

Criando Portfólios de Alto Desempenho: Otimização de Portfólios de Ativos de Alta Volatilidade Através da Previsão de Retorno Baseada em CNN+BiLSTM

Israel R. Soares¹, Sérgio D. C. Canuto¹

¹Instituto Federal de Educação, Ciência e Tecnologia de Goiás (IFG)
Goiás – Brasil.

irsoares@protonmail.com, sergio.canuto@ifg.edu.br

Abstract. *This paper proposes an innovative approach for optimizing portfolios of high-volatility assets, integrating return prediction with CNN+BiLSTM into the Sharpe Index Model. The aim is to adapt the Sharpe Index Model to the specific characteristics of the high-volatility asset market, characterized by high volatility, non-normal distributions, and strong correlations between assets. The methodology uses a model that estimates the average return and future variance of assets, providing more accurate inputs to the SIM and resulting in the Sharpe Index Model with Prediction. The results show that the Sharpe Index Model with Prediction outperforms the model without prediction, with an average accumulated gain of 68.88%, compared to -19.76% with the SIM over 75 days.*

Resumo. *Este artigo propõe uma abordagem inovadora para otimização de portfólios de ativos de alta volatilidade, integrando previsão de retorno com CNN+BiLSTM ao Modelo do Índice de Sharpe (MIS). O objetivo é adaptar o MIS às particularidades do mercado de ativos de alta volatilidade, marcado por alta volatilidade, distribuições não normais e forte correlação entre ativos. A metodologia utiliza um modelo que estima o retorno médio e a variância futura dos ativos, fornecendo entradas mais precisas ao MIS e originando o Modelo do Índice de Sharpe com Previsão (MIScP). Os resultados mostram que o MIScP supera o MIS, com ganho acumulado médio de 68,88%, contra -19,76% com o MIS em 75 dias.*

1. Introdução

No âmbito da pesquisa voltada para a área de finanças, a otimização de portfólio desempenha um papel crucial na gestão eficiente de ativos, com implicações significativas para investidores, formuladores de políticas e a economia em geral. Ao buscar alocações de ativos que mitigam riscos de perda de capital e ampliam retornos, ela se destaca como um instrumento valioso na construção de portfólios robustos e eficientes. Seu emprego é crucial para a preservação do capital, principalmente mercados de alto risco, como é o caso do mercado de ativos de alta volatilidade na *blockchain* [Hrytsiuk et al. 2019].

A gestão eficiente desses ativos apresenta grandes desafios. Diferentemente dos mercados convencionais, esse mercado é caracterizado por apresentar alta volatilidade [Saad e Jabbar 2022, Malladi e Dheeriyaa 2020,

Al-Yahyaee et al. 2020, Miglietti et al. 2019], distribuições não normais de preços [Hrytsiuk et al. 2019], alta correlação entre ativos [Gkillas et al. 2018], movimentação conjunta [Gkillas et al. 2018], e liquidez limitada [Al-Yahyaee et al. 2020]. Essas características dificultam o uso de abordagens clássicas de otimização de portfólio nesse tipo de mercado. A baixa liquidez também pode afetar o desempenho de alguns algoritmos de machine learning [Bomfim e Nascimento 2024]. No entanto, é possível adaptar esses modelos para lidar com a complexidade inerente ao contexto desses ativos da *blockchain*.

A primeira abordagem de otimização de portfólio tem origem em Harry Markowitz e seu trabalho inovador, a Teoria Moderna do Portfólio (MPT, na sigla em inglês) [Markowitz 1952]. Essa teoria culminou nos modelos conhecidos como modelos de Média-Variância (MV). Esses modelos se baseiam na utilização dos retornos esperados de uma carteira como o retorno do investimento e a variância dos retornos da carteira como o risco do investimento [Chen et al. 2013].

Dentre esses modelos se destaca o modelo do Índice de Sharpe, um modelo clássico de MV que busca identificar o portfólio que maximiza o Índice de Sharpe. Ao focar a maximização desse índice, o modelo procura equilibrar de forma ótima o potencial de retorno com a volatilidade associada, sendo frequentemente usado na construção de portfólios em mercados convencionais. Esse modelo, assim como os outros modelos de MV, pressupõe que os investidores são avessos ao risco, racionais, buscam maximizar o retorno esperado, e que os ativos são independentes e os seus retornos possuem uma distribuição normal.

No entanto, essas premissas não condizem com as características dos mercados de ativos da *blockchain*. Assim, embora o modelo do Índice de Sharpe possa ser eficaz na construção de portfólios em mercados convencionais, como o de ações, é necessário modificá-lo para que ele possa ser empregado nesse mercado [Hrytsiuk et al. 2019].

Portanto, visando viabilizar a aplicação do modelo do Índice de Sharpe na construção de portfólios no mercado de ativos da *blockchain*, uma nova abordagem é proposta neste artigo. A metodologia adotada utiliza modelos de previsão do valor de fechamento dos ativos para calcular estimativas mais precisas do retorno e da correlação futura deles. A utilização dessas estimativas, em vez do retorno médio e da correlação dos ativos, como é comum no modelo do Índice de Sharpe, resulta na formulação de portfólios com desempenho aprimorado.

