



08, 09, 10 e 11 de novembro de 2022
ISSN 2177-3866

QUALIDADE DE PREVISÕES DOS PREÇOS MÁXIMOS E MÍNIMOS: UMA ANÁLISE APLICADA A AÇÕES DO SETOR ELÉTRICO

DANIEL VITOR TARTARI GARRUTI
UNIVERSIDADE FEDERAL DE UBERLÂNDIA (UFU)

FLAVIO LUIZ DE MORAES BARBOZA
UNIVERSIDADE FEDERAL DE UBERLÂNDIA (UFU)

LUCAS NAVES DA SILVEIRA
UNIVERSIDADE FEDERAL DE UBERLÂNDIA (UFU)

GUMERCINDO RODRIGUES CHAVES NETO
UNIVERSIDADE FEDERAL DE UBERLÂNDIA (UFU)

Agradecimento à órgão de fomento:
CAPES

QUALIDADE DE PREVISÕES DOS PREÇOS MÁXIMOS E MÍNIMOS: UMA ANÁLISE APLICADA A AÇÕES DO SETOR ELÉTRICO

1. Introdução

Investir em ações é uma alternativa de rendimento a ser considerada pelos brasileiros. De acordo com o relatório elaborado pela B3 (2022a), há, ao todo, 5 milhões de pessoas físicas investindo em renda variável (menos de 2% da população), representando apenas 17% do total de recursos investidos na bolsa de valores. Embora seja arriscado, investir se tornou uma possibilidade interessante para se obter independência financeira.

Há inúmeras formas de alocações de recursos e estratégias de investimentos, que são estudadas principalmente por profissionais e analistas do mercado financeiro. Neste segundo caso, as mais conhecidas são a análise técnica – também chamada de análise gráfica e que tem um foco no comportamento do preço ao longo do tempo, ou seja, uma visão mais quantitativa – e a análise fundamentalista, a qual busca entender a saúde da empresa, sendo assim de cunho mais qualitativo. Em seu papel consultivo, alguns analistas preferem observar os movimentos de preços (tendência) (Henrique, Sobreiro, & Kimura, 2019). Outros avaliam os fundamentos das diversas ações ou realizam análises técnicas antes de aconselhar seus clientes sobre decisões de investimento (Wang & Kim, 2018). Para cada estratégia, não há garantia de rentabilidade futura, além da possibilidade de eventos externos, capazes de influenciar diretamente na rentabilidade dos preços.

A previsibilidade do mercado de ações tornou-se alvo de debate e duas hipóteses tornaram-se mais aceitas. Uma delas é a de que os mercados são eficientes (Fama, 1970), que consiste na hipótese de que as notícias e conhecimentos vigentes de um ativo, já são contabilizadas na precificação do ativo; portanto, não há possibilidade de antecipar a tendência ou preço de uma ação, devido à capacidade de organização dos mercados. Outra hipótese considera que os movimentos de mercado são influenciados por diversos fatores, incluindo aspectos comportamentais dos seus participantes, que continuamente podem ser percebidos pelas oscilações dos preços (Lo, 2004); e, conseqüentemente, é possível prever preços e ou tendências (Goetzmann, 1998).

A utilização de técnicas computacionais para análise, previsão e identificação de padrões dos ativos tem ganhado notoriedade ao longo dos últimos anos. Com isso, modelos de *machine learning* (ML; por exemplo, *random forest*, *boosting*, *bagging* e *regressão linear*), e mais especificamente, *deep learning*, vêm sendo implementados no mercado financeiro, sendo utilizados para captar o risco de falência (Barboza, Kimura, & Altman, 2017) ou para estimar preços de ações (Laboissiere, Fernandes, & Lage, 2015).

A partir da literatura científica, observa-se resultados atrativos quando as arquiteturas empregadas para a classificação e previsão de séries temporais foram o *Support Vector Machine* (SVM) conjugado com Rede Neural Artificial (RNA) (Henrique et al., 2019). Entretanto, a abordagem de técnicas de ML para séries temporais se torna complexa. Tal desafio está geralmente associado ao comportamento não linear e à imprevisibilidade das variações dos preços, dado que sofrem impactos frequentes de fatores endógenos e exógenos (Lo, 2004). Portanto, utilizar as melhores arquiteturas para prever os preços ou tendências de ativos financeiros é fundamental para a precisão dos resultados, mas é necessário escolher os parâmetros, variáveis explicativas, entre outras coisas, para criar um modelo preditivo consistente; conseqüentemente, examinar indicadores de erros apropriados é crucial para a qualidade e robustez desse previsor.

Diante disso, este estudo investiga alguns modelos baseados em *machine learning* para prever preços de ativos máximo e mínimos diários (Laboissiere et al., 2015), que sejam capazes de fornecer resultados mais precisos e consistentes. Nesse sentido, foram testadas 3 arquiteturas, sendo 2 delas baseadas na técnica de SVM – com bases linear e não linear, respectivamente –

e um modelo híbrido (SVM com RNA), o qual utiliza as previsões destes 2 previsores puros como dados de entrada na rede neural. A fim de contrapor a teoria, verificou-se a qualidade destes 3 modelos frente ao *Random Walk*, considerado o melhor estimador possível para um mercado eficiente.

As variáveis aplicadas nesta pesquisa baseiam-se nos preços das empresas do setor elétrico, juntamente com os índices Ibovespa (como sinal do mercado) e IEE (Energia Elétrica, relacionado ao setor), e o valor do câmbio Real-Dólar. Para avaliar a qualidade dos previsores, foram calculados 3 indicadores de erro: *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE) e *Mean Absolute Error* (MAE). Além disso, aplicou-se uma estratégia razoavelmente simples de investimento no intuito de averiguar o custo de erro nessas previsões e fornecer uma perspectiva mais detalhada do efeito que cada decisão imprecisa pode causar nos ganhos dos investidores.

Os resultados mostram que a técnica SVM com base linear teve melhor desempenho que todas as outras, o que evidencia uma possível ineficiência no mercado local, em especial, no setor elétrico. Embora seja supostamente simples, a simulação da estratégia de investimento em ativos do IEE confirma a superioridade do melhor predictor, que apresentou retornos acima do *benchmark* em 11 dos 14 ativos analisados, sendo que o total de retorno (considerando o desempenho em todos ativos juntos) foi maior nos 3 cenários investigados (operando com foco no preço mínimo, preço máximo e em ambos simultaneamente), chegando a mais de 600% ao ano.

