuais melhora a precisão preditiva da curva de juros.

Os resultados empíricos indicaram que a incorporação de variáveis textuais pode agregar informação relevante à previsão da curva de juros. A comparação entre os modelos foi realizada por meio de métricas como RMSE e CEFS, bem como pelo teste de Diebold-Mariano modificado. Os resultados sugerem que modelos que incluem informação textual das atas podem superar modelos tradicionais em termos de precisão preditiva, especialmente em horizontes de curto e médio prazo.

No que se refere à metodologia, a utilização do filtro de Kalman para a estimação dos parâmetros da curva de Nelson-Siegel mostrou-se adequada para capturar a dinâmica da estrutura a termo dos juros. Ademais, a previsão por origem rolante permitiu uma avaliação mais robusta do desempenho dos modelos, garantindo que os resultados fossem consistentes ao longo do tempo.

Apesar dos avanços apresentados, este estudo possui algumas limitações. Primeiramente, a análise foi conduzida com base nas atas do COPOM e do FOMC, para trabalhos futuros, sugere-se a investigação do impacto de outras fontes textuais, como discursos de autoridades, notícias, principais palavras pesquisadas em sites de busca ou até mesmo comentários de rede sociais.

Além disso, técnicas mais avançadas de processamento de linguagem natural, como modelos de deep learning, poderiam ser incorporadas para refinar a extração de informação dos textos e assim contribuir para uma compreensão ainda mais aprofundada da relação entre a comunicação do banco central e a curva de juros.

Contudo, a incorporação das atas do FOMC, integrando os dados textuais de dois centros de política monetária, juntamente com a ampliação das maturidades analisadas, com ênfase especial nas maturidades mais longas, permitiram avaliar não apenas os efeitos de curto e médio prazo, mas também captar as expectativas e dinâmicas que influenciam os prazos mais extensos da curva de juros. Contribuindo para a discussão sobre previsão da curva de juros

brasileira usando dados textuais abordado pelo [Andrade Alves et al. \(2023\)](#).

Dessa forma, esta dissertação contribui para a literatura ao demonstrar que a informação contida nas atas do COPOM e do FOMC, principalmente o tom dos comunicados podem aprimorar previsões da curva de juros, abrindo caminho para novas pesquisas que integrem análise textual e previsão macroeconômica.

**Inteligência Artificial** Esta pesquisa utilizou ferramentas de inteligência artificial (IA) como apoio nas etapas de análise de dados, redação do manuscrito e geração de figuras. Todo o conteúdo gerado com auxílio de IA foi criteriosamente revisado e validado pelos autores, assegurando a precisão das informações e a conformidade com os princípios de integridade científica. O uso dessas ferramentas seguiu diretrizes éticas, com total transparência e em conformidade com os padrões acadêmicos. Possíveis vieses ou limitações inerentes às tecnologias de IA foram cuidadosamente considerados na interpretação dos resultados. Os autores afirmam que o uso de IA não comprometeu a originalidade nem a integridade do trabalho.