2. Revisão da Literatura

2.1. Modelos de Média-Variância

A Teoria Moderna do Portfólio (MPT) propõe a diversificação como ferramenta para minimizar o risco de um portfólio, mantendo níveis desejáveis de retorno [Markowitz 1952]. A correlação entre ativos desempenha papel essencial na composição de portfólios eficientes.

Essa teoria originou os modelos de Média-Variância (MV), que visam minimizar a variância do portfólio σ_p^2 para um dado retorno esperado μ :

$$\min \sigma_p^2 = \sum_{i=1}^N \sum_{j=1}^N \omega_i \omega_j \text{cov}(\mu_i, \mu_j) \quad (1)$$

sujeito a

$$\bar{\mu}_p = \sum_{i=1}^N \omega_i \bar{\mu}_i \geq \mu, \quad \sum_{i=1}^N \omega_i = 1, \quad 0 \leq \omega_i \leq 1 \quad (2)$$

O modelo padrão considera que ativos são independentes e que seus retornos seguem uma distribuição normal, o que nem sempre se verifica em mercados mais voláteis. Uma extensão relevante é o modelo da fronteira eficiente [Zhu et al. 2011], que introduz o parâmetro de aversão ao risco $\lambda \in [0, 1]$, permitindo ponderar o peso relativo entre risco e retorno:

$$\min \lambda \left[\sum_{i=1}^N \sum_{j=1}^N \omega_i \omega_j \text{cov}(\mu_i, \mu_j) \right] - (1 - \lambda) \left[\sum_{i=1}^N \omega_i \bar{\mu}_i \right] \quad (3)$$

Quando $\lambda = 0$, o investidor prioriza o retorno; quando $\lambda = 1$, prioriza a minimização do risco. Outra abordagem amplamente utilizada é o modelo baseado no Índice de Sharpe, que busca maximizar o retorno excedente ajustado pelo risco:

$$\text{SR} = \frac{\mu_p - \mu_f}{\sigma_p} \quad (4)$$

$$\max \text{SR} = \frac{\left[\sum_{i=1}^N \omega_i \bar{\mu}_i \right] - \mu_f}{\sqrt{\sum_{i=1}^N \sum_{j=1}^N \omega_i \omega_j \text{cov}(\mu_i, \mu_j)}} \quad (5)$$

Esses modelos são a base teórica para a construção de portfólios eficientes, mas apresentam limitações práticas diante de mercados como o de ativos da *blockchain*, caracterizados por alta volatilidade e correlações dinâmicas.

2.2. Uso de Inteligência Artificial para os Modelos de Média-Variância

Com os avanços em inteligência artificial, surgiram propostas para aprimorar os modelos de Média-Variância (MV) por meio da previsão de retornos futuros [Chaweewanchon e Chaysiri 2022, Guo et al. 2022, Du 2022, Ma et al. 2021]. Essas abordagens buscam gerar entradas mais precisas para os modelos de otimização.

[Yu et al. 2020] analisaram o impacto da previsão de retorno em diversos modelos de portfólio, demonstrando que a inclusão de previsões melhora a alocação de ativos e o desempenho dos portfólios, mesmo considerando custos de transação. Concluíram que modelos MV e Omega se beneficiam mais desse aprimoramento em comparação a abordagens como MAD, DSR, LVaR e CVaR.

De forma semelhante, [Chaweewanchon e Chaysiri 2022] propuseram uma estratégia que combina redes CNN e BiLSTM com seleção robusta de características para previsão de preços de ações. Sua integração com o modelo MV resultou em portfólios mais eficientes e melhor desempenho em séries temporais financeiras. Além

disso, [Ma et al. 2021] compararam técnicas de aprendizado supervisionado, como *Random Forests*, *Support Vector Regression* e redes LSTM, na previsão de retornos. Apesar da eficácia geral do método *Random Forest*, o estudo indicou que as redes LSTM alcançam melhor desempenho com a escolha adequada de atributos.

[Du 2022] focaram no uso de LSTM para prever preços de ativos co-integrados, construindo portfólios estacionários com ganhos superiores em índices como o CSI 300 e o S&P 500. Já [Wang et al. 2020] propuseram uma combinação de LSTM com o modelo MV de Markowitz, demonstrando o potencial da pré-seleção de ativos no aprimoramento da performance de portfólios no mercado financeiro do Reino Unido.

Considerando o mercado de ativos da *blockchain*, [Brauneis e Mestel 2019] aplicaram o framework de Média-Variância para analisar portfólios compostos pelos 500 criptoativos mais capitalizadas entre 2015 e 2017. O estudo demonstrou que a diversificação entre criptoativos reduz riscos e que a estratégia 1/N supera, em muitos casos, a seleção ótima clássica de MV em termos de índice de Sharpe e retorno.