Este artigo contribui para o campo pesquisa especialmente em 2 quesitos. Primeiramente, evolui resultados anteriores com a demonstração de eficiência das previsões, além de revelar contra exemplos à hipótese de eficiência do mercado. E, segundo, que a pesquisa mostra aplicação imediata e com resultados expressivos que sugerem benefícios para seus usuários e suficientemente simples de serem implementados por especialistas, gestores de fundos e investidores independentes.

Não obstante, uma implicação natural deste trabalho é a possibilidade de se empregar estratégias de investimentos automatizadas baseadas em inteligência artificial, posto que as previsões apresentadas aqui podem ser incluídas em algoritmos – que são usados em plataformas de investimentos – e até mesmo a própria estratégia investigada ser um deles.

Além desta seção introdutória, este trabalho contém a seção 2 de referencial teórico, tratando sobre os temas de análise de investimento e inteligência artificial. Seguido pela seção 3 de metodologia, tratando como os dados foram coletados e os métodos utilizados para as análises, a seção 4 realiza as análises dos resultados e na seção 5 é tratado sobre as principais conclusões obtidas.

2. Fundamentação Teórica

Na literatura acadêmica, pode-se observar 2 formas de examinar o comportamento de preços futuros por meio de dados passados: a análise técnica e a fundamentalista (Ahmadi et al., 2018; Henrique et al., 2019).

A análise fundamentalista está preocupada principalmente com os dados financeiros das empresas, como por exemplo as demonstrações de resultados e fluxo de caixa (Anbalagan & Maheswari, 2015). Em contrapartida, a análise técnica acredita que os preços passados geram sinais para avistar os preços futuros e, sendo assim, os analistas técnicos geralmente projetam indicadores que são formulados a partir dos preços históricos, na tentativa de identificar padrões que se repetem e, então, antecipar o valor futuro de ativos financeiros (Jain, Saini, & Ahluwalia, 2019).

A Teoria de Dow afirma que o mercado se movimenta em tendências, oscilando em períodos de baixa e alta, sendo esta uma das principais bases da análise técnica, que foi criada

por Charles Henry Dow. Posteriormente, Willian Peter Hamilton, seu sucessor, afirmou que os movimentos realizados pelos preços, já refletem todas as informações do mercado; logo, é possível realizar as previsões de acordo com tais valores (Goetzmann, 1998).

No mercado financeiro, pode-se empregar a análise técnica para diferentes objetivos. Barroso, Cardoso, e Melo (2021), utilizaram 4 indicadores da análise técnica para otimizar portfólios de investimentos na bolsa brasileira durante 6 anos. Assim, foram montadas 2 carteiras mensais e analisados os retornos, bem como seus riscos. Diante disso, conseguiram bons resultados, uma vez que chegaram a melhores retornos sofrendo os mesmos riscos.

Apesar de existir uma infinidade de técnicas de análise, o modelo denominado *Random Walk* (Passeio aleatório, RW) pressupõe que os valores das ações de mercados financeiros se comportam de maneira aleatória. Dessa forma, a melhor estimativa para o preço de amanhã é o preço de hoje (Fama, 1995). No entanto, a Hipótese dos Mercados Eficientes (HME) é uma teoria a qual defende que os ganhos entre os investidores são limitados ao desempenho do mercado como um todo (que seria, em tese, a carteira mais diversificada), ou seja, nenhum participante tem retornos acima do mercado, pelo menos num mercado eficiente. Com isso, para um aumento de ganhos é necessário que o investidor corra mais riscos para superar a melhor estimativa que seria aquela proveniente do RW (Fama, 1970).

Em particular, ur Rahman (2019) utilizou os dados diários dos anos de 2004 a 2015 do índice KSE 100 (mercado financeiro do Paquistão), para verificar a hipótese do passeio aleatório e comparar com resultados de previsões utilizando a análise técnica. Como resultado, constatou-se que o mercado não segue um passeio aleatório, como também obtiveram resultados superiores utilizando os indicadores da análise técnica.

Existe também a hipótese dos mercados adaptativos (HMA), elaborada por Lo (2004), sendo uma alternativa interessante para as diversas críticas a HME. Nela, acredita-se que as informações e ou variáveis que afetam os preços no mercado financeiro não conseguem realizar tais mudanças de valor em tempo real. Diante disso, os indicadores técnicos podem oferecer boas observações, podendo verificar antecipadamente os comportamentos de manada, que conseguem causar grandes alterações no mercado (Panopoulou & Souropanis, 2019)

Dentro dessa perspectiva, a literatura acadêmica apresenta uma vasta utilização de técnicas de ML, especialmente RNAs, com o intuito de encontrar padrões a partir de dados conhecidos previamente. Para os estudos direcionados a fenômenos do mercado financeiro, pode-se citar a previsão de preços com variáveis baseadas nos indicadores técnicos (Ayala, García-Torres, Noguera, Gómez-Vela, & Divina, 2021; Henrique et al., 2019; Laboissiere et al., 2015). Uma vez que, apesar de existirem muitos métodos eficientes para a predição de mercados financeiros, as técnicas de RNAs tem apresentado resultados interessantes, pois dificilmente são superados pelas demais (Ahmadi et al., 2018).

Para a previsão de preços de máximos e mínimos, Laboissiere et al. (2015) utilizaram a rede neural *Multilayer Perceptron* (MLP) e geraram bons resultados, ao atingir MAPE inferior a 0,9% para os máximos e inferior a 2,1% para os mínimos de algumas ações da bolsa brasileira. Na pesquisa desenvolvida por Guresen, Kayakutlu e Daim (2011), foi verificado que para o índice de ações da NASDAQ a RNA MLP obteve melhores resultados do que as RNAs *Dynamic Artificial Neural Network* (DAN2) e *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH). Este resultado, foi obtido após a realização de validações cruzadas, com as métricas *Mean Square Error* (MSE) e *Mean Absolute Deviate* (MAD).

SVM é outra técnica de ML normalmente empregada para classificação (por exemplo, prever se a tendência será de alta ou baixa), mas que também é usada para regressão (Ahmadi et al., 2018). Recentemente, a combinação de redes neurais com SVM para previsões tem mostrado bons resultados nos mercados de ações (Anbalagan & Maheswari, 2015; Henrique et al., 2019).

Ballings, Van den Poel, Hespeels, e Gryp (2015) verificaram que as melhores técnicas para a previsão de preços foi SVM, *random forest* e *kernel factory*, dentre 7 técnicas que foram analisadas neste estudo. Enquanto, Nayak, Mishra, e Rath (2015) utilizaram uma estrutura híbrida de SVM e *K-Nearest Neighbor* para a previsão de índices do mercado Indiano, realizando para tempos diário, semanal e mensal. Como resultado, os autores encontraram resultados melhores que os modelos anteriores, uma vez que foi possível trabalhar apropriadamente com os dados e complementarmente controlar os erros.

