

# Utilização de Notícias de Mercado para Diversificação em Investimentos com Criptoativos

Categoria do Projeto: Pesquisa

Aluno: Matias Antônio Lima <sup>\*1</sup> and Coordenador : Daniel Reed Bergmann <sup>†1</sup>

<sup>1</sup>Faculdade de Economia, Administração, Contabilidade e Atuária da Universidade de São Paulo.

**Resumo:** Neste estudo, aplicamos métodos de deep learning e processamento de linguagem natural para construir a distribuição de visões no modelo Black-Litterman. Implementamos essa abordagem para alocação de portfólio e realizamos uma análise com alguns indicadores para avaliar o desempenho do portfólio. A análise empírica produz dois principais resultados. Entre os dois modelos de deep learning utilizados, comparamos os resultados das previsões utilizando o erro quadrático médio (MSE). O modelo de memória de longo curto prazo (LSTM) supera o modelo Gated Recurrent Unit(GRU) na previsão de preço de 6 criptomoedas. Além disso, na comparação dos modelos de portfólio, o modelo Black-Litterman, construído utilizando o FinBERT modelo baseado no BERT (Bidirectional Encoder Representations from Transformers) do Google para medir o sentimento das notícias e o modelo LSTM para prever os preços das criptomoedas, apresenta a maior taxa de retorno anualizada: 123,28%. Ademais, tem o maior índice de Sharpe 1,12 indicando que, sob um certo grau de risco, o modelo Black-Litterman supera outros portfólios construídos.

**Palavras-chave:** Alocação de Portfólio; Criptomoedas; Modelo Black-Litterman; Redes Neurais

**Abstract:** *In this study, we applied deep learning methods and natural language processing to construct the distribution of views in the Black-Litterman model. We implemented this approach for portfolio allocation and conducted an analysis using some indicators to evaluate the portfolio's performance. The empirical analysis produces two main results. Among the two deep learning models used, we compared the prediction results using the mean squared error (MSE). The long short-term memory (LSTM) model outperforms the gated recurrent unit (GRU) model in predicting the prices of 6 cryptocurrencies. Additionally, in the comparison of portfolio models, the Black-Litterman model, built using the FinBERT model based on Google's BERT (Bidirectional Encoder Representations from Transformers) to measure news sentiment and the LSTM model to predict cryptocurrency price, presents the highest annualized return rate of 123.28%. Furthermore, it has the highest Sharpe ratio of 1.12, indicating that, under a certain degree of risk, the Black-Litterman model outperforms other constructed portfolios.*

**Keywords:** Portfolio Allocation; Cryptocurrency; Black-Litterman Model; Neural Network

---

<sup>\*</sup>Enderço de correspondência: matiaslima@usp.br

<sup>†</sup>Enderço de correspondência: danielbergamann@usp.br

## 1 Introdução

No campo das finanças, os modelos clássicos de alocação de ativos enfrentam dificuldades para incorporar eventos extremos e adaptar matrizes de covariância, visando compreender melhor as nuances das distribuições de retorno dos ativos. A adequação dos coeficientes de correlação linear, que são fundamentais para o Modelo de Média-Variância de Markowitz (MVM) é frequentemente questionada. Isso levou ao surgimento de soluções não paramétricas, como o método de "shrinkage" de Ledoit e Wolf. Apesar das alternativas acadêmicas, o MVM continua a ser amplamente utilizado devido à sua eficiência matemática na resolução de desafios de investimento a longo prazo.

Pesquisas recentes destacam que eventos extremos e notícias de mercado distorcem as matrizes de covariância históricas, desafiando a resiliência do MVM clássico em fornecer uma alocação robusta de ativos. Em resposta a essas limitações, modelos de aprendizado de máquina e processamento de linguagem natural emergem como abordagens promissoras para desenvolver estruturas adaptativas e realistas neste cenário complexo.

No mercado financeiro brasileiro, as soluções de Robo-Advisory mais comuns focam predominantemente na alocação estatística, negligenciando o impacto das notícias de mercado. Diferentemente dos Estados Unidos e da Europa, onde os ETFs predominam, o Brasil prioriza títulos de renda fixa. Essas soluções estáticas, que alocam uma porcentagem fixa em ações e ativos de renda fixa, ignoram a influência dinâmica das notícias de mercado e dos sentimentos dos investidores.

Esta iniciativa de pesquisa visa preencher essa lacuna ao desenvolver uma estrutura computacional que utiliza algoritmos de processamento de linguagem natural e modelos de aprendizado de máquina para compreender e avaliar notícias de mercado. O objetivo é aumentar a eficiência da diversificação de portfólios de criptoativos, considerando eventos extremos, notícias e sentimentos de mercado, aprimorando assim a gestão de investimentos em um ambiente dinâmico e desafiador.

## 2 Revisão de Literatura

Na arena financeira, os modelos clássicos de alocação de ativos têm dedicado atenção à incorporação de eventos extremos (**Alcock; Hatherley, 2009; Hatherley; Alcock, 2007**) e ajustes na matriz de covariâncias para apreender a assimetria e curtoza na distribuição dos retornos dos ativos (**Ledoit; Wolf, 2004**). **Rachev, Menn e Fabozzi (2005)** empiricamente constataram que os retornos dos ativos no mercado norte-americano frequentemente apresentam caudas pesadas e assimetria, questionando a adequação do coeficiente de correlação linear, fundamento do modelo mean-variance de Markowitz (MVM). Como resposta a essa questão, **Ledoit e Wolf (2004)** propuseram uma solução não-paramétrica conhecida como "shrinkage" na matriz de covariâncias, visando assimilar tais nuances.

Um dos modelos de maior sucesso na gestão de portfólios é o Black-Litterman, introduzido por Fischer Black e Robert Litterman em 1990, quase quatro décadas após a introdução da Teoria Moderna de Portfólios. Este modelo foi desenvolvido para superar algumas das desvantagens da teoria tradicional. O modelo Black-Litterman ajusta a alocação de ativos considerando as expectativas dos investidores em relação aos retornos esperados, resultando em um desempenho aprimorado. A construção do modelo Black-Litterman envolve duas etapas principais: a distribuição de equilíbrio prévia e a distribuição baseada nas visões dos investidores. Utilizando estimativas bayesianas, essas duas distribuições são combinadas para formar uma nova distribuição de retornos dos ativos. Ao abordar as deficiências da otimização de portfólio média-variância, o modelo Black-Litterman utiliza uma variável de entrada mais apropriada: o vetor de retorno esperado. O uso de pontos de equilíbrio de mercado na distribuição de equilíbrio prévia é considerado superior à abordagem tradicional de otimização de portfólio média-variância, proporcionando uma solução mais robusta e ajustada às expectativas do mercado.