## Referências

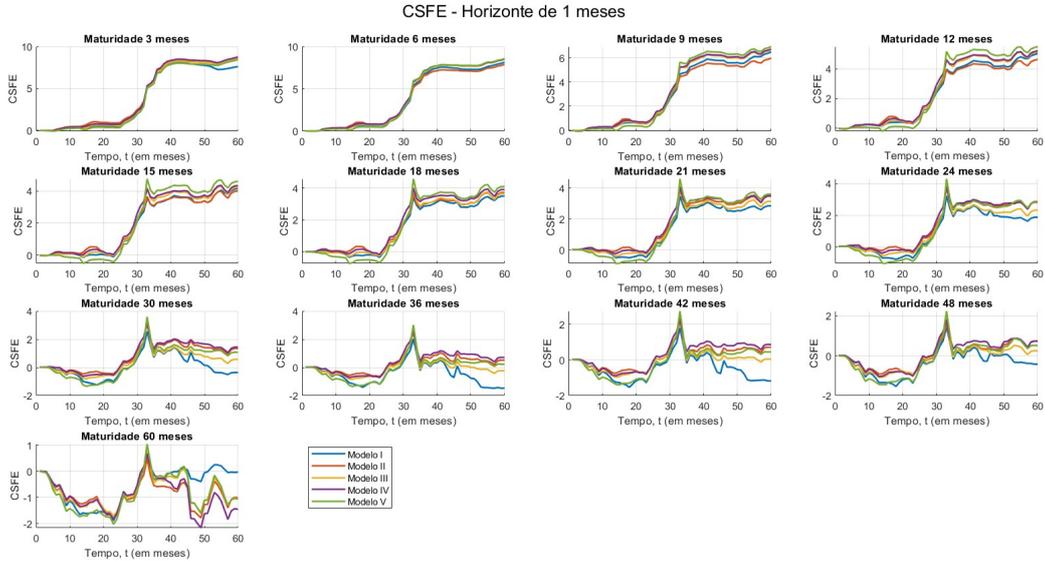
- Andrade Alves, C. R. d., Abraham, K. J. e Laurini, M. P. (2023). Can sentiment of the brazilian central bank help to predict yield curve?, *Journal of Forecasting*.
- Ang, A. e Piazzesi, M. (2003). A no-arbitrage vector autoregression of term structure dynamics with macroeconomic and latent variables, *Journal of Monetary economics* **50**(4): 745–787.
- Bernanke, B. S. (2004). Central bank talk and monetary policy, technical report, remarks at the japan society corporate luncheon.
- Bholat, D., Hansen, S., Santos, P. e Schonhardt-Bailey, C. (2015). Text mining for central bank communication: Should economists pay more attention to what they say?, *Bank of England Working Papers* (137).
- Boukus, E. e Rosenberg, J. V. (2006). The information content of fomc minutes, *Available at SSRN 922312*.
- Caldeira, J. e Torrent, H. (2017). Forecasting the us term structure of interest rates using nonparametric functional data analysis, *Journal of Forecasting* **36**(1): 56–73.

- Cannon, S. (2015). Sentiment of the fomc: unscripted., *Economic review (Federal Reserve Bank of Kansas City)* **100**(4).
- Chague, F., De-Losso, R., Giovannetti, B. e Manoel, P. (2015). Central bank communication affects the term-structure of interest rates, *Revista Brasileira de Economia* **69**: 147–162.
- Costa Filho, A. E. e Rocha, F. (2010). Como o mercado de juros futuros reage à comunicação do banco central?, *Economia aplicada* **14**: 265–292.
- Dankner, D. J. e Luecke, M. M. (2005). Background on fomc meeting minutes, *Fed. Res. Bull.* **91**: 175.
- Diebold, F. X. e Li, C. (2006). Forecasting the term structure of government bond yields, *Journal of econometrics* **130**(2): 337–364.
- Diebold, F. X. e Mariano, R. S. (1995). Comparing predictive accuracy, *Journal of Business & economic statistics* **20**(1): 134–144.
- Diebold, F. X. e Rudebusch, G. D. (2013). *Yield curve modeling and forecasting: the dynamic Nelson-Siegel approach*, Princeton University Press.
- Diebold, F. X., Rudebusch, G. D. e Aruoba, S. B. (2006). The macroeconomy and the yield curve: a dynamic latent factor approach, *Journal of econometrics* **131**(1-2): 309–338.
- Green, K. C. e Armstrong, J. S. (2015). Simple versus complex forecasting: The evidence, *Journal of Business Research* **68**(8): 1678–1685. Special Issue on Simple Versus Complex Forecasting.
- Harvey, D., Leybourne, S. e Newbold, P. (1997). Testing the equality of prediction mean squared errors, *International Journal of forecasting* **13**(2): 281–291.
- Joslin, S., Singleton, K. J. e Zhu, H. (2011). A new perspective on gaussian dynamic term structure models, *The Review of Financial Studies* **24**(3): 926–970.
- Lima, L. R. e Godeiro, L. (2022). Quantile forecasting with textual data, *Available at SSRN 4515134* .
- Litterman, R. e Scheinkman, J. (1991). Common factors affecting bond returns, *Journal of fixed income* pp. 54–61.

