

# Buying and Selling Decision in the Brazilian Stock Exchange Financial Market by a Neo Fuzzy Neuron (NFN) Applied to the Hurwicz Criterion

Gabriel S. Rosa, Pedro H. Pereira, Alisson M. Silva, Charlene C. Resende

Bacharelado em Engenharia de Computação  
Centro Federal de Educação Tecnológica de Minas Gerais  
CEFET-MG - Campus V  
Divinópolis, Minas Gerais, Brasil.

{ms.gabriel.rosa, hrpereira.pedro, charlenecassia}@gmail.com,

alisson@cefetmg.br

**Abstract.** *This work introduces an approach for making decisions on buying and selling stocks in the Brazilian Stock Exchange to maximize profits in each operation. The proposed approach was built using the Neo-Fuzzy-Neuron (NFN) network to predict the future value of stocks and the Hurwicz criterion for decision analysis under risk and uncertainty, considering different degrees of optimism and pessimism. The approach was applied to Petrobras stocks (PETR4), and the results obtained were compared with the "buy and hold" strategy. The computational results and comparisons suggest that the proposed approach is promising and provides a significant return on investment*

**Resumo.** *Este trabalho apresenta uma nova abordagem para a tomada de decisões de compra e venda de ações na Bolsa de Valores brasileira, com o objetivo de maximizar o lucro obtido em cada operação. A abordagem proposta foi construída utilizando a rede Neo-Fuzzy-Neuron (NFN) para prever o valor futuro das ações e o critério de Hurwicz para análise de decisões sob riscos e incerteza, considerando diferentes graus de otimismo e pessimismo. A abordagem foi aplicada às ações da Petrobras (PETR4) e os resultados obtidos são comparados com a estratégia de buy and hold. Os resultados computacionais e as comparações sugerem que a abordagem proposta é promissora e proporciona um retorno significativo ao investimento realizado.*

## 1. Introdução

O mercado financeiro é um sistema complexo que abrange instituições financeiras, investidores, empresas, governos e outros agentes econômicos. Seu principal objetivo é facilitar o fluxo de capital entre esses agentes, permitindo que empresas e governos obtenham financiamento para suas operações e projetos, enquanto oferece oportunidades de investimentos para os investidores. Para tal, o mercado financeiro é dividido por diferentes segmentos, como o mercado de capitais, mercado monetário e mercado cambial [Mishkin and Eakins 2015]. Os valores de capitalização dos ativos presentes nesses segmentos podem ser representados por meio de séries temporais descritas no formato  $S_t = S_{t-1} + \theta$ , em que  $S$  corresponde ao valor atual do ativo,  $t$  é o tempo atual e  $\theta$  reflete a variação positiva ou negativa do valor do ativo.

As variações nos valores dos ativos podem ser influenciadas por diversos fatores, como condições econômicas globais e locais, políticas monetárias e fiscais, eventos geopolíticos, indicadores de desempenho das empresas, fluxos de capital, notícias e informações relevantes, entre outros aspectos [Bekaert et al. 2021]. Esses fatores podem interagir e impactar os preços de maneira complexa e dinâmica, contribuindo para a volatilidade e as oscilações observadas no mercado financeiro.

A teoria do mercado eficiente sugere que os preços dos ativos refletem todas as informações disponíveis publicamente [Samuelson 2016]. No entanto, há "fenômenos que parecem aleatórios, sem aparente periodicidade, embora recorrentes em um sentido geral", conforme apontado por Refenes [Refenes and Azema-Barac 1994]. Isso sugere que as oscilações, embora aparentemente desconexas em curto prazo, são influenciadas por eventos e oscilações passadas, indicando a presença de padrões. Portanto, é possível extrair padrões complexos que seriam dificilmente observados por seres humanos.

Melhor equipe do centro-oeste de Minas Gerais - Maratona mineira de Programação 2023.

Para identificar e aproveitar esses padrões diversos métodos determinísticos e não determinísticos foram utilizados visando tomar decisões de investimentos informadas. Entre eles, destacam-se a econometria e a inteligência artificial (IA). A econometria é um ramo da economia que envolve a aplicação de técnicas estatísticas e modelos matemáticos (determinísticos) para analisar e interpretar fenômenos econômicos [Carvalho et al. 2018]. Por outro lado, a IA é um campo de estudo que busca desenvolver modelos supostamente inteligentes (majoritariamente não determinísticos), capazes de reconhecer padrões complexos e realizar previsões com base no conhecimento adquirido por meio de uma etapa de aprendizado.