A combinação da análise técnica e técnicas de aprendizado de máquina podem gerar bons resultados no mercado financeiro. Como pode ser observado no trabalho de Ayala et al. (2021), que utilizaram os indicadores *Triple Exponential Moving Average* (TEMA) e *Moving Average Convergence/Divergence* (MACD) juntamente com as técnicas *Linear Model* (LM), RNA, *Random Forest* e SVM. Para tanto, examinaram ativos de empresas dos índices Ibex35 (IBEX), DAX and *Dow Jones Industrial* (DJI), a partir de dados diários entre os anos de 2011 a 2019. Seus resultados mostram que é possível obter melhores lucros com menos negociações realizadas.

Em síntese, há evidências (baseadas em estudos acadêmicos) de que técnicas de ML, aliadas aos indicadores técnicos, conseguem identificar padrões embutidos nos preços históricos de ativos financeiros. Assim, esse estudo propõe a seguir um exame empírico de tais arquiteturas no mercado brasileiro, o que é detalhado na seção seguinte.

3. Metodologia

O desenvolvimento deste estudo pode ser dividido em duas partes. Inicialmente, aplica-se 4 técnicas para prever o valor de ativos e avaliar a qualidade de tais previsões. Depois, examina-se o desempenho de uma estratégia de investimento com o intuito de confirmar que as estimativas feitas na etapa anterior podem apresentar resultados interessantes. Assim, esta seção descreve todos elementos envolvidos: dados, técnicas de previsão, variáveis explicativas, análise de qualidade e proposta de estratégia de investimento.

3.1 Dados

Foram coletados os valores diários de abertura, máximo, mínimo e fechamento (usualmente chamados de *Open*, *High*, *Low* e *Close*, OHLC) de todas ações que compõem o Índice de Energia Elétrica (IEE) e com dados disponíveis por mais de 10 anos, como também o histórico do índice Ibovespa, do índice do setor (IEE) e da cotação do Dólar Americano frente ao Real.

A escolha de ações deste setor se deve a possibilidade de comparar os resultados com o estudo de Laboissiere et al. (2015), que também investigaram alguns dos ativos investigados aqui. Cabe ressaltar que o estudo citado utiliza dados referente as ofertas de compra e venda dos ativos (comumente denominadas de *Bid price* e *Ask price*, respectivamente), mas que foram desconsideradas nesse estudo por uma questão de simplicidade, isto é, são dados que requerem uma certa habilidade adicional do investigador, além de não estarem disponíveis tão facilmente quanto as cotações.

A janela de investigação abrange um período de 12 anos, ou melhor, com início em 01 de janeiro de 2010 e término em 31 de dezembro de 2021. Isso se faz necessário, pois permite que os modelos de ML sejam treinados adequadamente e potencialmente evitem problemas de sobreajuste. Todos os dados foram extraídos do site Yahoo Finance (2022), exceto o IEE que foi coletado no site da B3 (2022b).

3.2 Indicadores técnicos, pré-processamento e seleção de atributos

Usou-se como atributos os últimos 5 valores anteriores de OHLC, além dos índices mencionados anteriormente, tomando como base o trabalho de Laboissiere et al. (2015). Ainda, foram calculadas as médias móveis ponderadas de 21 dias (WMA21) para todas as variáveis de OHLC e índices, totalizando assim, um total de 28 atributos. A Equação (1) mostra a fórmula para WMA para n períodos e a Tabela 1 mostra resumidamente todos os atributos usados para prever os preços das ações.

$$WMA_n = \frac{\sum_{k=1}^n k \cdot p_k}{\sum_{k=1}^n k} \quad \text{Eq. (1)}$$

Tabela 1

Atributos Usados Neste Estudo.

Atributos	Quantidade
<i>Open</i>	1
<i>Open</i> D-1 a D-5	5
<i>High</i> D-1 a D-5	5
<i>Low</i> D-1 a D-5	5
<i>Close</i> D-1 a D-5	5
WMA21 de OHLC	4
WMA21 de Ibovespa	1
WMA21 de IEE	1
WMA21 de USD/BRL	1
Total	28

A base de dados foi previamente separada em 2 partes: 80% dos dados mais antigos foram usados para esta filtragem e os outros 20% de amostras recentes foram reservados para avaliar a qualidade dos previsores (também chamada de base de dados fora da amostra, ou *out-of-sample*, ou mesmo amostra teste).

Seguindo a proposta de Laboissiere et al. (2015), os atributos passaram por uma etapa denominada *feature selection*, que tem o intuito de diminuir o número de atributos usados na etapa de predição, que podem gerar ruídos desnecessários.

De acordo com Srivastava, Joshi, e Gaur (2014), esta etapa é importante pois nela são selecionados apenas os atributos com maior relevância para o modelo de regressão, ou seja, os atributos com informações redundantes e que podem gerar ruídos nas etapas seguintes são descartados. Outras vantagens percebidas é que com a diminuição da dimensionalidade dos dados de entrada ganha-se em termos de performance computacional (diminui o tempo gasto na previsão) e precisão do modelo (Ahmadi et al., 2018).

Neste trabalho a etapa de *feature selection* utilizou um algoritmo com abordagem do tipo *Wrapper*, conhecido por *Backward Elimination*. Neste método a busca pelos atributos mais relevantes começa usando o conjunto completo de atributos e a cada iteração verifica-se a contribuição de cada atributo. Se não for significativa, então o atributo é descartado. Ao final da busca temos então um conjunto reduzido de atributos que serão usados na etapa seguinte de modelagem.

Outra etapa de tratamento de dados usual é a normalização dos dados, que foi realizado neste estudo logo após a seleção de atributos. Seu intuito é diminuir o efeito de ruídos nas observações, o que aparentemente tende a melhorar as previsões. Para tanto, aplicou-se a técnica chamada *StandardScaler*, que segue a seguinte regra dada pela Equação (2):

$$z = \frac{x-\mu}{\sigma}, \quad \text{Eq. (2)}$$

onde z é o valor normalizado, x é o valor a ser transformado, μ e σ são a média e o desvio-padrão dos valores x presentes na amostra, respectivamente.

Importante mencionar que o cálculo de μ e σ são baseados somente na amostra de treinamento; e posteriormente aplicados para a normalização os dados de teste. Tal procedimento tem o intuito de evitar inconsistências no emprego de parâmetros que considerariam dados futuros em suas estimativas.