- 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.
- Lucca, D. O. e Trebbi, F. (2009). Measuring central bank communication: an automated approach with application to fomc statements, *Technical report*, National Bureau of Economic Research.
- Mishra, A. K., Singh, K. e Mishra, A. K. (2024). [Spline function interpolation techniques for generating smooth curve](#), *Journal of mechanics of continua and mathematical sciences* **19**(9).
- Nelson, C. R. e Siegel, A. F. (1987). Parsimonious modeling of yield curves, *Journal of business* pp. 473–489.
- Piazzesi, M. (2010). Affine term structure models, *Handbook of financial econometrics: Tools and Techniques*, Elsevier, pp. 691–766.
- Silva, P. H. N. et al. (2020). Mensurando o sentimento de incerteza da política econômica: uma análise a partir da comunicação do banco central do brasil.
- Stock, J. H. e Watson, M. W. (2007). Why has us inflation become harder to forecast?, *Journal of Money, Credit and banking* **39**: 3–33.
- Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy: an analysis and review, *International journal of forecasting* **16**(4): 437–450.
- Tetlock, P. C. (2007). Giving content to investor sentiment: The role of media in the stock market, *The Journal of finance* **62**(3): 1139–1168.
- Vajjala, S., Majumder, B., Gupta, A. e Surana, H. (2020). *Practical natural language processing: A comprehensive guide to building real-world NLP systems*, O’Reilly Media.
- Vaz, L. V. e Raad, R. J. (2022). [Functional data analysis for brazilian term structure of interest rate curves](#), *Brazilian Review of Finance* .
- Vicente, J. e Tabak, B. M. (2008). Forecasting bond yields in the brazilian fixed income market, *International Journal of Forecasting* **24**(3): 490–497.
- Welch, I. e Goyal, A. (2008). A comprehensive look at the empirical performance of equity premium prediction, *The Review of Financial Studies* **21**(4): 1455–1508.
- Woodford, M. (2005). Central bank communication and policy effectiveness.

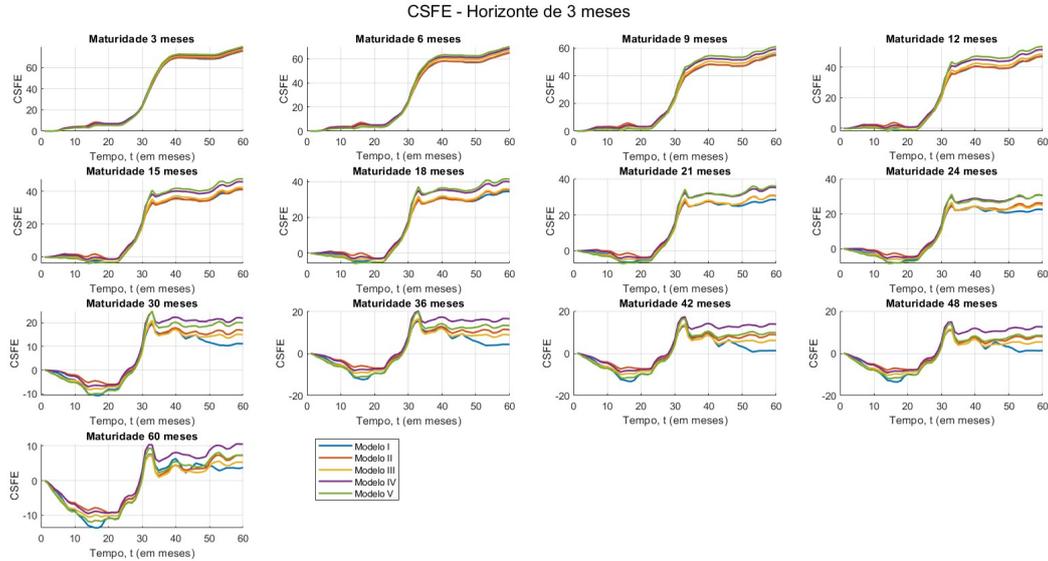
## A. Erro quadrático cumulativo de previsão