Na literatura é possível encontrar diversos trabalhos nos quais a econometria e a inteligência artificial são aplicadas ao mercado financeiro. No trabalho de Charlene [Resende 2021] foi proposto um novo modelo matemático para prever tendências de preços, explorando desvios da hipótese de mercado eficiente. Outras abordagens incluem o uso de modelos simples, como médias móveis [Nametala et al. 2023], e modelos mais complexos, como *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH) [Ni and Xu 2021, Aminimehr et al. 2022] e *Autoregressive Integrated Moving Average* (ARIMA) [Jiang et al. 2022, Felizardo et al. 2019], para prever o valor de ativos.

Modelos de inteligência artificial têm se destacado nesse campo devido à sua capacidade de reconhecer padrões. Diferentes técnicas de inteligência artificial são aplicadas, como o *Support Vector Machine* (SVM) [Anand 2021], *Long Short-Term Memory* (LSTM) [Aminimehr et al. 2022], *Recurrent Neural Network* (RNN) [Yilmaz and Yildiztepe 2022], e até mesmo modelos evolutivos, como o *Evolving Granular Neural Network* (eGNN) e o *Evolving Multivariable Gaussian Fuzzy System* (eMG) [Amaral 2021].

Este trabalho apresenta uma nova abordagem para a tomada de decisão de compra e venda de ativos na bolsa de valores brasileira, a B3. A abordagem proposta combina a capacidade de generalização e predição da rede *Neo Fuzzy Neuron* (NFN) [Silva 2014] com conceitos da teoria de decisão sob riscos e incertezas, utilizando o critério de Hurwicz [Sheng et al. 2013]. A integração da NFN com o critério de Hurwicz visa melhorar a

precisão e eficácia das decisões de investimento, oferecendo uma estratégia robusta e adaptável às flutuações e complexidades do mercado de ações.

O restante do artigo está organizado da seguinte maneira: a Seção 2 apresenta os conceitos fundamentais sobre representação de dados no mercado financeiro, média móvel, NFN e critério de Hurwicz; a Seção 3 detalha passo a passo todas as etapas da abordagem proposta; na Seção 4, são apresentados os resultados obtidos e sua comparação com a estratégia *buy and hold*; por fim, a Seção 5 discute as considerações finais e explora outras possíveis abordagens para o aprimoramento do sistema.

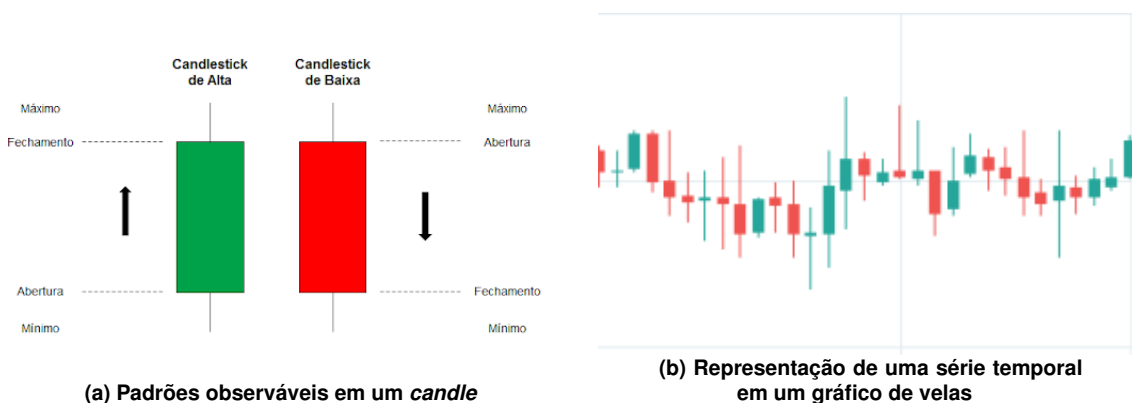
## 2. Fundamentação Teórica

Esta seção apresenta os conceitos necessários para a compreensão da proposta deste artigo. Na Seção 2.1, é descrito um método de representação de dados financeiros por meio de séries temporais utilizando *candlestick*. Em seguida, na Seção 2.2, são introduzidos os conceitos de média móvel. A Seção 2.3 explora a rede *Neo-Fuzzy-Neuron (NFN)*, e, por fim, na Seção 2.4, é discutida a teoria de decisão aplicada ao Critério de *Hurwicz*.