Esses resultados indicam que, embora métodos clássicos de otimização tragam benefícios, o mercado de ativos da *blockchain* impõe desafios específicos devido à sua alta volatilidade, liquidez limitada e correlações dinâmicas. Assim, a integração de modelos de previsão baseados em redes neurais, como CNN+BiLSTM, mostra-se promissora para fornecer entradas mais precisas a métodos de otimização como o modelo do Índice de Sharpe.

Portanto, neste trabalho optou-se pela arquitetura CNN+BiLSTM considerando evidências recentes da literatura que apontam sua superioridade frente a modelos isolados. Segundo [Chen et al. 2024], modelos híbridos baseados em CNN e LSTM tornaram-se *estado-da-arte* em tarefas de previsão de séries temporais financeiras, na maioria das vezes superando redes LSTM puras e CNNs isoladas. Essa superioridade decorre do fato de que as camadas convolucionais capturam padrões locais relevantes nos dados, enquanto as camadas LSTM modelam dependências temporais de longo prazo.

Modelos baseados apenas em LSTM ou GRU tendem a não capturar explicitamente padrões locais presentes nos dados de preço ou indicadores técnicos, o que limita sua capacidade de representação. Por outro lado, arquiteturas como Transformers exigem um grande número de parâmetros e dependem fortemente de pré-treinamento em grandes volumes de dados externos para evitar *overfitting*, o que pode ser inviável em contextos de dados limitados como o mercado de criptoativos.

Dessa forma, embora existam alternativas viáveis, o presente estudo concentra-se em investigar como a integração da arquitetura CNN+BiLSTM com o modelo de otimização do Índice de Sharpe pode melhorar o desempenho de portfólios nesse mercado específico, buscando adaptar métodos tradicionais ao contexto de dados altamente voláteis e correlacionados.

3. Metodologia

A Figura 1 (b) descreve a *pipeline* usada para gerar um portfólio com o modelo do Índice de Sharpe. Com o objetivo de aprimorar esse modelo para a construção de portfólios no mercado de criptoativos, este trabalho propõe o uso de modelos de

previsão do valor de fechamento dos ativos, baseado em redes neurais, para calcular estimativas mais precisas do retorno e da correlação futura deles para servirem como parâmetros de entrada do modelo do Índice de Sharpe (MIS).

Esse novo modelo foi referido como modelo do Índice de Sharpe com previsão (MIScP). A Figura 1 (a) descreve a *pipeline* usada para gerar um portfólio com esse novo modelo. A hipótese é que o uso dessas estimativas mais precisas, ao invés dos retornos médios e da matriz de correlação dos retornos dos ativos, resultam na formulação de portfólios de melhor desempenho pelo MIScP.

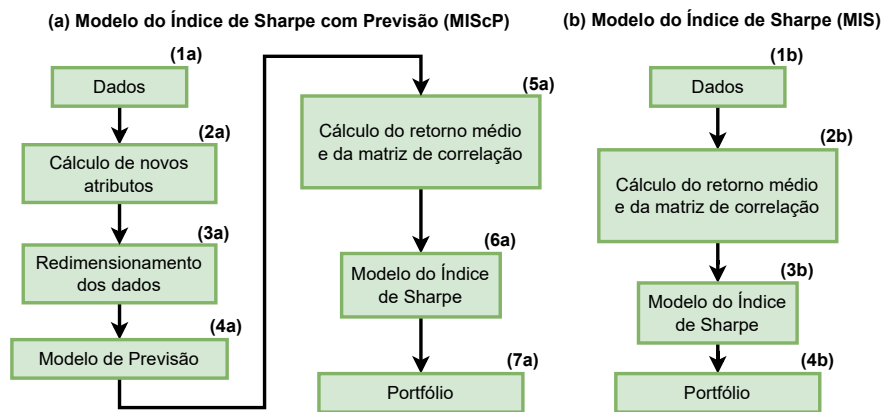


Figura 1. Pipeline do modelo do Índice de Sharpe com Previsão (a) e do modelo do Índice de Sharpe (b)

Para realizar a comparação entre esses dois modelos, foram definidos para compor o portfólio na simulação um ativo livre de riscos, atrelado à 100% do índice dos Certificados de Depósitos Interbancários (CDI), e os 25 criptoativos de maior capitalização de mercado em fevereiro de 2023, com pelo menos 2 anos de dados. Os criptoativos que compõem esse conjunto são: Bitcoin (BTC), Ethereum (ETH), Tether (USDT), Binance Coin (BNB), USD Coin (USDC), Ripple (XRP), Cardano (ADA), Dogecoin (DOGE), Polygon (MATIC), Hex (HEX), Litecoin (LTC), TRON (TRX), Avalanche (AVAX), Chainlink (LINK), Ethereum Classic (ETC), Monero (XMR), Bitcoin Cash (BCH), Hedera Hashgraph (HBAR), Stellar (XLM), Filecoin (FIL), Crypto.com Coin (CRO), Algorand (ALGO), VeChain (VET), Quant (QNT) e Decentraland (MANA).