Em consonância com **Tu e Zhou (2011)**, embora modelos alternativos tenham sido propostos na esfera acadêmica (**Brandt, 2010; Meucci, 2011; Black; Litterman, 1992**), o MVM continua preponderantemente empregado na prática de mercado. Tal predileção decorre de sua eficiência matemática em abordar problemas de alocação de carteiras de ações e da relativa insignificância da demanda por hedge intertemporal em investimentos de longo prazo.

A investigação conduzida por **Michaud e Michaud (2008)** e **Duchin e Levy (2009)**, que compararam o desempenho do modelo clássico de **Markowitz (1952)** com a regra 1/N, e a pesquisa

de **DeMiguel, Garlappi e Uppal (2009)**, que contrastaram a regra  $1/N$  com diversas técnicas de otimização, revelaram limitações intrínsecas às abordagens clássicas de alocação ótima de carteiras de ativos, conforme documentado por **Neto, Leal e Almeida (2011)**. Múltiplos estudos abordam as deficiências da análise média-variância. **Michaud (1989)** demonstrou que o problema de propagação de erro surge quando a multiplicação de matrizes é usada na teoria. **Best e Grauer (1991)** descobriram que o modelo é sensível a mudanças na média amostral. **Black e Litterman (1992)**, **He e Litterman (2002)** demonstraram que o portfólio tende a ser excessivamente focado em ativos específicos. Além disso, **Avramov e Zhou (2010)** observaram que os pesos são excessivamente concentrados, resultando em um portfólio desequilibrado, sem viabilidade e significado prático. Em conjunto, essas descobertas indicam vários desafios quando a teoria média-variância é usada para configurar ativos de portfólio na prática.

O estudo de **Silvapulle e Granger (2001)** adiciona uma dimensão crucial, evidenciando que os retornos de ações tendem a exibir maior correlação em mercados em declínio (bear markets) do que em mercados em alta (bull markets). Essa observação destaca a importância de incorporar a dependência entre ativos em períodos de alta volatilidade na avaliação do risco da carteira, corroborando as discussões de **Hatherley e Alcock (2007)** acerca da utilização de índices de dependência caudal provenientes da teoria estatística de cônjuges.

**Xing, Cambria e Welsch (2019; 2018)** recentemente ressaltaram que eventos extremos e notícias de mercado, de curto ou longo impacto, distorcem de maneira significativa a matriz de covariâncias histórica, comprometendo assim a capacidade do MVM clássico para proporcionar uma alocação robusta e eficiente dos ativos. Neste contexto complexo, os modelos clássicos de alocação de ativos revelam-se ineficazes ao não contemplarem eventos extremos, notícias e sentimentos de mercado.

Recentes avanços tecnológicos e o desenvolvimento da Internet possibilitaram o armazenamento completo de grandes volumes de informações. Esses avanços também permitiram o desenvolvimento de múltiplos modelos de deep learning que antes eram limitados por restrições tecnológicas. Estudos recentes (**Chen et al., 2019; Ding et al., 2019**) destacam a utilidade da análise de sentimentos para estimar visões absolutas sobre ativos e aplicar modelos de deep learning com sentimentos de ações ao modelo Black-Litterman.

A análise de sentimentos, utilizando processamento de linguagem natural (NLP), mineração de texto e linguística computacional, facilita a compreensão dos estados emocionais expressos em texto. Este método tem aplicações variadas, como na melhoria da previsão de preços de ações (**Ding et al., 2014**) e na classificação de sentimentos em dados de mídias sociais usando modelos como LSTM (**Liu et al., 2021**).

Modelos baseados em redes neurais recorrentes, como o LSTM, são particularmente eficazes para dados sequenciais, como preços de ações e análise de texto. Por exemplo, **Ding et al. (2014)** exploram a influência de eventos noticiosos nos movimentos de preços das ações, enquanto **Chang e Lin (2011)** compararam SVMs e redes neurais profundas na análise de eventos noticiosos e movimentos de ações. Em resposta a essas lacunas, modelos de machine learning e processamento de linguagem natural emergem como abordagens promissoras para criar estruturas mais adaptáveis e realistas, conforme destacado por **Xing, Cambria e Welsch (2019; 2018)**.

### 3 Metodologia

Esta seção detalha os métodos e procedimentos empregados na condução da pesquisa sobre alocação de ativos utilizando o modelo Black-Litterman. O cerne desta abordagem é a criação do vetor  $Q$ , que reflete as visões dos investidores sobre os retornos esperados das criptomoedas. Para estimar esses retornos, utilizamos modelos de deep learning, especificamente LSTM (Long Short-Term Memory) e GRU (Gated Recurrent Unit). Esses modelos foram escolhidos por sua capacidade de processar dados sequenciais, incluindo sentimentos extraídos de notícias, preços históricos das criptomoedas e volumes de negociação.

A pesquisa é conduzida em três etapas principais:

- 1. Coleta e Preparação dos Dados de Notícias:** Inicialmente, coletamos dados de notícias financeiras e os preparamos para serem utilizados como entrada no modelo FinBERT, que é especializado em análise de sentimentos no contexto financeiro.

- 
2. **Coleta de Dados de Preços, Volumes de Negociação e Aplicação dos Modelos de Redes Neurais:** Simultaneamente, reunimos dados históricos de preços das criptomoedas e volumes de negociação. Esses dados, juntamente com as informações de sentimentos extraídas das notícias, formam a base para nossos modelos de deep learning. Utilizamos os modelos LSTM e GRU para prever os preços futuros das Criptomoedas. Essas previsões são então utilizadas para calcular os retornos projetados das criptomoedas, que alimentam o vetor  $Q$  no modelo Black-Litterman.
  3. **Construção do Modelo de Alocação de Ativos:** Com a conclusão das etapas anteriores, temos os elementos necessários para aplicar o modelo de alocação de ativos Black-Litterman.