### 2.1. Representação dos Dados

A análise e representação de dados financeiros por meio de séries temporais é comumente realizada utilizando o método de *candlestick* [Debastiani 2007]. Essa abordagem permite a geração de informações discretas sem perder dados relevantes para o processo de negociação. Ela também permite a definição de diferentes intervalos de tempo, destacando os valores mais importantes, como Abertura, Máximo, Mínimo e Fechamento (conhecidos como OHLC em inglês: *Open, High, Low, Close*), conforme ilustrado na Figura 1a. A composição de múltiplos *candles* ao longo do tempo forma uma série temporal discretizada, como exemplificado na Figura 1b. Essa visualização é amplamente utilizada para identificar padrões e tendências nos dados financeiros, fornecendo informações valiosas aos investidores e *traders*. A análise visual dos *candles* auxilia na tomada de decisões de compra e venda de ativos, possibilitando a identificação de pontos de entrada e saída do mercado.

Figura 1. Gráfico de velas e suas características observáveis.



Fonte: FoxBit [Foxbit 2020]

## 2.2. Média Móvel Simples

A Média Móvel Simples (SMA, do inglês *Simple Moving Average*) é uma técnica estatística utilizada para suavizar flutuações de curto prazo e destacar tendências de longo prazo em um conjunto de dados sequenciais [Murphy 1999]. Ela é obtida calculando-se a média aritmética dos valores em um determinado período de tempo, conhecido como janela de suavização. A SMA é dada por:

$$SMA(i) = \frac{V_i + V_{i-1} + V_{i-2} + \dots + V_{i-n}}{n} = \frac{1}{n} \sum_{j=i-n}^i V_j \quad (1)$$

em que,  $V_j$  representa o  $i$ -ésimo valor no conjunto de dados e  $n$  indica a janela de suavização da média.

A SMA é amplamente utilizada em análises estatísticas e financeiras para identificar padrões, suavizar ruídos e fornecer *insights* sobre a evolução dos dados em um horizonte de tempo mais amplo [Kodama 2021]. Ela proporciona uma visão mais suave e estável dos dados, eliminando variações de curto prazo e realçando as mudanças de tendência ao longo do tempo.

## 2.3. Rede Neo-Fuzzy Neuron (NFN)

A rede *Neo-Fuzzy Neuron* (NFN) (Figura 2), proposta por Yamakawa [Yamakawa 1992], é uma rede *Neuro-Fuzzy* composta por  $n$  modelos de Takagi-Sugeno de ordem zero [Takagi and Sugeno 1985], sendo um para cada variáveis de entrada. Os modelos são independentes entre si, e a saída da NFN no instante  $t$  ( $y_t$ ) é obtida através da soma das saídas dos modelos individuais  $y_{ti}$ . A saída da NFN no instante  $t$  é dada por:

$$y_t = \sum_{i=1}^n f_i(x_{ti}) = \sum_{i=1}^n y_{ti} \quad (2)$$

e as saídas individuais  $y_{ti}$  são obtidas pelo grau de ativação de cada regra  $\mu_{A_{ij}}(x_i)$  multiplicado pelo seu respectivo peso  $q_{ij}$ , ponderado pelo somatório do grau de ativação de todas as regras. Os valores de  $y_{ti}$  são calculados por:

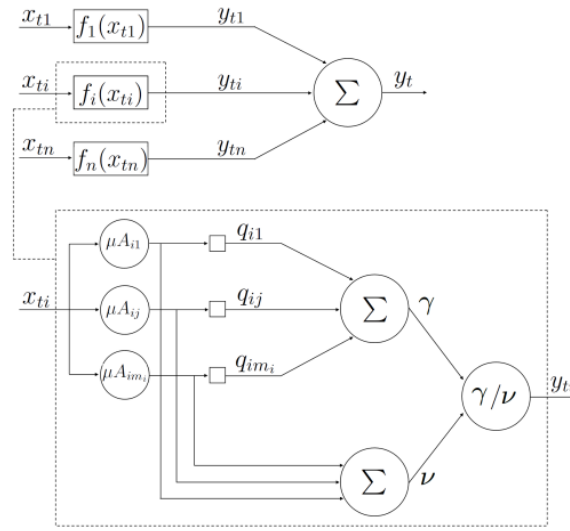
$$y_{ti} = f_i(x_{ti}) = \frac{\sum_{j=1}^{m_i} \mu_{A_{ij}}(x_{ti}) q_{ij}}{\sum_{j=1}^{m_i} \mu_{A_{ij}}(x_{ti})} = \frac{\gamma}{\nu} \quad (3)$$

onde  $i$  indexa as variáveis de entrada,  $j$  indexa as funções de pertinência e  $t$  é o instante de tempo.

