

# Análise Multicritério e Rede Neurais Artificiais para prever ações na bolsa de valores

Bruno Nicolau M de Souza Conte  
Universidade Federal do Pará - UFPA  
Belém, PA, Brasil  
brunonicolau.conte@gmail.com

Roberto Célio Limão de Oliveira  
Universidade Federal do Pará - UFPA  
Belém, PA, Brasil  
limao@ufpa.br

**Resumo**—Este artigo apresenta uma abordagem inovadora que combina o método *Analytic Hierarchy Process (AHP)* com *Redes Neurais Artificiais (RNAs)* para prever o desempenho de ações na Bolsa de Valores. O AHP é utilizado para atribuir pesos às variáveis relevantes, considerando sua importância relativa, enquanto as redes neurais são empregadas para modelar e prever o comportamento das ações. Ao combinar essas duas técnicas, a precisão das previsões é aprimorada, superando métodos tradicionais como análise fundamentalista e análise técnica. O desempenho da abordagem foi avaliado utilizando dados históricos de empresas listadas na Bolsa de Valores, métricas como o erro médio absoluto (MAE), erro quadrático médio (MSE) e a Raiz do erro quadrático médio (RMSE) foram aplicadas.

**Palavras-Chave**—*Analytic Hierarchy Process (AHP)*, *Rede Neural Artificial*, *Petrobras*, *Bolsa de Valores*, *Ações*.

## I. INTRODUÇÃO

A Bolsa de Valores desempenha um papel fundamental no cenário financeiro, oferecendo um ambiente onde investidores podem comprar e vender ativos, como ações, visando obter lucros e aumentar seu patrimônio. No entanto, prever o preço desses ativos é um desafio complexo e crucial para os investidores.

Dois abordagens comumente utilizadas para a previsão de preços de ações são a análise fundamentalista e a análise técnica. A análise fundamentalista baseia-se na avaliação de fatores financeiros e econômicos, como balanços patrimoniais, demonstrações de resultados e indicadores macroeconômicos. Já a análise técnica concentra-se no estudo de padrões de preços históricos e volume de negociação, utilizando gráficos e indicadores técnicos [1].

Embora essas abordagens tenham se mostrado úteis, elas apresentam limitações. A análise fundamentalista pode ser influenciada por eventos imprevisíveis e subjetividade na interpretação dos dados. A análise técnica, por sua vez, pode ser afetada pela eficiência de mercado e dificuldade em identificar padrões confiáveis.

Neste contexto, o método *Analytic Hierarchy Process (AHP)* e as *Redes Neurais Artificiais (RNAs)* surgem como ferramentas promissoras para melhorar a precisão das previsões de preços de ativos na Bolsa de Valores. O AHP permite a hierarquização de variáveis relevantes e a atribuição de pesos de acordo com sua importância relativa [2]. As RNAs, por sua vez, são capazes de aprender padrões complexos a partir de conjuntos de dados históricos, identificando relações não lineares entre as variáveis de entrada e a saída desejada [3].

Neste artigo, propõem-se a combinação do AHP com RNA como uma abordagem inovadora para a previsão de preços de ativos na Bolsa de Valores. Essa combinação pode superar as limitações das abordagens tradicionais, oferecendo aos investidores uma ferramenta poderosa para tomada de

decisões informadas, redução de riscos e identificação de tendências com maior confiança.

## II. BOLSA DE VALORES

A bolsa de valores é um mercado organizado onde os investidores podem comprar e vender ações e outros ativos financeiros. É influenciada por uma série de fatores, incluindo indicadores econômicos, eventos políticos, notícias corporativas e condições gerais do mercado. A volatilidade e a imprevisibilidade da bolsa de valores tornam a previsão de preços de ativos um desafio, mas também uma oportunidade para os investidores obterem lucros [4].

Um ativo é um instrumento financeiro que possui valor econômico e pode ser negociado. No contexto do mercado de ações, os ativos são as ações emitidas pelas empresas e são considerados como participação acionária nas mesmas.

Investir na bolsa de valores pode ser um processo complexo, pois envolve análise criteriosa das condições econômicas, financeiras e regulatórias das empresas, além da avaliação dos riscos e das perspectivas de seus rendimentos. A volatilidade dos preços das ações e a influência de fatores externos e internos também contribuem para a complexidade desse mercado.