### 3.1 News sentiment

Para construir o Índice de Sentimento das Criptomoedas, seguimos três etapas principais. Primeiro, coletamos diariamente artigos de notícias sobre 9 criptomoedas(XRP, TRX, DOGE, ETH, LTC, ADA, BTC, XLM e BNB) de várias fontes utilizando um algoritmo de web scraping. Em seguida, organizamos esses artigos cronologicamente e mesclamos seus títulos e descrições. Finalmente, aplicamos o modelo de análise de sentimento FinBERT.

**Coleta de Dados:** Para estruturar o corpus, prosseguimos com a coleta diária de artigos de notícias disponíveis publicamente, publicados por meios de comunicação entre 1º de janeiro de 2018 e 1º de janeiro de 2024. O procedimento de coleta foi realizado utilizando um algoritmo de web scraping desenvolvido em Python, utilizando a biblioteca Selenium; o algoritmo foi projetado para interagir sistematicamente com o principal motor de busca, o Google. O algoritmo foi desenvolvido para extrair informações consideradas mais relevantes, conforme a classificação automática do motor de busca, através do uso de uma palavra-chave específica - [Nome da Cripto] news. A saída do código incluía detalhes chave como título, descrição, data de publicação, nome da fonte de notícias e URL. A escolha do Google como fonte primária para a coleta de dados foi justificada por sua posição predominante como motor de busca global, abrangendo uma ampla variedade de fontes de informação (**Lewandowski, 2008**). Essa decisão visa garantir uma representação abrangente e ampla das notícias, contribuindo assim para a robustez e generalização dos resultados obtidos a partir do corpus construído (**Hajian Hoseinabadi e CheshmehSohrabi, 2024**).



Figura 1: NUVEM DE PALAVRAS PARA O CORPUS PRÉ-PROCESSADO

Notas: Esta visualização representa a nuvem de raízes de palavras extraídas dos textos usados na construção do Índice de Sentimento. O corpus, uma coleção estruturada de textos, foi utilizado para gerar esta nuvem de palavras usando a biblioteca 'wordcloud' do Python. Abrangendo o período de 1º de dezembro de 2023 a 31 de dezembro de 2023, captura a essência dos artigos de notícias desse período.

**Construção do Índice:** Após a fase de coleta de dados, passamos para a fase de pré-processamento dos dados, onde estruturamos os dados organizando os artigos de notícias cronologicamente e mesclando o título com a descrição da notícia para usar como entrada no modelo de classificação FinBERT (**Araci, 2019**). Desenvolvido com base no transformador BERT, o FinBERT foi especificamente projetado para análise de sentimento em contextos financeiros (Sidogi, Mbuinha, & Marwala, 2021), caracterizado por sua capacidade de compreender nuances linguísticas intrínsecas ao domínio econômico.

A decisão de empregar o FinBERT neste estudo foi motivada pela necessidade de capturar e entender o sentimento subjacente dentro dos textos financeiros coletados, visando identificar padrões e tendências relevantes para análise, bem como pela eficiência demonstrada por modelos baseados na arquitetura de transformadores (Huang et al., 2023). A integração deste modelo em nosso projeto foi facilitada através da plataforma Hugging Face, que nos permitiu utilizar o modelo pré-treinado para a execução da tarefa de análise de sentimento. Como resultado do modelo, obtivemos a probabilidade de cada notícia inserida em nosso modelo se enquadrar em uma das três categorias: neutra, positiva e negativa. O índice de sentimento foi calculado através da diferença de probabilidade entre positivo e negativo (Araci, 2019).

Ticker	Outlets	Total	Positive	Negative	Neutral
BNB	213	2546	746	651	1149
BTC	245	2866	576	486	1804
ADA	141	1473	610	276	587
DOGE	221	1677	565	364	748
ETH	291	2801	910	645	1246
LTC	170	1367	485	252	630
XRP	521	2736	693	685	1358
XLM	129	1090	419	142	529
TRON	149	1219	407	225	587

Tabela 1: Crypto Sentiment Analysis

Notas: A tabela apresenta estatísticas resumidas tanto para os dados brutos de notícias quanto para os dados processados gerados pelo FinBERT. Os dados cobrem o período de 1º de janeiro de 2018 a 31 de dezembro de 2023. Incluem detalhes como o número total de fontes (abrangendo os principais jornais e outros meios de comunicação), o número total de artigos de notícias coletados e a divisão dos artigos de notícias em categorias positivas, negativas e neutras.

### 3.2 Stock prediction

Para a construção do vetor Q, é necessário obter o retorno de cada ativo de investimento. Primeiro prevemos os preços das criptomoedas. A seguir, calculamos os retornos simples ao invés dos retornos logarítmicos, e esses retornos calculados são então usados como componentes do vetor Q.

$$R_t = \frac{p_t}{p_{t-1}} - 1 \quad (1)$$

Os recursos de entrada e os hiperparâmetros dos modelos são exatamente os mesmos e foram baseados em (**Huang et al., 2024**), que realizada trabalho semelhante para ações. Para cada ponto no tempo, os recursos de entrada são os preços de abertura, máxima, mínima e fechamento; os volumes de negociação dos 180 dias anteriores após a normalização; e os sentimentos das notícias provenientes do modelo FinBERT. Utilizamos MinMaxScaler como a função de normalização. Definimos nosso modelo de deep learning com três camadas múltiplas e 50 unidades. Na etapa final, adicionamos uma camada densa para prever os preços das criptomoedas. Para evitar overfitting, adicionamos uma camada dropout de 20%. Os hiperparâmetros são: epochs = 64, batch size = 16, e learning rate = 0.001 para um otimizador Adam.

A Figura 2 exibe o gráfico de previsão das nove criptomoedas com as tendências reais dos preços e os dois modelos de previsão. A Tabela 2 apresenta os erros quadráticos médios desses dois modelos nas previsões dos preços das criptomoedas. Exceto pelas previsões para a BNB, DOGE e ETH, a capacidade preditiva do modelo LSTM supera o GRU.