A NFN utiliza funções de pertinência triangulares e complementares, e no máximo duas funções são ativadas por amostra e a soma do grau de ativação é sempre igual a 1. Portanto, com a soma dos graus de ativação iguais a 1, a Equação (3) pode ser expressa na forma de:

$$y_{ti} = f_i(x_{ti}) = \sum_{j=1}^{m_i} \mu_{A_{ij}}(x_{ti}) q_{ij} = \gamma \quad (4)$$

Figura 2. Estrutura da NFN.



Fonte: [Silva 2014]

O aprendizado é realizado de maneira supervisionada, visando ajustar os parâmetros  $q_{ij}$  das funções ativadas para cada variável de entrada conforme:

$$q_{ij} = q_{ij} - \alpha(y_t - \hat{y}_t)\mu_{A_{ij}}(x_{ti}) \quad (5)$$

$$q_{ij+1} = q_{ij+1} - \alpha(y_t - \hat{y}_t)\mu_{A_{ij+1}}(x_{ti})$$

em que,  $\alpha$  é a taxa de aprendizado. Os parâmetros  $q_{ij}$  são atualizados utilizando o algoritmo do gradiente descendente [Ruder 2016]. Esse método busca minimizar o erro de saída ao efetuar pequenos deslocamentos ponderados pela taxa de aprendizado [Bottou et al. 1991]. Destaca-se que na NFN somente os pesos referentes as regras ativadas são ajustados.

#### 2.4. Teoria de decisão (Critério de Hurwicz)

O critério de *Hurwicz*, também conhecido como critério de realismo, é uma técnica utilizada para tomar decisões em situações de incerteza. Ele busca equilibrar a aversão ao risco e a aversão à perda, atribuindo um peso  $\alpha$  (chamado de coeficiente de otimismo) à possibilidade de ocorrência de um resultado favorável. Esse coeficiente varia entre 0 e 1, onde 0 indica total aversão ao risco e 1 indica total aversão à perda [Kahneman and Tversky 2013].

Sob esse critério, o tomador de decisão realiza um cálculo de média ponderada entre o melhor e o pior resultado possível para cada alternativa de decisão, levando em consideração todos os estados possíveis da natureza para aquela alternativa específica. É escolhida a decisão que possui a média ponderada máxima [Tsang et al. 2007]. Assim, o critério de *Hurwicz* considera que os resultados tendem a ficar em algum ponto intermediário entre o melhor e o pior cenário possível. Destaca-se que o critério de *Hurwicz* é uma ferramenta importante na teoria de decisão, permitindo que os tomadores de decisões

considerem tanto as possibilidades otimistas quanto as pessimistas ao fazer escolhas em um ambiente incerto [Wang 2022]. O valor de *Hurwicz* é pode ser obtido por:

$$E = \max_{a_i} [\alpha \max_{s_j} v(a_i, s_j) + (1 - \alpha) \min_{s_j} v(a_i, s_j)] \quad (6)$$

em que  $a_i$  corresponde a uma possível decisão,  $s_j$  corresponde a um estado da natureza e  $v$  representa a correlação entre as decisões e os estados da natureza (matriz de retorno esperado).

### 3. Abordagem Proposta

A abordagem proposta pode ser dividida em três etapas distintas. A primeira etapa, descrita na Seção 3.1, consiste na construção e preparação dos dados. Em seguida, na segunda etapa, apresentada na Seção 3.2, é realizada a definição da estrutura da rede NFN. Por fim, na terceira etapa, ilustrada na Seção 3.3, a rede NFN é treinada, executada e os resultados obtidos são submetidos para a análise de decisão, aplicando-se o critério de *Hurwicz*.

#### 3.1. Preparação dos dados

A primeira etapa da abordagem proposta consiste na coleta, preparação e construção do conjunto de dados usado como entrada para a rede NFN. O objetivo da NFN é realizar a previsão um passo a frente, i.e., em  $t + 1$ , usando valores passados da série. Para isso, nessa etapa são coletados os valores de OHLC das ações de interesse durante um intervalo específico de tempo. Em seguida, é criado um conjunto com 28 novas variáveis considerando os últimos 7 valores passados da série para cada um dos atributos OHLC, isto é,  $O_t, O_{t-1}, \dots, O_{t-6}, H_t, H_{t-1}, \dots, H_{t-6}, L_t, L_{t-1}, \dots, L_{t-6}, C_t, C_{t-1}, \dots, C_{t-6}$ .