Os dados relativos ao índice CDI foram obtidos junto ao Banco Central do Brasil, com coleta realizada em intervalos diários. Os dados relativos aos criptoativos foram obtidos através da plataforma Yahoo Finance. O conjunto de dados abrange informações detalhadas sobre cada criptoativo, incluindo data, preço de abertura, preço mais alto, preço mais baixo, preço de fechamento e volume de negociação. Essas informações foram coletadas em intervalos de uma hora, abrangendo o período de 10 de outubro de 2021, das 0:00 horas (GMT 0), até 25 de dezembro de 2022, às 14:00 horas (GMT 0).

Alguns intervalos horários não puderam ser coletados devido a períodos de manutenção programada da *blockchain* de alguns criptoativos, representando

pequenos períodos de menos de 8 horas por ano. Optou-se por preencher essas lacunas temporais aplicando interpolação linear dos valores dos intervalos adjacentes, que, embora tendam a reduzir a variabilidade local das séries e possam afetar negativamente a capacidade do modelo preditivo de capturar picos, quedas rápidas ou reversões de tendência, mantêm a frequência temporal dos dados sem comprometer o cálculo de alguns dos indicadores econômicos adicionados como *features* no MIScP, descritos na Seção 3.2.1.

A seguir, é descrito o experimento que consiste da comparação dos dois modelos e as métricas utilizadas para a comparação. Em seguida, é detalhado o MIScP, explicando as estratégias usadas no desenvolvimento do modelo de previsão do valor de fechamento dos ativos do portfólio, que incluem a geração de novas *features*, a definição da arquitetura da rede neural utilizada, o seu treinamento e a geração das entradas modificadas para o MIS.

3.1. Experimento

O experimento proposto para avaliar a hipótese apresentada consiste na comparação do desempenho do MIS com o MIScP, através da comparação dos ganhos acumulados por esses dois modelos em diferentes intervalos de tempo e do uso da métrica *Maximum drawdown* (MDD), descrita em [Mendes e Lavrado 2017]. Uma estratégia de investimento foi desenvolvida para avaliar o desempenho dos modelos. Essa estratégia consiste dos seguintes passos:

1. Entre com o modelo a ser usado (MIS ou MIScP).
2. Gere um portfólio usando esse modelo.
3. Aloque todo o capital disponível nos ativos que o compõem por 24 horas.
4. Repita o passo (3) até o final do intervalo de tempo definido para a simulação de desempenho do portfólio.
5. Retorne o ganho total acumulado pelo modelo e o MDD para esse intervalo de tempo.

Foram definidos 5 intervalos de tempo diferentes de 75 dias para a execução da simulação com a estratégia de investimento descrita, a fim de verificar o desempenho dos portfólios gerados por cada modelo em um cenário que imita a realidade. Esses intervalos estão representados na Figura 2, sendo que os períodos delimitados pela cor verde correspondem a esses intervalos de 75 dias usados para a simulação. Todas as transações simuladas foram realizadas considerando uma taxa fixa de 0,1%¹.

Além disso, os intervalos delimitados pelas cores roxo e azul da Figura 2 consistem dos períodos usados pelo Modelo de Previsão (MP) do MIScP para o treinamento e a validação dos parâmetros, respectivamente. Em cada um dos intervalos, o MP do MIScP foi treinado usando diferentes quantidades de dados, de forma a avaliar seu desempenho à medida que se aumenta o volume de dados utilizados.

¹Essa taxa foi definida como uma aproximação baseada nas taxas praticadas por corretoras de alta liquidez. A incorporação de custos dinâmicos ou de estratégias de simulação mais realistas configura uma direção relevante para investigações futuras.




Figura 2. Definição dos períodos de treinamento, teste e validação do Modelo de Previsão (MP) do MIScP, bem como o período de validação do MIS e do MIScP na estratégia de investimento proposta, para cada um dos 5 intervalos de tempo definidos.

3.2. Modelo do Índice de Sharpe com Previsão

3.2.1. Conjunto de Dados do Modelo de Previsão

Com base nos dados adquiridos pela plataforma Yahoo Finance, e com o objetivo de aprimorar a precisão e robustez do Modelo de Previsão, foram adicionadas novas *features* ao conjunto de dados utilizado nos modelos preditivos. Essas *features* foram derivadas de indicadores econômicos amplamente empregados na análise de investimentos e foram incorporadas por meio da biblioteca *pandas-ta*². Essas *features* foram selecionadas dentre um conjunto de mais de 130 *features* disponíveis na biblioteca *pandas-ta* utilizando o método de seleção de *features* descrito em [Biesiada e Duch 2007]. Esses indicadores incluem:

- **Archer Double Smoothed Oscillator (ADOSC):** Oscilador que suaviza as oscilações de preço e volume para fornecer uma visão mais estável das tendências do mercado.
- **Average Directional Index (ADX):** Mede a força de uma tendência, indicando se o mercado está em uma fase de tendência ou lateralização.
- **Aroon Down (AROOND) e Aroon Up (AROONU):** Avaliam a força da tendência com base na posição dos preços em relação aos pontos mais altos e mais baixos em um determinado período.
- **Bollinger Bands (BBB):** Utiliza bandas para avaliar a volatilidade e os níveis de sobrecompra ou sobrevenda do mercado.