A Petrobras, por exemplo, é uma das maiores produtoras de petróleo e gás do mundo, em 2022, os campos operados pela companhia produziram 92,66% da produção total de óleo e gás natural do Brasil, enquanto outras operadoras responderam por 7,34% da produção. Assim, sua presença no mercado acionário torna-a um caso relevante para análise das particularidades e desafios do investimento em ações [5][6].

Portanto, compreender a bolsa de valores, o mercado de ações e os desafios de investir, como exemplificado pela Petrobras, é fundamental para investidores interessados em tomar decisões informadas e enfrentar a complexidade desse mercado dinâmico e volátil.

## III. TRABALHOS RELACIONADOS

Vários trabalhos na literatura têm sido amplamente propostos para realizar negociação automatizada de ações. Um dos trabalhos pioneiros neste aspecto é o trabalho de Kimoto T [7], que utilizou Redes Neurais treinadas em várias informações técnicas e econômicas, para determinar quando comprar e vender ações, referente às aplicações relacionadas a predição de ações na bolsa de valores.

Salvatore [8] explora o tema utilizando um conjunto baseado em aprendizagem por Reforço. O modelo é composto por um classificador multicamada, que atua em três etapas e usa duas técnicas de combinação ao mesmo tempo. O modelo tem como objetivo maximizar as recompensas (lucros), gerando novos sinais de negociação por meio de diferentes

iterações no mercado futuro Standard & Poor's 500 e nas ações J.P. Morgan e Microsoft.

Mghazli [9] utiliza análise de modelos de redes neurais artificiais, como perceptrons multicamadas, redes neurais convolucionais, redes LSTM (memória de longo prazo) e transformers de fusão temporal, para resolver o dilema do passeio aleatório na previsão de séries temporais financeiras. O experimento foi conduzido utilizando dados do Índice da Bolsa de Valores de São Paulo (IBOVESPA), demonstrando a efetividade dos modelos investigados no desempenho preditivo.

Vásquez [10] apresenta uma metodologia que integra teorias econômico-financeiras de investimento em carteiras de ações com a técnica multicritério AHP-TOPSIS. O objetivo é tomar decisões no mercado de ações considerando critérios de liquidez, risco e rentabilidade. A metodologia foi testada em um caso real de seleção de carteira de ações no mercado colombiano, demonstrando a importância de equilibrar rentabilidade e risco na tomada de decisões de investimento.

Portanto para preencher as lacunas de trabalhos publicados, este artigo propõem a combinação do método Analytic Hierarchy Process (AHP) com Redes Neurais Artificiais (RNAs) que oferece uma abordagem inovadora e promissora para a previsão de preços de ativos na Bolsa de Valores. Essa combinação supera as limitações das abordagens tradicionais, proporcionando aos investidores uma ferramenta poderosa para tomada de decisões informadas, redução de riscos e identificação de tendências com maior confiança.

#### IV. FUNDAMENTOS

##### A. Analytic Hierarchy Process (AHP)

O método AHP (Analytic Hierarchy Process) é uma abordagem amplamente utilizada na tomada de decisões e resolução de conflitos negociados em problemas com múltiplos critérios. O AHP baseia-se no método newtoniano e cartesiano de decomposição e divisão do problema em fatores claros e dimensionáveis, estabelecendo relações entre eles para posteriormente sintetizá-los. Esse método segue três etapas de pensamento analítico, permitindo uma abordagem estruturada para lidar com a complexidade dos problemas de decisão[11].

A primeira etapa envolve a construção de hierarquias, dividindo o problema em níveis hierárquicos com propósito geral, critérios e alternativas. A Figura 1 apresenta a estrutura hierárquica básica do método AHP.




Fig. 1. Estrutura Hierárquica Básica.

A segunda etapa é a definição de prioridades, usando julgamentos paritários e escalas numéricas para comparar e avaliar os elementos. A quantidade de julgamentos necessários para a construção de uma matriz de julgamentos de  $A$  é  $n(n-1)/2$ , onde  $n$  é o número de elementos dessa matriz, conforme a Equação 1.

$$A = \begin{bmatrix} 1 & a_{12} & \dots & a_{1n} \\ \frac{1}{a_{21}} & 1 & \dots & a_{2n} \\ \vdots & \vdots & \dots & \vdots \\ \frac{1}{a_{n1}} & \frac{1}{a_{n2}} & \dots & 1 \end{bmatrix}, \text{onde: } \begin{aligned} a_{ij} > 0 &\Rightarrow \text{positivo} \\ a_{ij} = 1 &\dots a_{ji} = 1 \\ a_{ij} = \frac{1}{a_{ji}} &\Rightarrow \text{recíproca} \\ a_{ik} = a_{ij} \cdot a_{jk} &\Rightarrow \text{consistência} \end{aligned} \quad (1)$$