Para selecionar as variáveis mais relevantes para a previsão, aplica-se o método qui-quadrado ( $R^2$ ), que permite ranquear as variáveis por ordem de relevância. Como resultado desse processo de ranqueamento, são selecionadas para compor o conjunto de dados as quatro variáveis mais relevantes. Além disso, calcula-se as médias móveis simples (SMA) de 10 a 39 espaços amostrais por meio da Equação 1. Em seguida, aplica-se nesse conjunto o método  $R^2$  e seleciona-se as três médias mais representativas para compor o conjunto de dados.

Ao final da etapa de preparação, o conjunto de dados é composto por sete variáveis de entrada: as quatro variáveis OHLC mais relevantes e as três médias móveis selecionadas. Esse conjunto de dados é utilizado como entrada para a rede NFN.

#### 3.2. Estrutura da rede NFN

O conjunto de dados construído na etapa anterior é utilizado como entrada para treinar e, posteriormente, executar e avaliar o desempenho da rede NFN. Para isso, o conjunto de dados é dividido em dois subconjuntos: o primeiro com 60% das amostras para realizar o treinamento e o segundo com 40% das amostras para avaliar o desempenho do preditor.

Um ponto importante a ser considerado é a definição da estrutura da rede NFN. O número de modelos de Takagi-Sugeno de ordem zero é definido pelo número de variáveis de entrada do conjunto de dados. Especificamente no caso da abordagem proposta, o conjunto de dados possui sete variáveis de entrada. Assim, cada variável de entrada é necessário definir o número de funções de pertinência triangulares e complementares

que particionarão o domínio de cada uma das variáveis. As funções de pertinência são responsáveis por mapear os valores das variáveis de entrada em graus de pertinência, indicando o quão relevantes eles são para cada conjunto. Essa etapa é fundamental para o funcionamento adequado da rede NFN, pois permite a representação dos dados de entrada de forma precisa e apropriada, considerando as características e padrões presentes nos mesmos. Por fim, define-se a taxa de aprendizagem ( $\theta$ ) e o número de épocas de treinamento.

### 3.3. Análise de decisão

Nesta última etapa, a rede NFN é treinada utilizando o conjunto de dados, estrutura e configurações definidos anteriormente. Após o treinamento, a NFN é executada no conjunto de dados de teste e os resultados da previsão são analisados segundo o critério de *Hurwicz*. O índice de otimismo é fixado em 0,6 para refletir a postura de um investidor mais otimista em relação ao mercado. No entanto, outros valores do índice de otimismo pode ser utilizados.

Em seguida, após a previsão realizada pela NFN, usa-se uma regressão linear entre os dois últimos valores reais e o valor previsto para criar e ajustar uma reta que se aproxima desses três pontos. A inclinação da reta ( $\Phi$ ) representa a tendência esperada para a ação e é utilizada para desenvolver a matriz de retorno esperado. Essa matriz fornece uma estimativa dos possíveis retornos financeiros com base nos dados coletados conforme

$$\begin{vmatrix} p & (1 - \frac{\Phi}{90})p \\ 0 & (\frac{\Phi}{90})p \end{vmatrix} \quad (7)$$

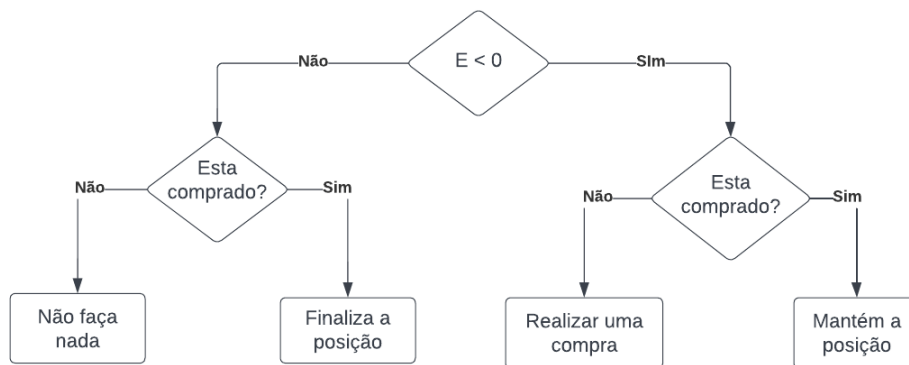
em que, 'p' é o valor previsto pelo modelo NFN e 'Φ' é a inclinação da reta após o ajuste linear.