²<https://pypi.org/project/pandas-ta/>

Tabela 1. Descrição das camadas da rede neural.

#	Camada	Dimensão de saída	Descrição
1	Entrada	(# de <i>batches</i> , 72, 11)	<i>Batch</i> composto por matrizes contendo 72 medições horárias de 11 atributos
2	CNN 1D (TimeDistributed)	(# de <i>batches</i> , 72, 11, 8)	CNN, tamanho do <i>kernel</i> 5, 8 filtros, ativação ReLU
3	Normalização	(# de <i>batches</i> , 72, 11, 8)	Normalização em lote
4	Ativação	(# de <i>batches</i> , 72, 11, 8)	Função de ativação ReLU
5	CNN 1D (TimeDistributed)	(# de <i>batches</i> , 72, 11, 4)	CNN, tamanho do <i>kernel</i> 3, 4 filtros, ativação ReLU
6	Normalização	(# de <i>batches</i> , 72, 11, 4)	Normalização em lote
7	Ativação	(# de <i>batches</i> , 72, 11, 4)	Função de ativação ReLU
8	Flatten	(# de <i>batches</i> , 72, 44)	Achatamento temporal
9	LSTM (Bidirectional)	(# de <i>batches</i> , 72, 16)	BiLSTM, 16 neurônios, <i>return_sequences</i> = True
10	Dropout	(# de <i>batches</i> , 72, 16)	Dropout 20%
11	LSTM (Bidirectional)	(# de <i>batches</i> , 16)	BiLSTM, 16 neurônios
12	Dropout	(# de <i>batches</i> , 16)	Dropout 20%
13	Densa	(# de <i>batches</i> , 48)	Camada Densa, 48 neurônios
14	Densa	(# de <i>batches</i> , 24)	Camada Densa, 24 neurônios, função de ativação tangente hiperbólica
15	Saída	(# de <i>batches</i> , 24)	Vetor com 24 previsões do valor de fechamento

- **Choppiness Index (CHOP):** Mede a amplitude de preços em relação a uma faixa fixa, ajudando a identificar a direção do mercado.
- **Detrended Price Oscillator (DPO):** Analisa ciclos de preços, destacando padrões de reversão e tendências.
- **Kurtosis (KURT):** Mede a forma da distribuição de preços, indicando a presença de caudas pesadas.
- **Money Flow Index Sentiment (MASSI):** Combina o índice de fluxo de dinheiro com a média móvel para avaliar o sentimento do mercado.
- **Skewness (SKEW):** Mede a assimetria da distribuição de preços, indicando se há uma inclinação para a direita ou esquerda.

O valor de fechamento dos criptoativos foi normalizado a partir da função Min-Max, conforme definida em [Patro e Sahu 2015]. Posteriormente, os dados foram organizados em intervalos de 72 horas, espaçados de 7 em 7 horas, dos 11 atributos (compostos pelo valor de fechamento em conjunto com os 10 indicadores adicionados). Em cada intervalo de tempo descrito na Figura 2, 75 dias de dados constituem o período de validação e, do período que sobra, 80% dos dados constituem o conjunto

de treinamento e 20% constituem o conjunto de teste.

3.2.2. Desenvolvimento do Modelo de Previsão do Valor de Fechamento dos Criptoativos

O Modelo de Previsão consiste de um Modelo de Previsão do valor de fechamento de cada um dos 25 criptoativos do portfólio. A arquitetura desses modelos foi baseada no trabalho de [Chaweewanchon e Chaysiri 2022] e está ilustrada na Figura 3, sendo possível explorar detalhes específicos de cada camada por meio dos números associados a elas, conforme apresentado na Tabela 1.

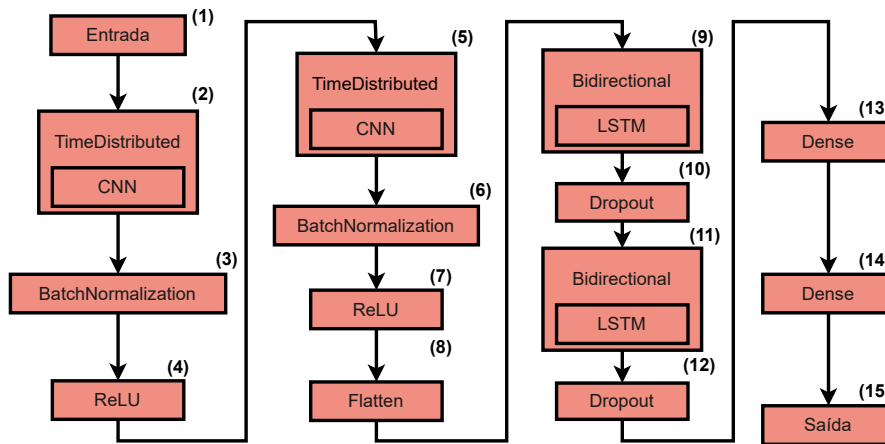


Figura 3. Arquitetura do modelo

A entrada de cada um desses Modelos de Previsão consiste em janelas de 72 horas de dados dos criptoativos, com diferença de 7 horas entre janelas consecutivas.