Do ponto de vista prático, usar dados ainda desconhecidos em modelos de previsão de tendências para o mercado financeiro não faz sentido, pois o que acontecerá daquele instante em diante é o que se pretende descobrir (com bom desempenho e consistência), justamente após o modelo já ter sido desenvolvido.

Tendo isso bem definido, a base de dados foi então devidamente preparada para uso na construção dos modelos, os quais são descritos a seguir.

3.3 Modelos previsores

Após estes passos, o estudo foi dividido em 2 partes. A primeira parte consiste no treinamento e teste dos modelos ligados a técnica SVM, sendo um modelo com *kernel* linear e outro com *kernel* não linear, no caso, a função de base radial (RBF). De acordo com Barboza et al. (2017), esse método consiste na separação dos dados por um hiperplano que é construído a partir de alguns pontos especialmente selecionados (os chamados de vetores de suporte) que minimizam o erro para os demais pontos. A escolha de pontos ocorre por meio de uma função de transformação, denominada *kernel*. No caso de um modelo de regressão (que é a forma aplicada nesta pesquisa), o hiperplano será o desenho que possui o maior número de suportes.

Para a implementação do algoritmo, utilizou-se 2 *kernels*: o linear, que tende a encontrar soluções para problemas mais simples; e o não linear, o qual considera é mais apropriado para situações mais complexas, como é o caso das previsões no mercado financeiro. Entretanto, a interpretação dos dados pode ser simples em alguns ativos e, por isso, testa-se nesse estudo essas duas formas.

Depois, seguiu-se para a fase de treinamento e teste da rede neural do tipo *Multi Layer Perceptron* (MLP), usando adicionalmente as previsões fornecidas pelos dos modelos de SVM.

Em outras palavras, os dados obtidos do modelo linear e não linear do algoritmo SVM, serviram como *input* para a rede neural, além dos outros atributos utilizados nos algoritmos SVM, os quais foram selecionados previamente, limitando a um máximo de 30 atributos para cada ativo.

A MLP é uma das topologias de RNAs mais utilizadas por conta de sua boa adaptação a funções não lineares (Guresen et al., 2011). As redes além de conseguirem aprender por meio de exemplos, conseguem ainda generalizar resultados a partir de suas próprias informações (Laboissiere et al., 2015). É possível utilizar técnicas de *backpropagation* - processo que retorna os resultados obtidos para uma nova aprendizagem - nas MLPs. Diante disso, é possível adaptar os elementos do processamento não linear (Guresen et al., 2011).

Resumidamente, o modelo MLP é um algoritmo de aprendizagem supervisionada, que simula as células neurais humanas, sendo que os terminais de entradas do modelo são análogos aos dendritos, e um terminal de saída, o axônio. O modelo matemático utiliza: (i) funções com pesos sinápticos, que determinam a importância de cada dado de entrada e, conseqüentemente, seu viés; e (ii) uma função de ativação, responsável pelo processamento em camada(s) oculta(s). (Laboissiere et al., 2015)

No presente estudo, a rede neural foi desenvolvida com 3 camadas ocultas, para realizar as iterações dos dados e com função de ativação conhecida como *Rectified Linear* (ReLU). Exceto a taxa de aprendizagem, que foi constante, os demais parâmetros foram ajustados em virtude da particularidade de cada ativo.

Todas as técnicas foram empregadas com o mesmo objetivo: prever o valor de uma ação no dia t , a partir de dados históricos e indicadores descritos no Tabela 1. Mais especificamente, o interesse aqui está em dois valores extremos da ação, ou seja, os preços máximo e mínimo. Diante disso, foram construídos dois modelos para cada técnica, representados genericamente pelas Equações 3 e 4:

$$\text{Preço máximo}_t = f(X) \quad \text{Eq. (3)}$$

$$\text{Preço mínimo}_t = g(X) \quad \text{Eq. (4)}$$

Com relação a base de dados, os atributos X e a variável de interesse foram separados em 80% para o treinamento e 20% para o teste, da mesma maneira feita por Laboissiere et al. (2015). É importante informar que essa divisão ocorreu em dois momentos. Primeiro, para a elaboração do modelo SVM. Com o modelo devidamente ajustado, esta amostra inicial de teste foi novamente dividida na proporção 80-20, sempre com corte temporal. Isso permitiu garantir que as previsões do modelo SVM eram apropriadas para comparar com o MLP. Com isso, o período de teste efetivamente investigado contempla o período entre julho e dezembro de 2021, o que representa 119 observações.

Para fins de comparação, as previsões destes 3 previsores foram comparadas com o modelo teórico de *Random Walk* (RW), considerado em tese o previsor a ser batido. Para fins de esclarecimento, o modelo RW considera que a melhor estimativa de um valor em uma série temporal (y_t), como é o caso do valor das ações, é o seu valor último valor conhecido (y_{t-1}), conforme descrito na Equação (5), a seguir:

$$y_t = y_{t-1} + \varepsilon, \quad \text{Eq. (5)}$$

sendo ε o erro da estimativa.

3.4 Métricas de erro

Existem diversos critérios adotados na literatura para comparar qual regressor é o mais apropriado. Mais uma vez, adotou-se as métricas de erro empregadas por Laboissiere et al. (2015), o que permitiu uma comparação minimamente apropriada dos resultados obtidos. Além

disso, são as mais frequentes em estudos com propósitos similares (Nti, Adekoya, & Weyori, 2020).

O Erro Médio Absoluto (*Mean Absolute Error*, MAE) é a média dos erros, que são dados pelo valor absoluto da diferença entre o valor real e o valor estimado. Tendo os erros absolutos calculados para cada amostra, calcula-se a média desses valores, conforme apresentado na Equação (6).

$$MAE = \frac{1}{n} \sum_{t=1}^n |p_t - \bar{p}_t|, \quad \text{Eq. (6)}$$

tal que n é o total de observações, p_t e \bar{p}_t são os valores estimados e observados, respectivamente.