Aplicando a Equação 6 na matriz de retorno esperado da Equação 7, é possível calcular um único valor (E) que representa a estimativa de ganho ou perda. Com base nesse valor, uma decisão é tomada: se E for maior que zero, é realizada uma compra com todos os recursos disponíveis, por outro lado, se já estiver comprado, matem a posição de compra anterior; caso E seja menor que 0, todas as operações em andamento são encerradas. O processo de tomada de decisão segue o fluxograma ilustrado na Figura 3.

## 4. Experimentos Computacionais e Resultados

Nesta seção, são detalhados os experimentos realizados para avaliar e comparar o desempenho da abordagem proposta. Os experimentos foram realizados considerando a ação da Petrobras (PETR4). Os dados obtidos da *Bloomberg* [Bloomberg 2017] compreendem o período de 02/05/2017 a 31/08/2017 e foram temporizados em intervalos de 15 minutos, resultando em 2500 amostras.

Para a construção do conjunto de dados, o método  $R^2$  foi aplicado no conjunto com 28 variáveis obtidas pelos 7 valores passados dos atributos OHLC. Foram selecionadas as variáveis  $C_t, C_{t-1}, C_{t-3}, C_{t-5}$ . Em seguida, após a aplicação do método nas médias móveis as variáveis  $SMA_{11}, SMA_{23}$  e  $SMA_{35}$  foram selecionadas. O conjunto de dados foi dividido em 60% para o treinamento da rede NFN e 40% teste. A Figura 4



**Figura 3. Fluxograma de ações possíveis após o cálculo do valor esperado do critério de Hurwicz**

ilustra a variação do preço da ação no período selecionado e a separação do conjunto de treinamento e teste.

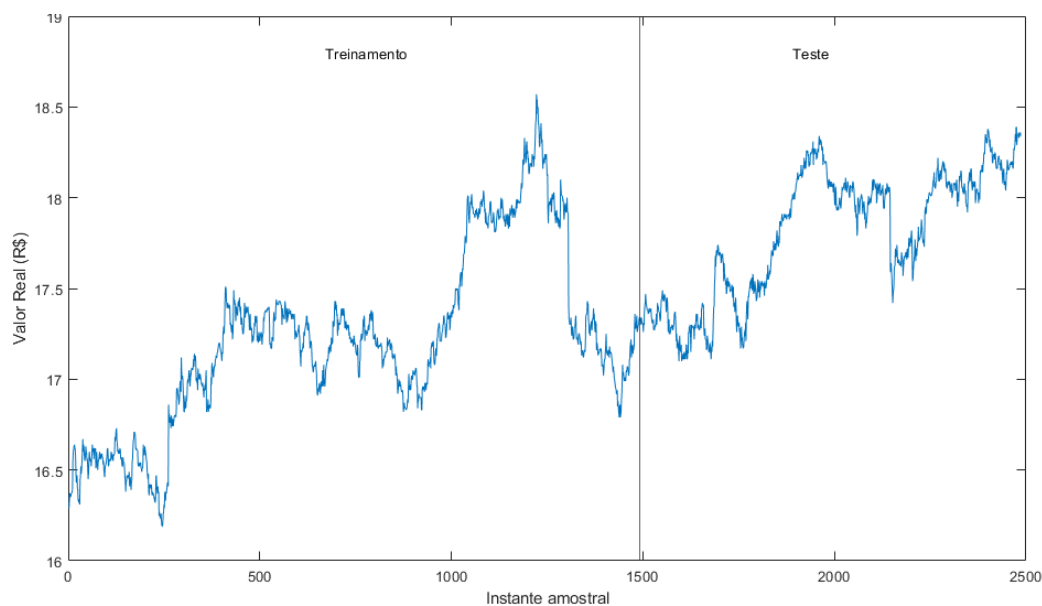
A estrutura da rede NFN foi definida com as 7 variáveis selecionadas e o universo de discurso de cada variável foi particionado uniformemente como se segue:  $C_t$  com 7 funções de pertinência;  $C_{t-1}$  com 6,  $C_{t-3}$  com 5,  $C_{t-5}$  com 4,  $SMA_1$  com 8,  $SMA_2$  com 6 e  $SMA_3$  com 4. A taxa de aprendizagem  $\theta$  foi fixada em 0.01 e o número de épocas de treinamento em 40.