Eles foram implementados com a biblioteca *TensorFlow* e apresentam uma mesma arquitetura sequencial composta por camadas convolucionais, recorrentes e densas. A estrutura foi projetada para capturar padrões locais e dependências temporais em séries temporais multivariadas.

Inicialmente, a estrutura desses modelos é composta duas camadas convolucionais (*Convolutional Neural Networks – CNN*) aplicadas via *TimeDistributed*, seguidas por normalização e ativação ReLU. A primeira, com filtros mais longos, extrai padrões gerais, enquanto a segunda refina capturando padrões mais complexos ao longo do tempo, enriquecendo a representação das séries temporais.

Após as camadas convolucionais, uma camada de achatamento (do inglês, *flatten layer*) é empregada para transformar a saída multidimensional das camadas anteriores em unidimensional para fazer a transição para as próximas camadas. Posteriormente, redes de memória de curto-longo prazo bidirecionais – *Bidirectional Long Short-Term Memory* (BiLSTM) são integradas para compreensão aprimorada de dependências temporais em ambas as direções, permitindo que o modelo capture padrões complexos e aprenda dependências de longo prazo.

Por fim, a fase final do modelo envolve duas camadas densas, sendo que a última camada utiliza ativação tangente hiperbólica, contribuindo para a não

linearidade do modelo. A saída consiste da estimativa do valor de fechamento do ativo nas próximas 24 horas, através de um vetor contendo 24 saídas, sendo uma para cada intervalo de uma hora.

3.2.3. Treinamento do Modelo de Previsão do Valor de Fechamento dos Criptoativos

A configuração de treinamento adota a função de otimização Adam, conforme definido em [Kingma e Ba 2014], com os valores padrão da biblioteca *python Keras*, exceto pelo *learning rate*, que foi ajustado individualmente para cada um dos criptoativos. Esse ajuste foi realizado por meio de avaliação automatizada sobre os valores {5e-3, 5e-4, 5e-5, 5e-6}, selecionando-se o que apresentou menor erro no conjunto de validação (parte azul da Figura 2). De maneira similar, o tamanho do *batch* foi definido por meio de busca em grade entre os valores {16, 32, 64} para cada criptoativo. O número de épocas utilizado foi limitado em 150, valor no qual se observou tendência de *overfitting* em todos os modelos. Para mitigar esse efeito, foi adotada a estratégia de salvar apenas os pesos correspondentes à época que apresentou o melhor desempenho no conjunto de validação.

A compilação de todos esses Modelos de Previsão utiliza a função de perda Erro Médio Quadrático – *Mean Squared Error* (MSE), definida conforme a Equação 6.

$$MSE(Y, \hat{Y}) = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (6)$$

Onde Y representa o conjunto de valores verdadeiros, \hat{Y} representa o conjunto de valores previstos e n é o número total de valores dos dois conjuntos.

3.2.4. Cálculo do Retorno Médio e da Matriz de Correlação dos Valores Previstos

Conforme mencionado anteriormente, a saída do Modelo de Previsão de um criptoativo é composto pela estimativa dos próximos 24 valores de fechamento em intervalos de 1 hora. O retorno médio é definido como a média desses 24 valores.

Já a matriz de correlação é uma representação tabular formada pelo coeficiente de correlação entre cada um dos 24 valores estimados pelos Modelos de Previsão dos 25 criptoativos que compõem o portfólio. A fórmula para o coeficiente de correlação entre dois conjuntos de valores X e Y é dada pela Equação 7.

$$\text{corr}(X, Y) = \frac{\text{cov}(X, Y)}{\sigma(X)\sigma(Y)} \quad (7)$$

Onde $\text{corr}(X, Y)$ é o coeficiente de correlação entre X e Y , $\text{cov}(X, Y)$ é a covariância entre X e Y , $\sigma(X)$ é o desvio padrão de X e $\sigma(Y)$ é o desvio padrão de Y . O retorno médio e a matriz de correlação dos valores previstos constituem as entradas modificadas para o MIS empregadas no MIScP.

4. Resultados e Discussão

A Figura 4 apresenta a evolução do investimento inicial (valor 1) obtido pela estratégia usando o MIScP e, em comparação, o MIS.