O Erro Percentual Médio Absoluto (*Mean Absolute Percentual Error*, MAPE) é o próprio MAE, porém calculado em termos de percentuais, conforme a Equação (7).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|p_t - \bar{p}_t|}{p_t} \quad \text{Eq. (7)}$$

A Raiz do Erro Quadrático Médio (*Root Mean Squared Error*, RMSE), cuja fórmula é dada pela Equação (8), é uma forma de calcular o erro de estimação um pouco diferente de MAE, pois é mais sensível a erros de maior valor, sendo útil para perceber se o erro dado por MAE é uma medida consistente (ou melhor que esconde uma variabilidade de menor intensidade).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (p_t - \bar{p}_t)^2}, \quad \text{Eq. (8)}$$

Toda a atividade de modelagem e cálculo de erros foram executados em linguagem Python, usando os pacotes *yfinance* (coleta de dados), *pandas* (manipulação dos dados), *pandas-ta* (estimação das WMAs) e *scikit-learn* (modelagem e previsões).

3.5 Simulação de Estratégia de Investimento

Uma questão frequentemente levantada a respeito de previsões de preços de ativos financeiros é: mesmo que tais estimativas sejam boas, como confirmar que elas de fato podem gerar lucros?

Para sanar essa dúvida, esse estudo complementa as análises de qualidade das previsões com a simulação de uma estratégia. Os critérios definidos para ela são simples e estão descritos nos Algoritmos 1 e 2 a seguir. Por simplicidade, são denominadas daqui em diante por *Low-only* e *High-only*, respectivamente.

Algoritmo 1

Detalhamento das Etapas e as Respectivas Tomadas de Decisões para a Estratégia de Investimento a Partir da Estimativa de Preço Mínimo (Low-only).

Etapa	Decisão
1. Previsão de Preço Mínimo (p)	Define preço de compra (objetivo ou alvo)
2. Verificar se $p <$ Preço de Abertura	Se atender, envia ordem de venda no valor do preço de abertura; se não, nada faz.
3. Caso a ordem seja executada, definir preço alvo	Enviar ordem de compra no valor p .

4. Conferir conclusão da operação no final do dia	Se a ordem de compra ainda não foi executada, excluir ordem em aberto e executar compra no valor a mercado.
---	---

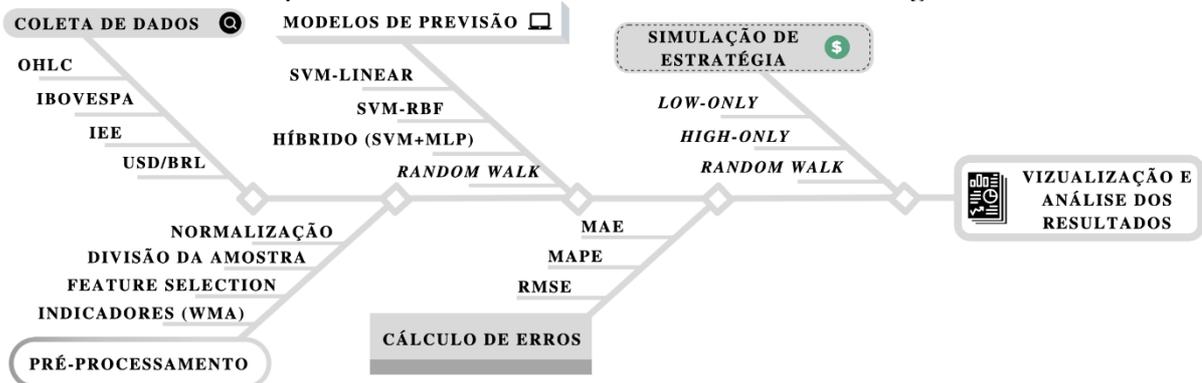
Algoritmo 2

Detalhamento das Etapas e as Respectivas Tomadas de Decisões para a Estratégia de Investimento a Partir da Estimativa de Preço Máximo (High-only).

Etapa	Decisão
1. Previsão de Preço Máximo (P)	Define preço de venda (objetivo ou alvo)
2. Verificar se $P >$ Preço de Abertura	Se atender, envia ordem de compra no valor do preço de abertura; se não, nada faz.
3. Caso a ordem seja executada, definir preço alvo	Enviar ordem de venda no valor P.
4. Conferir conclusão da operação no final do dia	Se a ordem de compra ainda não foi executada, excluir ordem em aberto e executar compra no valor a mercado.

Figura 1

Passo a Passo da Pesquisa Realizada, Delineado Através de um Fluxograma.



4. Resultados e discussões

Por meio de 4 técnicas usadas prever valores máximos e mínimos de ações do setor elétrico negociadas na B3, inicia-se a apresentação dos resultados pelas estimativas das 3 métricas de erros. Depois disso, avalia-se a aplicação de uma estratégia de investimentos tendo como base tais previsões.

4.1. Qualidade das previsões

Em termos práticos, a visualização do erro percentual, no caso o MAPE, é o dado mais aplicado nesse contexto, uma vez que os ativos analisados possuem valores absolutos diferentes. Por isso, primeiramente ilustra-se na Figura 2 os valores do MAPE provenientes de cada previsor, separado em dois blocos (estimativas de preços mínimos e máximos diários de ativos que compõem o IEE), considerando os 4 métodos aplicados.

Figura 2

MAPE das Previsões de Preços Mínimos e Máximos para cada Ativo

Ativo	Preço Mínimo				Preço Máximo			
	RW	SVM-Lin	SVM-RBF	MLP	RW	SVM-Lin	SVM-RBF	MLP
CEBR3	2,481	1,421	76,480	34,867	1,828	0,873	77,683	33,241
CMIG3	1,335	0,912	5,560	26,046	1,190	0,886	6,336	22,726
CPFE3	1,164	0,768	7,984	15,927	1,275	0,889	5,868	16,616
CPLE6	1,070	0,988	46,613	7,539	1,140	0,864	45,094	7,405
CSNR3	2,331	1,139	2,078	1,703	1,286	1,100	1,047	2,032
EGIE3	0,724	0,465	1,506	10,184	0,680	0,508	1,479	12,652
ELET3	1,893	1,228	9,969	8,200	1,452	1,001	5,066	8,555
ENBR3	0,838	0,501	6,945	6,777	0,829	0,645	9,762	1,447
ENEV3	1,446	1,115	54,160	21,517	1,381	1,137	4,660	24,472
ENGI11	1,141	0,868	12,389	13,245	1,096	0,830	6,434	9,135
EQTL3	1,168	0,799	45,194	9,744	1,071	0,807	44,006	10,295
LIGT3	2,070	1,368	1,716	37,129	1,921	1,145	21,643	38,596
TAE3	0,969	0,748	29,080	17,415	0,809	0,590	31,482	16,841
TRPL4	0,769	0,478	4,543	5,567	0,731	0,530	5,431	5,567

Nota: (1) as abreviações RW, SVM-Lin, SVM-RBF e MLP referem-se aos métodos de *Random Walk*, SVM usando *kernels* linear e não linear, e o modelo híbrido SVM com MLP, respectivamente; (2) as cores destacam os melhores resultados (verde), os piores (vermelho) e os intermediários representados pelas tonalidades.