A Figura 5 ilustra os resultados obtidos pela rede NFN no conjunto de teste. O maior erro obtido foi de R\$ 0,09, enquanto o erro médio foi de apenas R\$ 0,0145. Os resultados apresentados sugerem que a rede NFN tem uma boa capacidade de fazer previsões, o que é fundamental para a tomada de decisões no mercado financeiro.

Para as simulações de investimento foi definido um valor inicial de R\$ 5.000,00 e um índice de otimismo ( $\alpha$ ) de 0,6. Os resultados obtidos serão comparados com a estratégia *buy and hold*. A Figura 6 ilustra ponto a ponto o desempenho das duas abordagens. Como pode ser visto na figura, a abordagem proposta obteve um desempenho superior à estratégia *buy and hold* em mais de 97% das amostras. Em outras palavras, se o investidor optasse por liquidar todas as ações em qualquer momento durante o período do experimento em 97,07% dessas vezes ele teria um melhor resultado com a abordagem proposta neste trabalho. Além disso, considerando todo o período do experimento a abordagem proposta propiciou um retorno de R\$ 658,60 (13,17%), enquanto *buy and hold* de R\$ 297,00 (5,94%).

Destaca-se ainda que a abordagem proposta apresentou vantagens adicionais em relação à estabilidade e volatilidade do investimento. Foi observado que a abordagem baseada em algoritmos de aprendizagem resultou em quedas menos acentuadas no valor do investimento, proporcionando uma maior proteção contra perdas significativas. Essa característica é particularmente relevante para investidores que desejam minimizar os riscos e manter uma trajetória mais estável de crescimento de seus investimentos.





**Figura 4. Dados das ações da Petrobras temporizados no gráfico de 15 minutos da bolsa de valores do Brasil (02/05/2017 a 31/08/2017). Com representação da divisão da base de dados com 60% destinado ao treinamento do modelo e 40% destinado ao teste do mesmo.**

## 5. Conclusão


Este artigo introduziu uma nova abordagem para prever a variação de ações no mercado da bolsa de valores brasileira. A abordagem proposta utiliza a rede NFN para prever o valor do ativo combinada com o critério de decisão de *Hurwicz* que possibilita incorporar o índice de otimismo do usuário e tornar a solução adaptativa a diferentes tipos de investidores. Em outras palavras, a abordagem pode ser personalizada tanto para investidores conservadores e moderados, quanto para investidores mais agressivos.

Experimentos computacionais foram realizados para avaliar o desempenho da abordagem proposta e os resultados obtidos foram comparados com a estratégia *buy and hold*. Os resultados obtidos e as comparações realizadas sugerem a abordagem proposta como uma alternativa viável e de grande potencial, especialmente na maximização dos lucros e minimização das perdas na variação dos ativos.


Para trabalhos futuros, uma possibilidade interessante é explorar outros algoritmos de aprendizagem aplicados ao critério de *Hurwicz*, permitindo uma comparação entre diferentes modelos. Além disso, utilizar dados em outras frequências temporais pode contribuir para identificar rapidamente mudanças de tendência no mercado e tomar decisões mais eficientes e oportunistas. Essas direções de pesquisa podem aprimorar ainda mais a solução proposta, oferecendo *insights* valiosos sobre o mercado financeiro e ampliando o potencial de sucesso na previsão da variação de ações. Outro ponto que deve ser avaliado é a aplicação da abordagem proposta para outros ativos do mercado financeiro.

## Referências

Amaral, V. L. d. (2021). Sistemas fuzzy evolutivos na previsão e recomendação de investimentos em criptomoedas. Master's thesis, Centro Federal de Educação Tecnológica



**Figura 5. Erro em reais (R\$) do conjunto de teste.**



**Figura 6. Gráfico comparativo dos valores acumulados entre a estratégia proposta e a estratégia de *Buy and Hold*, fornecendo uma análise visual das diferenças de desempenho ao longo do tempo.**

de Minas Gerais, Belo Horizonte - MG.

Aminimehr, A., Raoofi, A., Aminimehr, A., and Aminimehr, A. (2022). A comprehensive study of market prediction from efficient market hypothesis up to late intelligent market prediction approaches. *Computational Economics*, 60(2):781–815.