A terceira etapa é a consistência lógica, que envolve a verificação da coerência e consistência dos julgamentos através do cálculo da Razão de Consistência (RC). A consistência é alcançada quando  $RC \leq 0,10$ , conforme a Equação 2 [12]:

$$RC = \frac{IC}{IR} \quad (2)$$

onde IR é o Índice Randômico obtido por matriz recíproca de ordem  $n$  e IC é o índice de Consistência e é dado pela Equação 3:

$$IC = \frac{\lambda_{max} - n}{n - 1} \quad (3)$$

onde  $\lambda_{max}$  é o maior auto valor da matriz de julgamento e  $n$  o número de elementos da matriz.

##### B. Multilayer Perceptron (MLP)

O preceptor multicamadas (MLP) é uma rede neural com arquitetura em camadas sequenciais, onde os neurônios são organizados em uma ou mais camadas de processamento. Essa arquitetura é amplamente utilizada na previsão de séries temporais financeiras. Pode-se descrever a saída  $y$  do neurônio  $k$  pela Equação 4:

$$y_k = f \left( \sum_{j=1}^m x_j w_{kj} + b_k \right) \quad (4)$$

onde  $x_1, x_2, \dots, x_m$  são os sinais de entrada,  $w_{k1}, w_{k2}, \dots, w_{km}$  são os respectivos pesos de conexão do neurônio  $k$ ,  $b_k$  é o bias, e finalmente,  $f(\cdot)$  é a função de ativação, neste trabalho utilizamos a ReLu e a Sigmoid como pode ser visto nas Equação 5 e 6 respectivamente.

$$f(x) = \max(0, x) \quad (5)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

#### V. METODOLOGIA

Este artigo utiliza abordagem integrada para a previsão de preços de ativos, envolvendo o uso do AHP e RNA. O AHP é uma técnica de tomada de decisão multicritério, que permite aos investidores atribuir pesos aos diferentes indicadores financeiros e técnicos, com base em suas importâncias relativas. Essa etapa ajuda a reduzir a complexidade da análise, focando nos indicadores mais relevantes [13]. O treinamento da rede neural permite que ela aprenda a capturar

relações não lineares entre esses dados e gere previsões futuras de preços mais precisas.

Inicialmente foi realizada a coleta dos dados históricos da ação Petrobras (PETR4) na B3, incluindo informações como preço de abertura, preço de fechamento, volume de negociação, entre outros.

Identificou-se os critérios do AHP relevantes para a previsão das ações da PETR4, considerando fatores econômicos, notícias relevantes do setor e indicadores financeiros. Assim, foi elaborada a Árvore de Critérios da problemática em análise, exposta na Figura 2.




Fig. 2. Árvore de Critérios da problemática do AHP.

Com base nesses critérios criou-se uma matriz de comparação, em que os critérios são comparados dois a dois, em relação a sua importância na previsão das ações da PETR4.

Em seguida, foram calculados os pesos relativos dos critérios com o AHP, com base na matriz de comparação, considerando sua importância relativa na previsão das ações.

Após a definição dos critérios da problemática do AHP, foi realizado o pré-processamento dos dados e o tratamento dos eventuais dados ausentes e inconsistentes. Posteriormente, os dados foram divididos em conjuntos de treinamento, validação e teste.

Na etapa seguinte, foi realizada a construção do modelo e a definição da arquitetura da Rede Neural, levando em consideração o número de camadas ocultas, os tipos de neurônios, as funções de ativação e a configuração dos parâmetros do modelo.

Por fim, foi realizado o treinamento, a avaliação e o teste do modelo de Rede Neural.

## VI. RESULTADOS

O processo teve início com a coleta dos dados históricos da ação Petrobras (PETR4) na B3, utilizando a biblioteca Python MetaTrader5 [14], incluindo informações como o preço de fechamento, volume de negociação, entre outros. A Figura 3, ilustra um exemplo da disponibilidade dos dados para o atributo preço de fechamento.




Fig. 3. Visualização do preço de fechamento para o PETR4

Após a coleta dos dados, é essencial realizar o tratamento adequado dos valores ausentes, antes de prosseguir com a análise e a modelagem dos dados. No contexto deste estudo,

foram empregados métodos da biblioteca Pandas para executar essas operações de tratamento de dados.