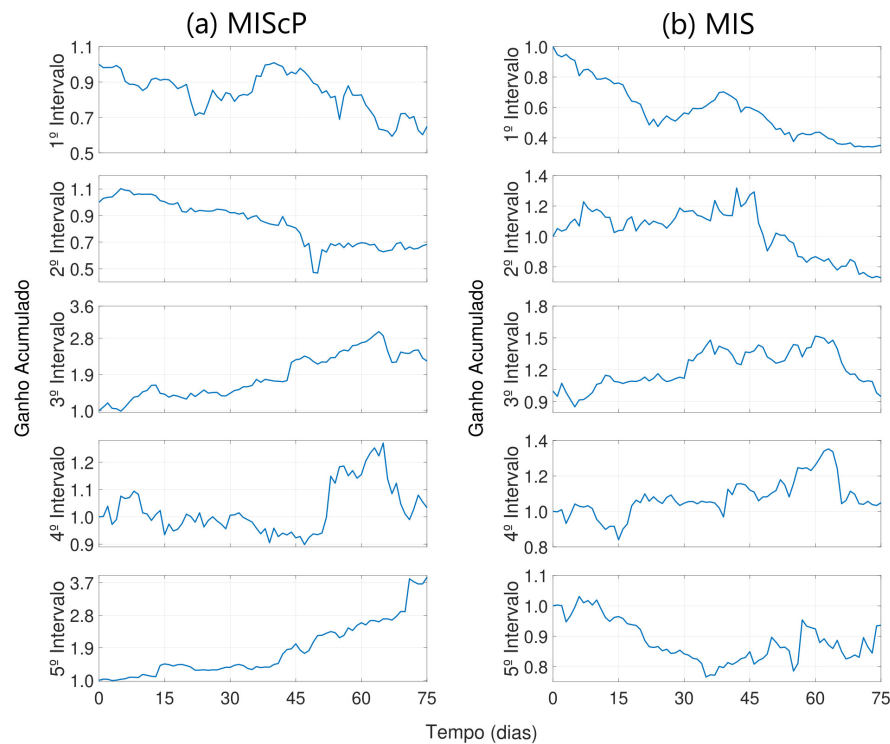


Figura 4. (a) Ganhos acumulados - MIScP; (b) Ganhos acumulados - MIS

A Tabela 2 resume os ganhos acumulados obtidos em cada intervalo de tempo para ambos os modelos.

Tabela 2. Ganhos acumulados ao longo dos intervalos experimentais

Intervalo	Ganho MIScP (%)	Ganho MIS (%)
1	-35.06	-64.97
2	-31.71	-27.19
3	123.19	-5.12
4	3.37	4.89
5	284.65	-6.40
Média	68.88	-19.76

Em geral, o MIScP superou o MIS em quatro dos cinco intervalos, com destaque para os intervalos 3 e 5, alcançando ganhos de 123,19% e 284,65%, respectivamente, enquanto o MIS apresentou perdas. A média total de ganhos também favoreceu o MIScP (68,88%) em relação ao MIS (-19,76%).

A Tabela 3 apresenta a métrica de risco *Maximum Drawdown* (MDD) para ambos os modelos.

Tabela 3. Valores da métrica MDD ao longo dos intervalos experimentais

Intervalo	MDD MIScP (%)	MDD MIS (%)
1	-41.17	-64.17
2	-57.58	-44.79
3	-25.92	-37.45
4	-22.10	-23.62
5	-13.17	-25.73
Média	-31.99	-39.15

O MIScP apresentou um risco médio menor (-31,99%) em comparação ao MIS (-39,15%), reforçando sua vantagem em termos de volatilidade. Esses resultados apresentam evidências favoráveis à inclusão de previsões no modelo de Índice de Sharpe para o aprimoramento da performance dos portfólios, resultando em maior ganho acumulado e menor risco.

Por fim, destaca-se que a estratégia de rebalanceamento diário com custos fixos de 0.1% por transação, visando comparar de forma padronizada o desempenho dos modelos. Contudo, essa escolha não considera limitações operacionais como *slippage*, impacto de mercado ou restrições de liquidez, o que constitui uma limitação do presente estudo.

5. Conclusão

Este estudo propôs uma abordagem inovadora para otimizar portfólios de criptoativos, combinando previsão de retorno com CNN+BiLSTM e o MIS, culminando no MIScP. A metodologia adaptou o modelo às características do mercado de ativos da *blockchain*, com alta volatilidade, distribuições não normais de preços, forte correlação entre ativos e liquidez limitada.

A aplicação do MIScP mostrou-se viável, com ganhos médios acumulados superiores ao MIS, especialmente nos intervalos 3 e 5 (123,19% e 284,65% em 75 dias), além de menor MDD médio. Esses resultados reforçam a importância de incorporar modelos de previsão para melhorar a construção de portfólios em mercados voláteis. A integração da previsão CNN+BiLSTM com o MIS demonstrou, com base nos dados avaliados, evidências empíricas de sua eficácia na maximização de ganhos e na mitigação de riscos. Portanto, conclui-se que a estratégia proposta oferece uma solução promissora para investidores que buscam otimizar retornos e mitigar riscos no mercado de criptoativos, destacando a eficácia dos modelos de previsão na construção de portfólios mais eficientes e adaptados a esse mercado.