Por tratar-se de uma medida de erro, quanto menor o valor, melhor é o resultado. Assim, pode-se observar que o *benchmark* (RW) é sempre superado pelo modelo de SVM com kernel linear, tanto para estimar o preço mínimo quanto o preço máximo diário, independente do ativo estudado. As cores facilitam essa comparação, pois observa-se nitidamente tons de verde em todos os valores de MAPE para SVM com *kernel* linear, enquanto RW está sempre uma tonalidade abaixo ou amarelo, sendo assim um resultado ainda pior neste último caso.

Interessante perceber que os demais previsores forneceram pouca qualidade em suas estimativas, as quais ficaram em grande maioria bem abaixo de SVM-Lin. Assim, tais números corroboram com ur Rahman (2019), ao superar RW em suas previsões.

Em particular, salienta-se que o melhor modelo teve MAPE abaixo de 0,5% em 3 casos (e somente para preço mínimo), enquanto RW não conseguiu alcançar 0,7% em caso algum. Não obstante, a variação dos erros é pequena para SVM-Lin e RW, o que revela uma certa consistência do melhor modelo. Isso simboliza uma provável ineficiência de mercado na forma fraca originária desses ativos, uma vez que há uma forma sistemática e razoavelmente persistente de prever a tendência de tais preços.

Além disso, pode-se afirmar que este nível de erro mostra que tais estimativas são mais qualificadas que aquelas apresentadas por Laboissiere et al. (2015). Embora seus resultados sejam de períodos distintos, trata-se de ações de empresas similares, como também em medidas de erros adimensionais (em níveis percentuais).

Nas Figuras 3 e 4, apresentam-se RMSE e MAE, respectivamente. Como ambos são mensurados em valores absolutos, o comparativo entre eles é permitido, desde que a observação seja no mesmo ativo; no caso, basta comparar dados que estão na mesma linha. Assim, apesar das cores não identificar precisamente o melhor em cada ativo, é possível associar os menores níveis de erro pela tonalidade.

Figura 3

RMSE das Previsões de Preços Mínimos e Máximos para cada Ativo

Ativo	Preço Mínimo				Preço Máximo			
	RW	SVM-Lin	SVM-RBF	MLP	RW	SVM-Lin	SVM-RBF	MLP
CEBR3	1,473	0,560	23,659	8,808	1,322	0,431	24,248	9,208
CMIG3	0,298	0,196	1,116	4,288	0,264	0,200	1,319	3,838
CPFE3	0,442	0,279	2,178	5,590	0,456	0,305	1,706	5,473
CPLE6	0,107	0,073	3,001	0,573	0,109	0,071	2,989	0,586
CSNR3	0,688	0,378	0,588	0,439	0,550	0,314	0,335	0,494
EGIE3	0,353	0,225	0,693	4,483	0,346	0,253	0,681	5,341
ELET3	0,939	0,670	4,493	3,702	0,732	0,457	3,052	3,989
ENBR3	0,223	0,130	2,030	1,520	0,215	0,148	2,219	0,351
ENEV3	0,291	0,226	8,494	3,650	0,282	0,226	0,813	4,396
ENGI1	0,674	0,511	5,410	7,498	0,661	0,512	3,088	5,771
EQTL3	0,383	0,288	11,003	2,606	0,351	0,275	11,064	2,835
LIGT3	0,344	0,213	0,275	5,441	0,327	0,206	2,901	5,719
TAAE3	0,189	0,119	3,647	6,668	0,149	0,098	4,011	6,589
TRPL4	0,273	0,152	1,147	1,680	0,261	0,182	1,376	1,680

Nota: (1) as abreviações RW, SVM-Lin, SVM-RBF e MLP referem-se aos métodos de *Random Walk*, SVM usando *kernels* linear e não linear, e o modelo híbrido SVM com MLP, respectivamente;(2) as cores destacam os melhores resultados (verde), os piores (vermelho) e os intermediários representados por tons mais claros até o valor mediano (em amarelo).

Mesmo que os resultados sejam parecidos, o RMSE mostra com maior riqueza a variabilidade dos erros em cada ativo. Por exemplo, a estimativa de preço máximo de CEBR3 por SVM-Lin tem menor variação que erros de previsão para CMIG3, pois o RMSE é pouco mais que o dobro do MAE para o primeiro ativo e no segundo caso, eles distanciam-se em torno de 20%. A partir daí, percebe-se que as previsões para CMIG3 oscilam preponderantemente entre 0,10 e 0,20. Curiosamente, o MAPE para ambos os ativos é praticamente o mesmo. Com essas análises, percebe-se que a qualidade do modelo de SVM se alinha com o estudo de Ballings et al. (2015).

Figura 4

MAE das Previsões de Preços Mínimos e Máximos para cada Ativo

Ativo	Preço Mínimo				Preço Máximo			
	RW	SVM-Lin	SVM-RBF	MLP	RW	SVM-Lin	SVM-RBF	MLP
CEBR3	0,624	0,348	21,927	8,744	0,474	0,214	22,618	8,987
CMIG3	0,218	0,149	0,946	4,160	0,201	0,149	1,119	3,784
CPFE3	0,306	0,201	2,119	4,293	0,343	0,242	1,606	4,573
CPLE6	0,069	0,063	2,976	0,476	0,076	0,057	2,961	0,478
CSNR3	0,399	0,200	0,373	0,301	0,236	0,193	0,189	0,364
EGIE3	0,276	0,178	0,581	3,940	0,265	0,199	0,580	4,972
ELET3	0,673	0,436	3,800	2,829	0,542	0,377	2,054	3,081
ENBR3	0,158	0,095	1,401	1,260	0,161	0,124	1,938	0,283
ENEV3	0,220	0,169	8,141	3,751	0,219	0,181	0,742	3,751
ENGI1	0,489	0,370	5,354	5,813	0,487	0,368	2,850	4,139
EQTL3	0,278	0,189	10,843	2,307	0,264	0,199	10,876	2,489
LIGT3	0,258	0,167	0,210	4,958	0,250	0,151	2,740	5,330
TAAE3	0,118	0,092	3,611	6,449	0,102	0,075	3,985	6,306
TRPL4	0,184	0,114	1,094	1,312	0,178	0,130	1,334	1,312

Nota: (1) as abreviações RW, SVM-Lin, SVM-RBF e MLP referem-se aos métodos de *Random Walk*, SVM usando *kernels* linear e não linear, e o modelo híbrido SVM com MLP, respectivamente;(2) as cores destacam os melhores resultados (verde), os piores (vermelho) e os intermediários representados por tons mais claros até o valor mediano (em amarelo).