Figura A1



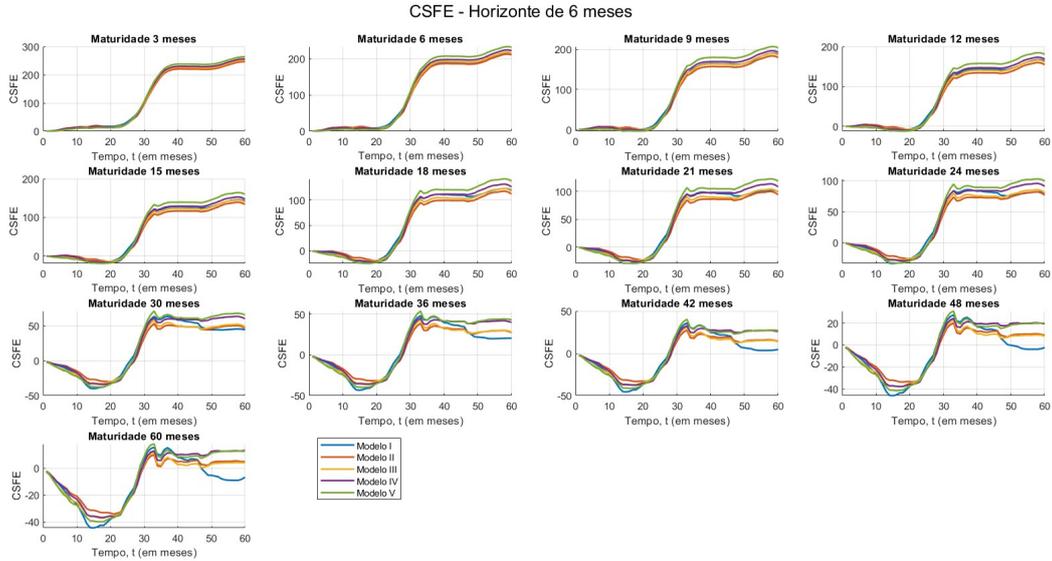
Fonte: Elaborada pelo autor. Erros quadráticos cumulativos de previsão (CSFE) para um passo à frente: um aumento na linha indica que o modelo nomeado apresentou desempenho superior, enquanto uma diminuição aponta para um melhor desempenho do passeio aleatório.

Figura A2



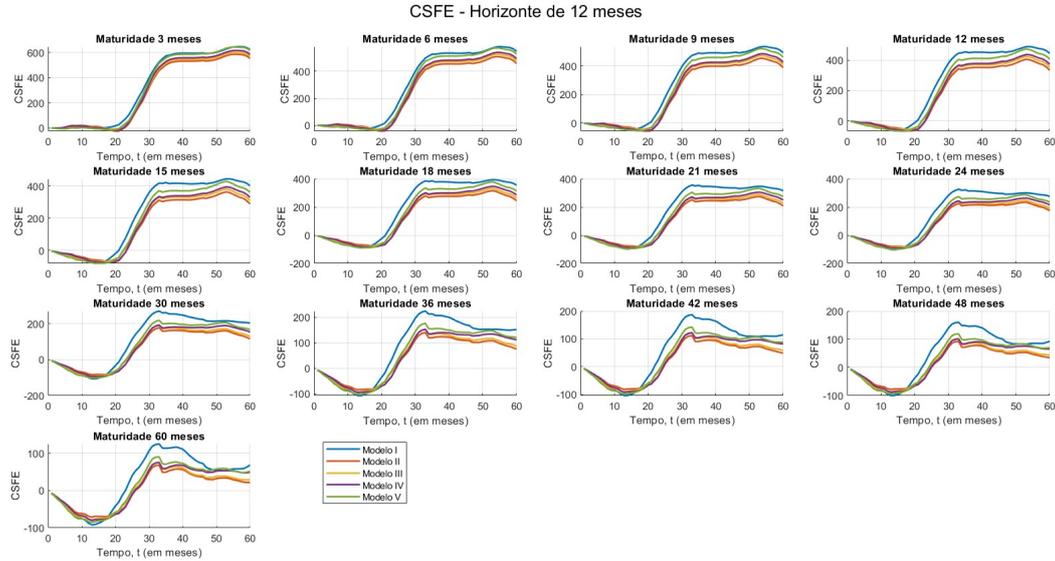
Elaborada pelo autor. Erros quadráticos cumulativos de previsão (CSFE) para três passos à frente: um aumento na linha indica que o modelo nomeado apresentou desempenho superior, enquanto uma diminuição aponta para um melhor desempenho do passeio aleatório.

Figura A3



Elaborada pelo autor. Erros quadráticos cumulativos de previsão (CSFE) para seis passos à frente: um aumento na linha indica que o modelo nomeado apresentou desempenho superior, enquanto uma diminuição aponta para um melhor desempenho do passeio aleatório.

Figura A4



Elaborada pelo autor. Erros quadráticos cumulativos de previsão (CSFE) para doze passos à frente: um aumento na linha indica que o modelo nomeado apresentou desempenho superior, enquanto uma diminuição aponta para um melhor desempenho do passeio aleatório.