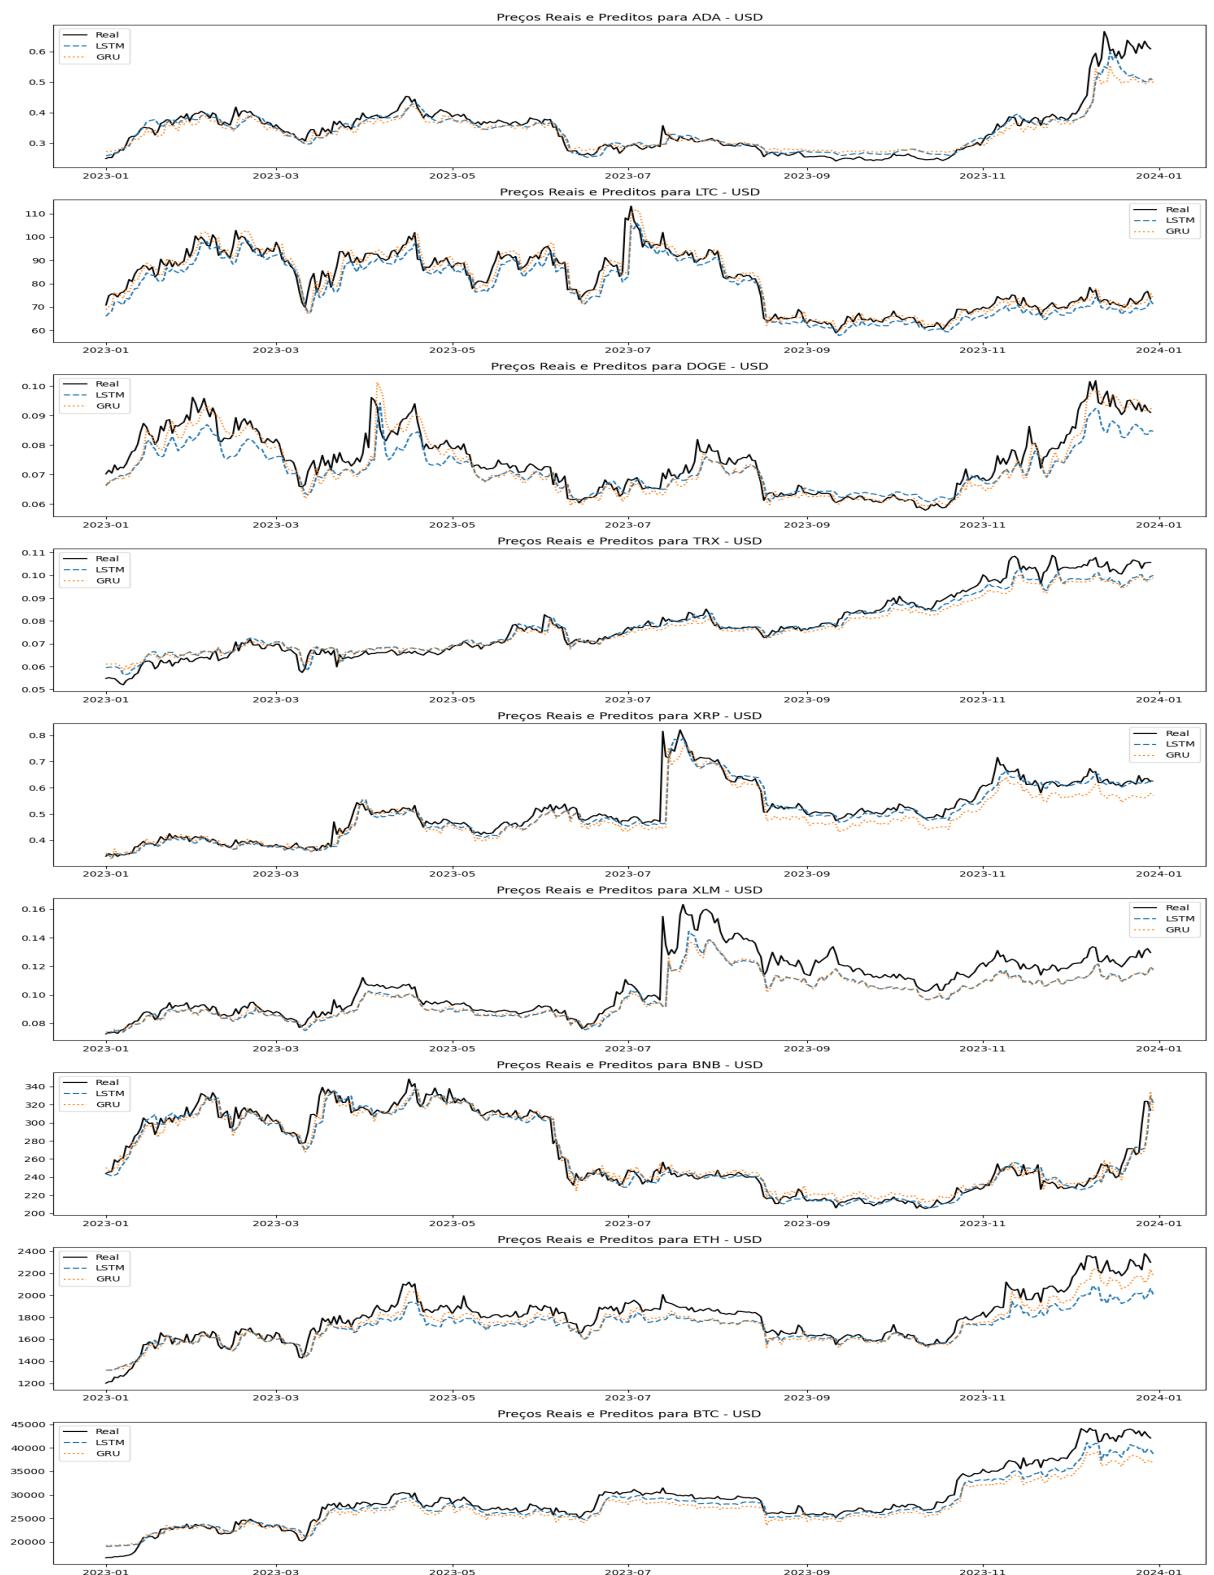


Figura 2: Gráfico com o plot das previsões das nove criptomoedas

Tabela 2: Erros quadráticos médios obtidos em previsões de criptomoedas pelos modelos LSTM e GRU.