Anand, C. (2021). Comparison of stock price prediction models using pre-trained neural networks. *Journal of Ubiquitous Computing and Communication Technologies (UCCT)*, 3(02):122–134.

Bekaert, G., Engstrom, E., and Ermolov, A. (2021). Macro risks and the term structure of interest rates. *Journal of Financial Economics*, 141(2):479–504.

Bloomberg (2017). Petroleo brasileiro.

Bottou, L. et al. (1991). Stochastic gradient learning in neural networks. *Proceedings of Neuro-Nimes*, 91(8):12.

Carvalho, V. P. d. et al. (2018). Previsão de séries temporais no mercado financeiro de ações com o uso de rede neural artificial.

- Debastiani, C. A. (2007). *Candlestick: um método para ampliar lucros na Bolsa de Valores*. Novatec Editora.
- Felizardo, L., Oliveira, R., Del-Moral-Hernandez, E., and Cozman, F. (2019). Comparative study of bitcoin price prediction using wavenets, recurrent neural networks and other machine learning methods. In *2019 6th International Conference on Behavioral, Economic and Socio-Cultural Computing (BESC)*, pages 1–6. IEEE.
- Foxbit (2020). Gráfico de candles: o que é e como interpretar.
- Jiang, M., Jia, L., Chen, Z., and Chen, W. (2022). The two-stage machine learning ensemble models for stock price prediction by combining mode decomposition, extreme learning machine and improved harmony search algorithm. *Annals of Operations Research*, pages 1–33.
- Kahneman, D. and Tversky, A. (2013). Prospect theory: An analysis of decision under risk. In *Handbook of the fundamentals of financial decision making: Part I*, pages 99–127. World Scientific.
- Kodama, L. S. (2021). Estudo da rentabilidade de fundos imobiliários com utilização da média móvel.
- Mishkin, F. S. and Eakins, S. G. (2015). *Financial markets and institutions*, eight edition.
- Murphy, J. J. (1999). *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. Penguin.
- Nametala, C. A., Souza, J. V. d., Pimenta, A., and Carrano, E. G. (2023). Use of econometric predictors and artificial neural networks for the construction of stock market investment bots. *Computational Economics*, 61(2):743–773.
- Ni, J. and Xu, Y. (2021). Forecasting the dynamic correlation of stock indices based on deep learning method. *Computational Economics*, pages 1–21.
- Refenes, A. N. and Azema-Barac, M. (1994). Neural network applications in financial asset management. *Neural Computing & Applications*, 2:13–39.
- Resende, C. C. d. (2021). Modelos matemático-computacional para previsão de tendência de preços: Abordagem com múltiplos ativos buscando oportunidades em desvios da hipótese de mercado eficiente. Master's thesis, Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte - MG.
- Ruder, S. (2016). An overview of gradient descent optimization algorithms. *arXiv preprint arXiv:1609.04747*.
- Samuelson, P. A. (2016). Proof that properly anticipated prices fluctuate randomly. In *The world scientific handbook of futures markets*, pages 25–38. World Scientific.
- Sheng, L., Zhu, Y., and Hamalainen, T. (2013). An uncertain optimal control model with hurwicz criterion. *Applied Mathematics and Computation*, 224:412–421.
- Silva, A. M. d. (2014). *Sistemas Neuro-Fuzzy Evolutivos: Novos Algoritmos de Aprendizado e Aplicações*. PhD thesis, Universidade Federal de Minas Gerais, Escola de Engenharia, Programa de Pós-Graduação em Engenharia Elétrica, Belo Horizonte.

- Takagi, T. and Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. *IEEE transactions on systems, man, and cybernetics*, (1):116–132.
- Tsang, K., Samsatli, N., and Shah, N. (2007). Capacity investment planning for multiple vaccines under uncertainty: 2: Financial risk analysis. *Food and Bioprocess Processing*, 85(2):129–140.
- Wang, Z. (2022). Uncertain differential game with hurwicz criterion. *Journal of Ambient Intelligence and Humanized Computing*, pages 1–11.
- Yamakawa, T. (1992). A neo fuzzy neuron and its applications to system identification and prediction of the system behavior. In *Proc. of the 2nd Int. Conf. on Fuzzy Logic & Neural Networks*, pages 477–483.
- Yilmaz, F. M. and Yildiztepe, E. (2022). Statistical evaluation of deep learning models for stock return forecasting. *Computational Economics*, pages 1–24.