Como trabalhos futuros, recomenda-se a realização de simulações que considerem os efeitos da baixa liquidez, *slippage* e os diferentes custos de transação associados ao rebalanceamento diário, bem como cenários extremos de valorização ou desvalorização de ativos. Além disso, propõe-se um estudo comparativo envolvendo técnicas baseadas em modelos preditivos recentes (e.g., FEDFormer, Reformer), bem como a investigação do impacto da incorporação de informações textuais provenientes de redes sociais e notícias, exploradas por meio de modelos de linguagem.

Referências

- Al-Yahyaee, K. H., Mensi, W., Ko, H.-U., Yoon, S.-M., e Kang, S. H. (2020). Why cryptocurrency markets are inefficient: The impact of liquidity and volatility. *The North American Journal of Economics and Finance*, 52:101168.
- Biesiada, J. e Duch, W. (2007). *Feature Selection for High-Dimensional Data — A Pearson Redundancy Based Filter*, page 242–249. Springer Berlin Heidelberg.
- Bomfim, U. B. e Nascimento, F. M. S. (2024). Monitoramento do mercado de ativos brasileiro: uma proposta de pipeline de dados para detecção de bolhas financeiras. In *Anais Estendidos do XXXIX Simpósio Brasileiro de Banco de Dados (SBBDEstendido 2024)*, SBBDEstendido 2024, page 58–64. Sociedade Brasileira de Computação - SBC.
- Brauneis, A. e Mestel, R. (2019). Cryptocurrency-portfolios in a mean-variance framework. *Finance Research Letters*, 28:259–264.
- Chaweewanchon, A. e Chaysiri, R. (2022). Markowitz mean-variance portfolio optimization with predictive stock selection using machine learning. *International Journal of Financial Studies*, 10(3):64.
- Chen, A. H. L., Liang, Y.-C., e Liu, C.-C. (2013). Portfolio optimization using improved artificial bee colony approach. In *2013 IEEE Conference on Computational Intelligence for Financial Engineering and Economics (CIFEr)*. IEEE.
- Chen, W., Hussain, W., Cauteruccio, F., e Zhang, X. (2024). Deep learning for financial time series prediction: A state-of-the-art review of standalone and hybrid models. *Computer Modeling in Engineering and Sciences*, 139(1):187–224.
- Du, J. (2022). Mean–variance portfolio optimization with deep learning based-forecasts for cointegrated stocks. *Expert Systems with Applications*, 201:117005.
- Gkillas, K., Bekiros, S., e Siriopoulos, C. (2018). Extreme correlation in cryptocurrency markets. *SSRN Electronic Journal*.
- Guo, L., Deng, H., e He, W. (2022). Currency portfolio using combination of assets and cryptocurrency based on LSTM-TLS. In *2022 13th International Conference on E-business, Management and Economics*. ACM.
- Hrytsiuk, P., Babych, T., e Bachyshyna, L. (2019). Cryptocurrency portfolio optimization using value-at-risk measure. In *Proceedings of the 6th International Conference on Strategies, Models and Technologies of Economic Systems Management (SMTESM 2019)*. Atlantis Press.
- Kingma, D. P. e Ba, J. (2014). Adam: A method for stochastic optimization.
- Ma, Y., Han, R., e Wang, W. (2021). Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, 165:113973.
- Malladi, R. K. e Dheeriyaa, P. L. (2020). Time series analysis of cryptocurrency returns and volatilities. *Journal of Economics and Finance*, 45(1):75–94.
- Markowitz, H. (1952). Portfolio selection*. *The Journal of Finance*, 7(1):77–91.

- Mendes, B. V. d. M. e Lavrado, R. C. (2017). Implementing and testing the maximum drawdown at risk. *Finance Research Letters*, 22:95–100.
- Miglietti, C., Kubosova, Z., e Skulanova, N. (2019). Bitcoin, litecoin, and the euro: an annualized volatility analysis. *Studies in Economics and Finance*, 37(2):229–242.
- Patro, S. G. K. e Sahu, K. K. (2015). Normalization: A preprocessing stage.
- Saad, S. M. e Jabbar, A. K. (2022). Analysis of the effect of e-currencies on financial performance based on information technology. *Eastern-European Journal of Enterprise Technologies*, 2(13 (116)):31–37.
- Wang, W., Li, W., Zhang, N., e Liu, K. (2020). Portfolio formation with preselection using deep learning from long-term financial data. *Expert Systems with Applications*, 143:113042.
- Yu, J.-R., Chiou, W.-J. P., Lee, W.-Y., e Lin, S.-J. (2020). Portfolio models with return forecasting and transaction costs. *International Review of Economics Finance*, 66:118–130.
- Zhu, H., Wang, Y., Wang, K., e Chen, Y. (2011). Particle swarm optimization (pso) for the constrained portfolio optimization problem. *Expert Systems with Applications*, 38(8):10161–10169.