MSE	ADA	BNB	BTC	DOGE	ETH	LTC	TXR	XLM	XRP
LSTM prediction	0,286	9,576	1734,187	0,005	121,393	4,674	0,002	0,008	0,031
GRU prediction	0,319	8,665	2441,67	0,0042	88,141	75,963	0,004	0,013	0,923

### 3.3 Black–Litterman model

O modelo Black-Litterman foi desenvolvido por Fischer Black e Robert Litterman em 1990 com o objetivo de solucionar dois problemas comuns na alocação tradicional de portfólios: a concentração de pesos em certos ativos e a sensibilidade exagerada às entradas de retorno esperadas. Para alcançar isso, o modelo integra as expectativas do mercado com as visões subjetivas do investidor, resultando em uma alocação de ativos mais equilibrada e robusta.

#### 3.3.1 Distribuição de Equilíbrio Prévia

A primeira etapa do modelo Black-Litterman envolve a construção da distribuição de equilíbrio prévia, estimando o vetor de prêmio de risco de equilíbrio ( $\Pi$ ). Segundo Black e Litterman (1990), o uso do retorno esperado nos pontos de equilíbrio de mercado como ponto de partida neutro é vantajoso. O prêmio de risco de equilíbrio é calculado utilizando o modelo de precificação de ativos de capital (CAPM):

$$\Pi = \beta_m(E(r_m) - r_f),$$

onde: -  $\Pi$  é o vetor de prêmio de risco de equilíbrio ( $n \times 1$ ), -  $E(r_m)$  é o retorno esperado do mercado, -  $r_f$  é a taxa livre de risco, -  $\beta_{im}$  é uma medida de volatilidade relativa ao mercado total, definida como  $\beta_{i,m} = \frac{Cov(r_i, r_m)}{Var(r_m)}$ .

Dada a dificuldade em medir  $\beta_{im}$ , empregamos o método de otimização reversa para estimar o vetor de prêmio de risco de equilíbrio:

$$\Pi = \lambda \Sigma w_{mkt},$$

onde: -  $\lambda$  é o coeficiente de aversão ao risco, -  $\Sigma$  é a matriz de covariância dos ativos, -  $w_{mkt}$  é o peso da capitalização de mercado dos ativos.

O modelo Black-Litterman assume que os retornos de equilíbrio ( $r_{eq}$ ) são normalmente distribuídos  $N(\Pi, \tau \Sigma)$ , onde  $\tau$  é um escalar que mede a confiança na estimativa do vetor de prêmio de risco de equilíbrio  $\Pi$ . Referenciando o estudo de Idzorek (2007), configuramos  $\tau$  para 0,025.

#### 3.3.2 Distribuição de Visões

A segunda etapa consiste na construção da distribuição de visões do investidor, onde Black e Litterman (1990) definem dois tipos de visões: relativas e absolutas. A visão relativa compara o desempenho futuro de dois ativos, enquanto a visão absoluta considera apenas um ativo-alvo em comparação com seu valor de mercado.

Para representar a distribuição de visões, usamos as matrizes  $P$ ,  $\Omega$ , e o vetor  $Q$ : -  $Q$  representa os retornos esperados em cada visão. -  $\Omega$  é a matriz de variâncias-covariâncias das visões, assumida como diagonal devido à independência das visões ( $\Omega = diag(\omega_1, \omega_2, \dots, \omega_k)$ ). -  $P$  indica os ativos mencionados nas visões.

A visão do investidor pode ser expressa como  $Q + \epsilon$ , onde  $\epsilon \sim N(0, \Omega)$ . Assim,  $r_{views} \sim N(Q, \Omega)$ .

#### 3.3.3 Estimativa de Parâmetros

Com as distribuições de equilíbrio e de visões estabelecidas, passamos a estimar os parâmetros necessários para a integração das visões do investidor ao modelo. As estimativas incluem:

1. **Volatilidade:** A matriz de covariância  $\Sigma$  é formada pelos elementos  $\sigma_{ij}$ , calculados como:

$$\sigma_{i,j} = \frac{1}{k} \sum_{n=1}^k r_{i,n} \cdot r_{j,n} - \frac{1}{k^2} \sum_{n=1}^k r_{i,n} \sum_{n=1}^k r_{j,n},$$

onde  $r_{i,n} = \log \frac{p_{i,n}}{p_{i,n-1}}$ .

2. **Confiança do Investidor:** A matriz de confiança  $\Omega$  é derivada da matriz de covariância:

$$\Omega = \text{diag}(P(\tau\Sigma)P').$$

3. **Retornos Esperados:**

**Retornos Esperados Ajustados ( $\mu_{BL}$ ):**

$$\mu_{BL} = [(\tau\Sigma)^{-1} + P'\Omega^{-1}P]^{-1} [(\tau\Sigma)^{-1}\Pi + P'\Omega^{-1}Q],$$

Essa fórmula combina os retornos de equilíbrio ( $\Pi$ ) com as opiniões do investidor, ajustadas pela confiança ( $\Omega$ ) e pela matriz de covariância ( $\Sigma$ ).

**Matriz de Covariância Ajustada ( $\Sigma_{BL}$ ):**

$$\Sigma_{BL} = \Sigma + [(\tau\Sigma)^{-1} + P'\Omega^{-1}P]^{-1}.$$

Esse termo adiciona uma correção à matriz de covariância de equilíbrio, ajustando-a para refletir as novas informações introduzidas pelas opiniões do investidor.

### 3.3.4 Pesos Ótimos do Portfólio

Finalmente, os pesos ótimos do portfólio ( $w^*$ ) são determinados integrando os retornos esperados ajustados e a matriz de covariância:

$$w_t^* = \left[ \lambda \left( \Sigma_t + [(\tau\Sigma_t)^{-1} + P'\Omega_t^{-1}P]^{-1} \right) \right]^{-1} [(\tau\Sigma_t)^{-1}\Pi + P'\Omega_t^{-1}Q].$$

Esta abordagem sistemática permite uma alocação de ativos que equilibra as expectativas do mercado com as visões subjetivas do investidor, resultando em um portfólio mais diversificado e menos sensível às variações nas entradas de dados.