Foi utilizado o método fillna(), que permite preencher os valores ausentes com informações relevantes. É possível utilizar diferentes estratégias para o preenchimento. Neste trabalho foi utilizado os valores medianos, conforme a Equação 7 e 8.

Se  $n$  é ímpar:

$$\text{Mediana: } \frac{n+1}{2} \quad (7)$$

Se  $n$  é par:

$$t_1 = \frac{n}{2} \text{ e } t_2 = \frac{n}{2} + 1$$

$$\text{Mediana} = \frac{t_1 + t_2}{2} \quad (8)$$

onde  $n$  é o número de elementos;

Com os dados prontos, foram extraídos do preço de fechamento, as métricas relevantes para o modelo, tais como: a Média Móvel Simples (MMS) de 20 e 50 períodos, Média Móvel Exponencial (EMA) de 20 e 50 períodos, as Bandas de Bollinger Superior (SBB) e Inferior (IBB) de 20 períodos e desvio padrão de 2

A Média Móvel Simples (MMS) de 20 e 50 períodos são utilizadas para identificar tendências e padrões de movimento dos preços, ao longo do tempo, conforme a Equação 9.

$$MMS = \frac{\sum_{i=1}^n \text{Preço}_i}{n} \quad (9)$$

onde  $\text{Preço}_i$  é preço de fechamento do período atual e  $n$  o número de períodos para o cálculo.

A Média Móvel Exponencial (MME) de 20 e 50 períodos, atribui maior peso aos preços mais recentes, sendo calculada com base em uma constante chamada de alpha, conforme a Equação 10.

$$MME_{Hoje} = \text{Preço}_{Hoje} * K + MME_{Ontem} * (1 - K)$$

$$\text{Onde } k = \frac{2}{n+1} \quad (10)$$

onde  $\text{Preço}_{Hoje}$  é preço de fechamento do período atual e  $n$  o número de períodos para o cálculo.

As Bandas de Bollinger Superior (SBB) e Inferior (IBB) de 20 períodos e desvio padrão de 2, sendo utilizadas para identificar a volatilidade dos preços de um ativo e possíveis

pontos de reversão ou continuação de tendências, conforme a Equação 11, 12 e 13:

$$MMS = \frac{\sum_{i=1}^n \text{Preço}_i}{n} \quad (11)$$

$$SBB = MMS + SD \sqrt{\frac{\sum_{i=1}^n (\text{Preço}_i - MMS)^2}{n}} \quad (12)$$

$$IBB = MMS - SD \sqrt{\frac{\sum_{i=1}^n (\text{Preço}_i - MMS)^2}{n}} \quad (13)$$

onde  $SD$  é desvio padrão,  $\text{Preço}$  é preço de fechamento do período atual,  $MMS$  representa o valor médio para os  $n$  períodos (calculado pela Equação 11) e  $n$  o número de períodos para o cálculo.

Com os dados prontos para a análise, foram identificados os critérios relevantes para a previsão das ações da Petrobras, considerando fatores econômicos, notícias relevantes do setor e indicadores financeiros. Ao final, obteve-se a Matriz de julgamento, exposta na Tabela 1.

TABELA I. MATRIZ DE JULGAMENTO DO AHP

	MMS20	MMS50	MME20	MME50	VOL	SBB	IBB
MMS20	1	5	1/5	3	5	1	1
MMS50	1/5	1	1/9	1/3	3	1/3	1/3
MME20	5	9	1	5	5	1	1
MME50	1/3	3	1/5	1	3	1/3	1/3
VOL	1/5	1/3	1/5	1/3	1	1/7	1/7
SBB	1	3	1	3	7	1	1
IBB	1	3	1	3	7	1	1

Em seguida, com o auxílio da biblioteca `ahpy` no Python [15] determinou-se o vetor de pesos associado à Matriz de Julgamento supracitada, exposto na Tabela 2, a seguir. Além disso, também foi possível determinar a razão de consistência (RC), das respostas dadas pelo decisor, obtida como sendo 0,064 [16].