No que tange os erros em si, confirma-se a qualidade soberana do SVM-Lin. Uma possível explicação para que o modelo híbrido não performe bem seja o excesso de ruído adquirido do previsor SVM com *kernel* não linear.

Outro ponto relevante é a utilização da ferramenta de seleção de atributos, que tem como base uma análise linear e, potencialmente, privilegia modelos lineares. Assim, as variáveis independentes tendem a fornecer mais informação para modelos com mesma estrutura.

No que concerne o modelo híbrido, os resultados foram insatisfatórios em todos os cenários, o que contrapõe achados anteriores como Ahmadi et al. (2018) e Guresen et al. (2011) que defendem RNA como um modelo mais consistente no contexto de investimentos, especialmente aquela do tipo MLP. Por outro lado, isso mostra que é preciso uma escolha parcimoniosa tanto das variáveis explicativas como dos parâmetros do modelo (Henrique et al., 2019). Mais que isso, entender as limitações e construir modelos requer melhor entendimento do problema.

4.2. Análise da Simulação de Investimento

Para confirmar a eficiência nas previsões, foi feita uma demonstração de investimento fictícia levando-se em conta os preços de mínimos e máximos previstos para cada ativo presente no IEE, que possuíam dados suficientes para a elaboração e aferição dos modelos.

Como os previsores de SVM-RBF e MLP tiveram níveis de erros muito acima do modelo teórico, eles foram dispensados desta análise. Essa escolha se justifica pela baixa confiança nos resultados, tornando as decisões baseadas na estratégia em algo de ordem aleatória e, portanto, com resultados sem sentido. A Figura 5 mostra os ganhos (ou prejuízos) na implementação das estratégias descritas anteriormente pelos Algoritmos 1 e 2. Adicionalmente, uma terceira estratégia é apresentada, a qual representa o somatório resultante de *Low-only* e *High-only* simultaneamente, denominada *High+Low*.

Pode-se observar que, considerando a estratégia *High+Low*, o método proposto (que usa SVM) supera RW na grande maioria dos ativos (11 de 14). Ao considerar apenas investidas sobre o preço máximo (*High-only*), o melhor desempenho permanece, porém SVM apresentou-se melhor para EGIE3 e ELET3 neste caso. Embora a estratégia tenha melhor resultado em *High-only* para o ativo CEBR3, tal comparação é desnecessária, pois ambas resultaram em retornos negativos. Já para a estratégia *Low-only*, 10 dos 14 ativos trouxeram melhores resultados para o modelo proposto, sendo todas elas com percentuais positivos. Cabe destacar o desempenho para LIGT3 (próximo de 10 vezes melhor), CPFE3 (quase 5 vezes melhor) e ENBR3 (4 vezes), que sugerem oportunidades interessantes.

Figura 5

*Comparativo dos Retornos Estimados para 2 Estratégias, Sendo a Primeira Baseada em Random Walk e a Segunda no Melhor Previsor Proposto (SVM com Kernel Linear). O Marcador * Denota o Melhor Desempenho em Cada Caso.*

Estratégia	Random Walk			SVM - kernel Linear		
	High-only	Low-only	High+Low	High-only	Low-only	High+Low
CEBR3						
CMIG3						
CPFE3						
CPL6						
CSR3						
EGIE3						
ELET3						
ENBR3						
ENE3						
ENGI1						
EQTL3						
LIGT3						
TAE3						
TRPL4						
Somatório	54,78%	213,33%	271,11%	96,96%	* 218,92%	* 315,88%

Considerando a performance mais abrangente (isto é, no somatório de todos os ativos), RW foi superado em todos os 3 cenários pelo modelo proposto, o qual alcançou a impressionante marca de 300% no período analisado, ou ainda mais de 650% (96,96% + 218,92% + 315,88%) em termos anuais. Em outras palavras, mesmo que a estratégia seja adotada conjuntamente para todos os ativos e também com meta somente nos máximos ou somente nos mínimos, SVM com *kernel* linear foi mais rentável em qualquer uma dessas circunstâncias.

Tais resultados confirmam majoritariamente os achados de Ayala et al. (2021), que apontam SVM aliado indicadores técnicos como uma ferramenta adequada para nesse contexto. Entretanto, o modelo linear trouxe melhores resultados que a forma mais complexa (não-linear), sugerindo que esses ativos possuem um comportamento mais simplista e, portanto, com maior previsibilidade.

Neste caso particular, fica evidenciado que o setor elétrico colabora para o mercado brasileiro apresentar oportunidades em que o investidor possa obter retornos acima do esperado, ou melhor, estaria em desacordo com a eficiência de mercado, ao menos em sua forma fraca. Entretanto, Lo (2004) defende que ocorram ajustes devido a fatores ligados ao comportamento dos participantes do mercado, liquidez, volume dos lucros, entre outros. Ao observar mais localmente, existem possíveis explicações para que tais resultados corroborassem com a teoria dos mercados adaptativos.

5. Conclusões

A análise preditiva no contexto do mercado de capitais tem sido intensamente investigada, tanto na academia quanto fora dela. Os recentes avanços nas metodologias e disponibilização de dados financeiros têm incentivado pesquisadores a entender o comportamento dos preços e desenvolver novas formas de investir.

Assim, este estudo investigou a qualidade de 2 técnicas de *machine learning* (SVM e RNA), por meio de 3 modelos de previsão, sendo um deles na forma híbrida, ou seja, na união dessas duas técnicas para estimar o valor futuro de ações.

Como objetivo inicial, buscou-se estimar os preços máximos e mínimos diários de ativos presentes no Índice de Energia Elétrica, o que permitiu a comparação com um estudo anterior, como também confrontar o modelo de *Random Walk*.

Os resultados mostram que o modelo híbrido foi ineficaz, mas o predictor baseado em SVM com *kernel* linear superou tanto os achados de Laboissiere et al. (2015) como RW,

apresentando níveis de erro abaixo de 0,5% em alguns casos, o que corrobora com outros estudos e, ao mesmo tempo, traz um contraexemplo para a HME e coloca em discussão a existência de outros elementos, como é sugerido na HMA (Lo, 2004)

Para confirmar a eficiência de tais previsões, realizou-se a análise de estratégia de investimentos nos ativos em estudo. Mais uma vez, confirmou-se o desempenho expressivo do modelo de SVM. No somatório de todos ativos, a estratégia proposta supera RW em todos os cenários examinados. Cabe destacar o retorno apurado superior a 600% a.a.