O modelo Black-Litterman oferece uma solução para os desafios da alocação de ativos, combinando de forma equilibrada as expectativas do mercado com as visões dos investidores. A aplicação desta metodologia permitirá a construção de portfólios mais eficientes e alinhados com as expectativas e visões específicas dos investidores, proporcionando um equilíbrio entre risco e retorno.

## 4 Resultados

### 4.1 Benchmark models

Três abordagens foram selecionadas como modelos de referência:

S&P 500: Este índice de mercado acompanha 500 grandes empresas listadas em várias bolsas de valores dos EUA. Os investidores frequentemente utilizam o S&P 500 como um benchmark, esperando que seus investimentos superem seu desempenho. Neste estudo, compramos o S&P 500 e o mantemos até a sessão final de negociação.

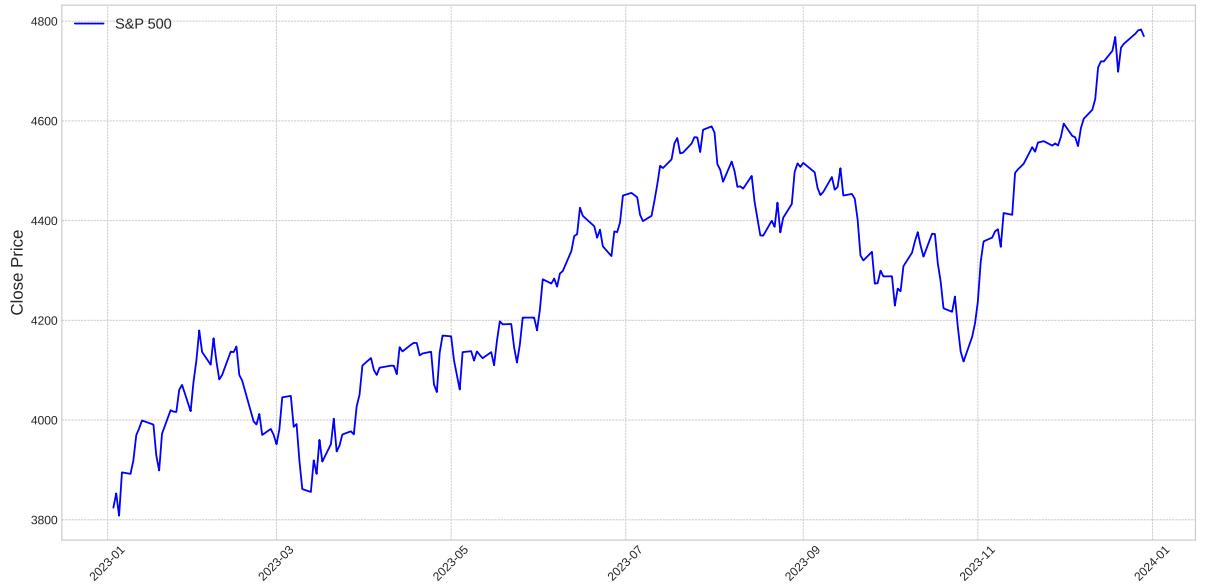


Figura 3: S&P 500

**Portfólio de Peso Igualitário:** Este é um método de alocação de ativos relativamente simples. Ao contrário de outras estratégias de investimento em que a alocação de ativos deve ser considerada sob diferentes condições, este método aloca pesos iguais para cada ativo. Como investimos em nove criptomoedas, cada uma recebe um peso de  $1/9$ . No nosso caso, o portfólio de peso igualitário apresenta um desempenho substancialmente melhor do que outros modelos de portfólio mais sofisticados, incluindo o portfólio de média-variância.

**Portfólio de Markowitz:** Na seção anterior, descrevemos as desvantagens de construir um portfólio de média-variância. Em nosso experimento, os pesos configurados pelo portfólio de média-variância, conforme verificado por outros estudos, são concentrados em ativos específicos. Além disso, a alocação de pesos é sensível à média do portfólio. Definimos o valor do parâmetro de risco como sendo um.



Figura 4: Gráfico com o plot dos Portfólios Markowitz e Pesos Igualitário

## 4.2 Evaluation

Em nosso experimento, assumimos que o agente está segurando \$100.000,00 no início do período de negociação. A cada dia de negociação, os investidores irão realocar todos os seus ativos. A duração da transação do conjunto de testes é de 362 dias.

A Figura 5 apresenta o gráfico de tendências de desempenho sob diferentes portfólios de investimento. Especificamente, as linhas roxa e laranja representam os modelos LSTM e GRU, respectivamente. Além disso, comparamos três modelos de referência, onde a linha vermelha denota os retornos do S&P 500, a linha verde indica o modelo de média-variância e a linha azul representa a estratégia de investimento do portfólio de peso igualitário. O modelo Black–Litterman apresenta um desempenho melhor com o modelo LSTM em comparação com outros modelos de referência.

No entanto, não podemos avaliar o desempenho dos portfólios apenas pelo seu valor total. Portanto, consideramos quatro métricas financeiras: retorno total, volatilidade, índice de Sharpe e drawdown máximo. Estas métricas nos permitem avaliar o desempenho de maneira mais abrangente, considerando tanto os retornos quanto os riscos associados a cada estratégia de investimento.

- 1. Retorno:** Este índice mede quanto um investimento aumentou em média durante um período específico a cada ano. A variável  $t$  representa o número de dias em que mantemos os ativos, ou seja, 362 - equivalente ao período 2/1/2023 a 30/12/2023.

A fórmula para os retornos percentuais simples é:

$$\text{Retorno Percentual Simples} = \frac{\text{Portfolio Value}_t - \text{Portfolio Value}_{t-1}}{\text{Portfolio Value}_{t-1}} \quad (2)$$

- 2. volatilidade:** A volatilidade é uma medida estatística que quantifica a dispersão dos retornos de um ativo financeiro ao longo do tempo. Ela reflete a magnitude das flutuações de preço ou retorno de um ativo em relação à sua média.