TABELA II. VETOR DE PESOS ASSOCIADO A MATRIZ DE JULGAMENTO

Critérios	Pesos
MME 20	0,328
SBB 20	0,179
IBB 20	0,179
MMS 20	0,154
MME 20	0,065
VOLUME	0,054
MMS 50	0,041

Antes de realizar o treinamento da Rede Neural é utilizada a técnica de Holdout, em que os dados são divididos em três conjuntos: o conjunto de treinamento (51,09%), o conjunto de validação (24,43%) e o conjunto de teste (24,48%). Os conjuntos de treinamento e validação são usados para treinar e validar o modelo, enquanto o conjunto de teste é usado para avaliar o desempenho do modelo em dados não vistos, conforme a Tabela 3.

TABELA III. DIVISÃO DOS DADO PELO HOLDOUT

Base	Amostras	%
Treinamento	22.250	51,09%
Validação	10.638	24,43%
Teste	10.663	24,48%
Total	43.551	100%

Em seguida, a Rede Neural foi treinada para obter um modelo de previsão de preços de ativos. A Rede Neural foi alimentada com os três últimos preços de fechamento do ativo e os 5 melhores indicadores técnicos selecionados pelo AHP: a média móvel exponencial de 20 períodos, as Bandas de Bollinger Superior e Inferior, a média móvel simples de 20 períodos e a média móvel exponencial de 20 períodos.

A RNA foi criada com 4 camadas. A camada de entrada, intermediária e de saída possuem 30, 25, 25, 1 neurônios respectivamente. A função de ativação utilizada em cada camada foi a ReLu, conforme a Equação 5 visto anteriormente.

O algoritmo de otimização para aprendizagem utilizado foi o RMSprop, por possuir taxa de aprendizagem adaptativo.

A Figura 4 ilustra o resultado desse treinamento.




Fig. 4. Gráfico de Treinamento e Validação da Rede Neural.

Após o treinamento, a Rede Neural foi submetida a um conjunto de testes, para avaliar a capacidade do modelo em prever as ações da bolsa de valores em dados ainda não conhecidos. Para a avaliação do modelo sobre o conjunto de dados de teste, foram utilizados três métricas de desempenho como: erro médio absoluto (MAE), erro quadrático médio (MSE) e a raiz do erro quadrático médio (RMSE), A MAE é calculado da seguinte maneira:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - d_i| \quad (13)$$

onde  $y_i$  é o valor de saída e  $d_i$  é o valor desejado. MSE e RMSE são apresentados a seguir, respectivamente.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - d_i)^2 \quad (14)$$

onde  $y_i$  é o valor de saída e  $d_i$  é o valor desejado.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - d_i)^2} \quad (15)$$

onde  $y_i$  é o valor de saída e  $d_i$  é o valor desejado.

O resultado da predição utilizando a MSE é exibido na Figura 5.




Fig. 5. Previsão da Rede Neural.

Após a previsão foi calculado o erro pelas 3 métricas, a Tabela 4 apresenta o resultado com essas 3 métricas.

TABELA IV. DESEMPENHO DO MODELO NA ETAPA DE TESTE.

Métrica	Erro
MAE	0.041
MSE	0.003
RMSE	0.058

Para melhor comparação foi realizado o treinamento, validação e teste para todos os critérios, sem a etapa de seleção do AHP. Assim, no estudo de caso 1, A Rede Neural foi alimentada com os três últimos preços de fechamento do ativo, a média móvel simples de 20 e 50 períodos, a média móvel exponencial de 20 e 50 períodos, o volume e as Bandas de Bollinger Superior e Inferior. No estudo de caso 2 o modelo foi alimentado com os critérios Selecionado pelo AHP, conforme visto anteriormente, ou seja, excluído a média móvel simples de 50 e o volume. A Tabela a seguir mostra o resultado desta comparação.

TABELA V. DESEMPENHO DOS CASO 1 E 2.

Estudo	MAE	MSE	RMSE
Caso 1	0.049	0.004	0.069
Caso 2	0.041	0.003	0.058

## VII. CONSIDERAÇÕES FINAIS

Neste estudo, foi proposta uma abordagem para prever as ações da bolsa de valores, com foco na ação Petrobras (PETR4) da B3. Utilizou-se uma combinação do método de

AHP (Analytic Hierarchy Process) e Redes Neurais para aumentar a precisão das previsões. Foram coletados os dados históricos da ação PETR4 na B3, incluindo informações como preço de abertura, preço de fechamento e volume de negociação, e posteriormente foi realizado o pré-processamento desses dados para análise.

Através da revisão da literatura, constatou-se que a previsão de ações da bolsa de valores é um desafio devido à volatilidade e imprevisibilidade do mercado. No entanto, essa incerteza também traz oportunidades para investidores obterem lucros. Nesse contexto, a Petrobras é influenciada por uma série de fatores específicos relacionados ao setor de petróleo e gás, como flutuações nos preços internacionais do petróleo e políticas governamentais.