Portanto, pode-se constatar que a aplicação da técnica de SVM com *kernel* linear foi eficaz na previsão de preços máximos e mínimos, posto que superou RW e trouxe retornos positivos na simulação realizada. Com isso, esse trabalho apresenta contribuições interessantes tanto para a academia – ao perceber que RNAs e modelos híbridos nem sempre superam outros métodos na previsão de preços –, como também para profissionais e investidores do mercado de capitais, quando apresenta uma estratégia de investimento com resultados expressivos. Consequentemente, esses achados trazem implicações principalmente para investidores, que podem utilizar tais ferramentas em suas análises e até mesmo em algoritmos automatizados.

Embora apresente melhorias, este trabalho possui algumas limitações, tais como, um pequeno período de testes, o emprego de *feature selection* de cunho linear, emprego de dados somente do setor elétrico, e aplicação de estratégia sem gestão de riscos. Em contrapartida, todos quesitos podem ser tratados em estudos futuros. Em particular, a janela de estudo pode ser aumentada com o uso de janela rolantes para a execução da modelagem. Entretanto, as inovações metodológicas constantes favorecem o aprimoramento e a realização contínua de pesquisas com este propósito.

Referências

- Ahmadi, E., Jasemi, M., Monplaisir, L., Nabavi, M. A., Mahmoodi, A., & Jam, P. A. (2018). New efficient hybrid candlestick technical analysis model for stock market timing on the basis of the Support Vector Machine and Heuristic Algorithms of Imperialist Competition and Genetic. *Expert Systems with Applications*, 94, 21-31.
<https://doi.org/10.1016/j.eswa.2017.10.023>
- Anbalagan, T., & Maheswari, S. U. (2015). Classification and prediction of stock market index based on fuzzy metagraph. *Procedia Computer Science*, 47, 214-221.
<https://doi.org/10.1016/j.procs.2015.03.200>
- Ayala, J., García-Torres, M., Noguera, J. L. V., Gómez-Vela, F., & Divina, F. (2021). Technical analysis strategy optimization using a machine learning approach in stock market indices. *Knowledge-Based Systems*, 225, 107119.
<https://doi.org/10.1016/j.knosys.2021.107119>
- Ballings, M., Van den Poel, D., Hespeels, N., & Gryp, R. (2015). Evaluating multiple classifiers for stock price direction prediction. *Expert systems with Applications*, 42(20), 7046-7056. <https://doi.org/10.1016/j.eswa.2015.05.013>
- B3. (2022a). 5 milhões de contas. https://www.b3.com.br/pt_br/noticias/5-milhoes-de-contas-de-investidores.htm
- B3. (2022b). Energia Elétrica - IEE - Estatísticas Históricas. https://www.b3.com.br/pt_br/market-data-e-indices/indices/indices-de-segmentos-e-setoriais/indice-energia-eletrica-iee-estatisticas-historicas.htm
- Barboza, F., Kimura, H., & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems with Applications*, 83, 405-417.
<https://doi.org/10.1016/j.eswa.2017.04.006>
- Barroso, B. C., Cardoso, R. T. N., & Melo, M. K. (2021). Performance analysis of the integration between Portfolio Optimization and Technical Analysis strategies in the Brazilian

- stock market. *Expert Systems with Applications*, 186, 115687. <https://doi.org/10.1016/j.eswa.2021.115687>
- Creswell, J. W. (2007). Projeto de Pesquisa: métodos qualitativo, quantitativo e misto. trad. Luciana de Oliveira da Rocha. 2ª ed. Porto Alegre: Artmed.
- Fama, E. F. (1995). Random walks in stock market prices. *Financial analysts journal*, 51(1), 75-80. <https://doi.org/10.2469/faj.v51.n1.1861>
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The journal of Finance*, 25(2), 383-417. <https://doi.org/10.2307/2325486>
- Goetzmann, W. N. (1998). The dow theory: William peter hamilton's track record reconsidered. In *Journal of Finance*.
- Guresen, E., Kayakutlu, G., & Daim, T. U. (2011). Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*, 38(8), 10389-10397. <https://doi.org/10.1016/j.eswa.2011.02.068>
- Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2019). Literature review: Machine learning techniques applied to financial market prediction. *Expert Systems with Applications*, 124, 226-251. <https://doi.org/10.1016/j.eswa.2019.01.012>
- Jain, V., Saini, D., & Ahluwalia, A. (2019). Real-time autonomous trading system. *Journal of Statistics and Management Systems*, 22(2), 403-413. <https://doi.org/10.1080/09720510.2019.1582881>
- Laboissiere, L. A., Fernandes, R. A., & Lage, G. G. (2015). Maximum and minimum stock price forecasting of Brazilian power distribution companies based on artificial neural networks. *Applied Soft Computing*, 35, 66-74. <https://doi.org/10.1016/j.asoc.2015.06.005>
- Lo, A. W. (2004). The adaptive markets hypothesis. *The Journal of Portfolio Management*, 30(5), 15-29. <https://doi.org/10.3905/jpm.2004.442611>
- Nayak, R. K., Mishra, D., & Rath, A. K. (2015). A Naïve SVM-KNN based stock market trend reversal analysis for Indian benchmark indices. *Applied Soft Computing*, 35, 670-680. <https://doi.org/10.1016/j.asoc.2015.06.040>
- Nti, I. K., Adekoya, A. F., & Weyori, B. A. (2020). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, 53(4), 3007-3057. <https://doi.org/10.1007/s10462-019-09754-z>
- Panopoulou, E., & Souropanis, I. (2019). The role of technical indicators in exchange rate forecasting. *Journal of Empirical Finance*, 53, 197-221. <https://doi.org/10.1016/j.jempfin.2019.07.004>
- Santos, A. R. D. (2011). Metodologia científica: a construção do conhecimento. In *Metodologia científica: a construção do conhecimento* (1-139).
- ur Rahman, W. (2019). Validity of Random Walk Hypothesis and Technical Analysis: An Investigation of Pakistan Stock Market. *GMJACS*, 9(1), 21-21.
- Yahoo Finance. (2022). Recuperado em 01 de abril de 2022, de <https://finance.yahoo.com/>
- Srivastava, M. S., Joshi, M. N., & Gaur, M. (2014). A review paper on feature selection methodologies and their applications. *IJCSNS*, 14(5), 78.