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (R_i - \bar{R})^2}$$

**índice de Sharpe:** O Índice de Sharpe, proposto por Sharpe (1966), considera não apenas os retornos dos ativos, mas também a variação dos ativos mantidos. Ele estabelece a taxa de juros livre de risco do mercado como referência, onde  $R_{rf}$  representa a taxa livre de risco.

$$\text{Sh.R} = \frac{R_{\text{portfolio}} - R_{rf}}{\sigma_{\text{portfolio}}} \quad (4)$$

**drawdown máximo:** Drawdown é a perda do lucro gradual da estratégia, a distância de um pico a um vale na curva de lucros e perdas. O máximo drawdown é a maior perda contínua observada de um pico a um vale em um portfólio.

$$MDD = \max_{0 < t < \tau} \left\{ \frac{Valor_t - Valor_{\tau}}{Valor_t} \right\} \quad (5)$$

Tabela 3: Performance do portfólio

Portfolio models	Retorno(%)	Volatilidade(%)	Sharpe	Drawdown(%)
Black-Litterman (LSTM)	123.28	98.32	1.1303	42.33
Pesos Iguais	78.55	47.46	1.2694	25.69
Markowitz-Portfolio	28.49	44.13	0.5864	41.01
S&P 500	23.80	15.78	1.0795	10.28
Black-Litterman (GRU)	-4.32	61.53	0.0822	42.84

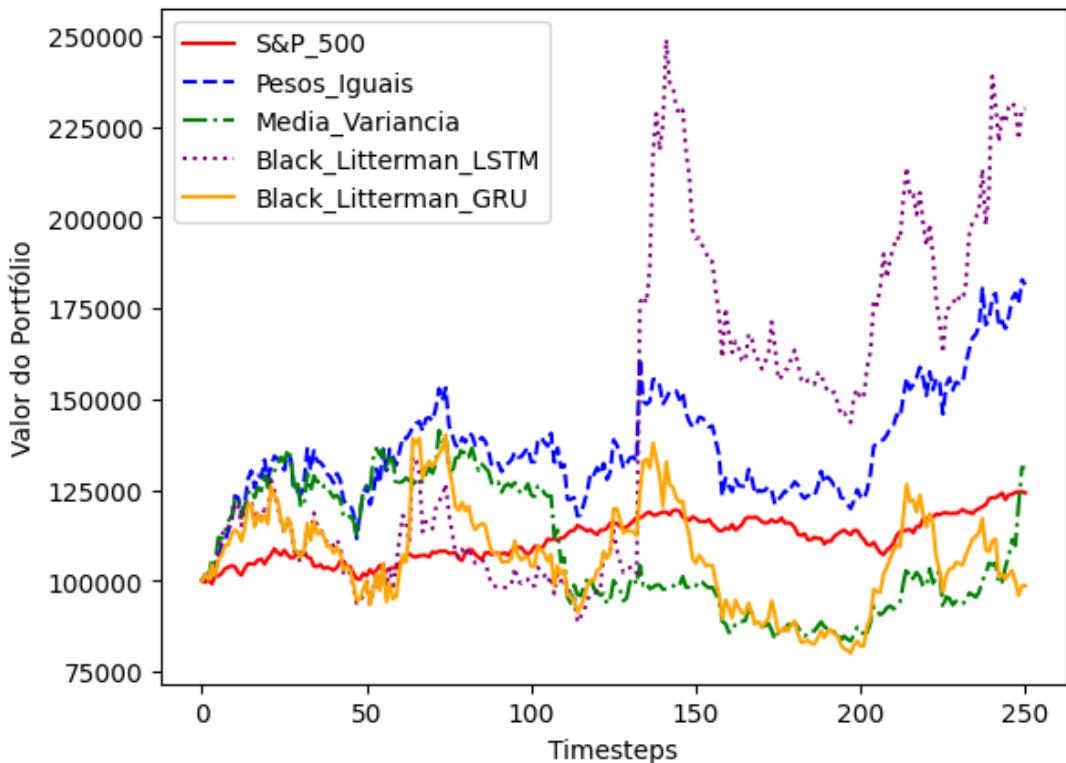


Figura 5: Gráfico com os Portfólios

Esta figura ilustra os valores dos portfólios ao longo dos dias úteis, dessa forma é possível comparar com os valores correspondentes do índice S&P 500.

A implementação do modelo Black–Litterman com LSTM supera os modelos de referência em desempenho, considerando o retorno anualizado. Em contraste, o modelo GRU apresenta o pior desempenho, possivelmente devido à incapacidade dessa estrutura de rede neural de capturar a complexidade da série temporal, dados os parâmetros utilizados como padrão. Comparado ao portfólio de Markowitz, nossas estratégias mostram uma rentabilidade mais alta, beneficiando-se de informações de notícias. A abordagem de igual ponderação tem uma rotatividade mais baixa e é considerada confiável, superando tanto o S&P 500 quanto o portfólio de Markowitz.

## 5 Considerações finais

Neste estudo, propusemos e avaliamos uma metodologia que integra o modelo Black–Litterman com redes neurais recorrentes – especificamente, as arquiteturas LSTM e GRU – na construção de portfólios de investimento. Nossos resultados indicam que a abordagem combinada com LSTM supera significativamente os modelos de referência, como o portfólio de peso igualitário e o índice S&P 500, em termos de retorno anualizado. Além disso, ao ser alimentado com dados de sentimento extraídos de notícias, o modelo LSTM demonstrou eficácia na captura das complexidades inerentes às séries temporais, maximizando os retornos enquanto manteve um índice de Sharpe semelhante com as abordagens menos volátil.

Em contraste, o desempenho do modelo GRU foi inferior, sugerindo que essa estrutura pode não ser a mais adequada para o contexto específico dos dados e parâmetros utilizados. No entanto, é importante considerar que diferentes configurações de parâmetros e ajustes adicionais poderiam potencialmente melhorar o desempenho do GRU.

Além disso, nossa análise destaca a robustez da abordagem de peso igualitário, que, apesar de sua simplicidade, apresentou uma baixa rotatividade e superou tanto o S&P 500 quanto o portfólio de Markowitz. Isso reforça a importância de estratégias simples e diversificadas em cenários de investimento.

Concluímos que a combinação de técnicas de deep learning com o modelo Black–Litterman oferece um caminho promissor para a construção de portfólios mais robustos e adaptáveis, especialmente em um ambiente financeiro cada vez mais influenciado por grandes volumes de dados e análises de sentimentos. Como trabalho futuro, pretendemos explorar a adição de mais informações e técnicas de aprendizado de máquina para refinar ainda mais as previsões e a construção de visões no modelo Black–Litterman, buscando otimizar a performance dos portfólios.