Ao combinar o método de AHP, que permite ponderar a importância dos critérios relevantes para a previsão das ações, com redes neurais, que são capazes de identificar padrões complexos nos dados históricos, possibilitou a obtenção de um modelo promissor para a previsão das ações PETR4. Essa abordagem mostrou potencial para auxiliar investidores e profissionais do mercado financeiro na tomada de decisões informadas.

## REFERENCIAS

- [1] PINTO, Leonardo. Análise Fundamentalista x Análise Técnica: Entenda as diferenças entre os métodos para investir na Bolsa. 2022. XP Expert. Disponível em: <https://conteudos.xpi.com.br>. Acesso em: fevereiro de 2023.
- [2] SITORUS, F.; CILLIERS, J.J.; BRITO-PARADA, P.R. Multi-criteria decision making for the choice problem in mining and mineral processing: Applications and trends. *Expert Systems with Applications*, v.121, p.393–417, 2019.
- [3] PUNIA, S.; NIKOLOPOULOS, K.; SINGH, S.P.; MADAAN, J.K.; LITSIOU, K. Deep learning with long short-term memory networks and random forests for demand forecasting in multi-channel retail. *International Journal of Production Research*, 2020.
- [4] MAIA, Gabriela. Investir na bolsa de Valores? Veja o que é e como funciona! 2022. Xp expert. Disponível em: <https://conteudos.xpi.com.br>. Acesso em: fevereiro de 2023.
- [5] ANP. Boletim da Produção de Petróleo e Gás Natural. 2022. Agência Nacional do Petróleo, Gás Natural e Biocombustíveis. Disponível em: <http://www.anp.gov.br>. Acesso em: fevereiro de 2023.
- [6] PETROBRAS, Conselho de Administração da. Carta Anual de Políticas Públicas e Governança Corporativa 2023. 2023. Disponível em: <https://petrobras.com.br>. Acesso em: fevereiro de 2023.
- [7] Kimoto T, Asakawa K, Yoda M, Takeoka M. Stock market prediction system with modular neural networks. *IJCNN International joint conference on neural networks*. IEEE, pp 1–6, 1990.
- [8] CARTA, Salvatore; CORRIGA, Andrea; FERREIRA, Anselmo; PODDA, Alessandro Sebastian; RECUPERO, Diego Reforgiato. A multi-layer and multi-ensemble stock trader using deep learning and deep reinforcement learning. *Applied Intelligence*, v. 51, n. 2, p. 889–905, 7 set. 2020. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10489-020-01839-5>.
- [9] MGHAZLI, Ya-Sin B.; ARAUJO, Ricardo de Andrade; SEIXAS, José Manoel. Previsão do Mercado Financeiro com Redes Neurais. *Congresso Brasileiro de Inteligência Computacional - CBIC*, Joinville, 2021.
- [10] VÁSQUEZ, Jaime Alberto; ESCOBAR, John Willmer; MANOTAS, Diego Fernando. AHP-TOPSIS Methodology for Stock Portfolio Investments. *Risks*, [S.L.], v. 10, n. 1, p. 4, 27 dez. 2021. MDPI AG. <http://dx.doi.org/10.3390/risks10010004>.
- [11] Costa, Helder Gomes. Introdução ao método de análise hierárquica: análise multicritério no auxílio à decisão. Niterói: H.G.C., 2002.
- [12] VAN KAMPEN, T.J.; AKKERMAN, R.; VAN DONK, D.P. SKU classification: A literature review and conceptual framework.

International Journal of Operations and Production Management, v.32, n.7, p.850– 876, 2012.

- [13] Costa, Helder Gomes. Auxílio multicritério à decisão: método AHP. Rio de Janeiro: Abepro, 2006.
- [14] MQL5 Reference. MetaTrader module for integration with Python. 2021. Disponível em: [https://www.mql5.com/en/docs/python\\_metatrader5](https://www.mql5.com/en/docs/python_metatrader5). Acesso em: 1 fev. 2023.
- [15] GRIFFITH, Philip. Python Package Index (PyPI). 2021. Disponível em: <https://pypi.org/project/ahpy/>. Acesso em: 1 fev. 2023.
- [16] Scikit-Learn (2018). Machine Learning in Python. <https://scikitlearn.org/stable/modules/clustering.html>.