## Referências

- Alcock, J., & Hatherley, A. Asymmetric dependence between domestic equity indices and its effect on portfolio construction. *Australian Actuarial Journal*, Forthcoming, 2009.
- Araci, D. “Finbert: Financial sentiment analysis with pre-trained language models.” CoRR, vol. abs/1908.10063, 2019.
- Avramov, D., & Zhou, G. Bayesian portfolio analysis. *Annual Review of Financial Economics*, vol. 2, no. 1, 2010, pp. 25-47.
- Best, Michael J.; Grauer, Robert R. On the Sensitivity of Mean-Variance-Efficient Portfolios to Changes in Asset Means: Some Analytical and Computational Results. *The Review of Financial Studies*, vol. 4, no. 2, Apr. 1991, pp. 315-342. Disponível em: <https://doi.org/10.1093/rfs/4.2.315>.
- Black, F., & Litterman, R. Global portfolio optimization. *Financial Analysts Journal*, vol. 48, no. 5, 1992, pp. 28-43.
- BRANDT, M. W. Portfolio choice problems. In: Handbook of financial econometrics: Tools and techniques. [S.l.]: Elsevier, 2010. p. 269–336.
- Chang, C. C., Lin, C. J. (2011). LIBSVM: a library for support vector machines. ACM transactions on intelligent systems and technology (TIST), 2(3), 1-27.
- Chen, L. C., Lee, C. M., & Chen, M. Y. Exploration of social media for sentiment analysis using deep learning. *Soft Computing*, vol. 24, no. 11, 2020, pp. 8187-8197.

- Demiguel, V., Garlappi, L., & UPPAL, R. Optimal versus naive diversification: How inefficient is the 1/n portfolio strategy? *The Review of Financial Studies*, vol. 22, no. 5, 2009, pp. 1915-1953.
- Ding, W., Mazouz, K., & Wang, Q. Investor sentiment and the cross-section of stock returns: new theory and evidence. *Review of Quantitative Finance and Accounting*, vol. 53, 2019, pp. 493-525.
- Ding, X., Zhang, Y., Liu, T., & Duan, J. Using structured events to predict stock price movement: An empirical investigation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2014, pp. 1415-1425.
- Ding, X. et al. Deep learning for event-driven stock prediction. In: *Twenty-fourth International Joint Conference on Artificial Intelligence*, 2015.
- Duchin, R., & Levy, H. Markowitz versus the Talmudic portfolio diversification strategies. *The Journal of Portfolio Management*, vol. 35, no. 2, 2009, pp. 71-74.
- Hajian Hoseinabadi, A., & CheshmehSohrabi, M. "Proposing a New Combined Indicator for Measuring Search Engine Performance and Evaluating Google, Yahoo, DuckDuckGo, and Bing Search Engines based on Combined Indicator." *Journal of Librarianship and Information Science*, vol. 56, no. 1, 2024, pp. 178-197. Disponível em: <https://doi.org/10.1177/09610006221138579>.
- Hatherley, A., & Alcock, J. Portfolio construction incorporating asymmetric dependence structures: a user's guide. *Accounting & Finance*, vol. 47, no. 3, 2007, pp. 447-472.
- He, Guangliang; Litterman, Robert. The Intuition Behind Black-Litterman Model Portfolios. Disponível em SSRN: <https://ssrn.com/abstract=334304>.
- Huang, Allen H., Hui Wang, and Yi Yang. "FinBERT: A large language model for extracting information from financial text." *Contemporary Accounting Research*, vol. 40, no. 2, 2023, pp. 806-841.
- Hung, M. C., Hsia, P. H., Kuang, X. J., Lin, S. K. (2024). Intelligent portfolio construction via news sentiment analysis. *International Review of Economics Finance*, 89, 605-617.
- Ledoit, O., & Wolf, M. Honey, I shrunk the sample covariance matrix. *The Journal of Portfolio Management*, vol. 30, no. 4, 2004, pp. 110-119.
- Lewandowski, D. "The retrieval effectiveness of web search engines: considering results descriptions." *Journal of Documentation*, vol. 64, no. 6, 2008, pp. 915-937. Disponível em: <https://doi.org/10.1108/0022041081091245>
- Liu, K., Zhou, J., & Dong, D. Improving stock price prediction using the long short-term memory model combined with online social networks. *Journal of Behavioral and Experimental Finance*, vol. 30, 2021, p. 100507.
- Markowitz, H. The utility of wealth. *Journal of Political Economy*, vol. 60, no. 2, 1952, pp. 151-158.
- MEUCCI, A. A new breed of copulas for risk and portfolio management. *Risk*, v. 24, n. 9, p. 122-126, 2011.
- Michaud, R. O. The Markowitz Optimization Enigma: Is 'Optimized' Optimal? *Financial Analysts Journal*, 1989. Disponível em SSRN: <https://ssrn.com/abstract=2387669>.
- Michaud, R. O., & Michaud, R. O. *Efficient asset management: A practical guide to stock portfolio optimization and asset allocation*. Oxford University Press, 2008.
- Neto, C. T., Leal, R. P. C., & Almeida, V. d. S. Um índice de mínima variância de ações brasileiras. *Economia Aplicada*, vol. 15, no. 4, 2011, pp. 535-557.
- Rachev, S. T., Menn, C., & Fabozzi, F. J. *Fat-tailed and skewed asset return distributions: Implications for risk management, portfolio selection, and option pricing*. John Wiley & Sons, 2005.
- Sidogi, Thendo, Rendani Mbuvha, & Tshilidzi Marwala. "Stock price prediction using sentiment analysis." *2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, IEEE, 2021.
- Silvapulle, P., & Granger, C. W. Large returns, conditional correlation and portfolio diversification: a value-at-risk approach. Taylor & Francis, 2001.
- Tu, J., & Zhou, G. Markowitz meets Talmud: A combination of sophisticated and naive diversification strategies. *Journal of Financial Economics*, vol. 99, no. 1, 2011, pp. 204-215.
- Xing, F., Cambria, E., & Welsch, R. *Intelligent Asset Management*. Springer, 2019.

Xing, F. Z., Cambria, E., & Welsch, R. E. Intelligent asset allocation via market sentiment views. *IEEE Computational Intelligence Magazine*, vol. 13, no. 4, 2018, pp. 25-34.