

Box-Jenkins (ARIMA) e Redes Neurais Artificiais *Multilayer Perceptron* (RNA_MLP) na Previsão de Preços de Ações da BOVESPA

Box-Jenkins (ARIMA) and Multilayer Perceptron Artificial Neural Networks (MLP_ANN) Methods in Predicting BOVESPA Stock Prices

Celso Correia de Souza^{a*}; João Bosco Arbués Carneiro Junior^b; Raul Assef Castelão^a; Josimar Fernandes de França^a; Celso Fabricio Correia de Souza^d; Yuzo Iano^d; José Odálio dos Santos^c; Juliana Maria Correia de Souza Vieira^a

^aUniversidade Anhanguera Uniderp. MS, Brasil.

^bUniversidade Federal de Rondonópolis. MS, Brasil.

^cUniversidade Católica de São Paulo. São Paulo. Brasil.

^dUniversidade Estadual de Campinas. SP, Brasil.

*E-mail: celso.correia@anhanguera.com

Resumo

A previsão de preços de ações é um desafio crítico no mundo financeiro, pois envolve inúmeras variáveis e complexidades. Nesse contexto, este estudo abordou a problemática da escolha entre os métodos ARIMA e Redes Neurais Artificiais (RNA) para prever os preços de ações da Bolsa de Valores de São Paulo (BOVESPA), buscando identificar qual destes apresentou maior acurácia e menores erros de previsão. Foram coletados dados históricos semanais de preços das ações entre 2018 e 2022, juntamente com informações do Dólar, SELIC, Dow Jones, Ibovespa e IPCA. Os modelos ARIMA e RNA foram aplicados, com extensos testes e ajustes realizados para otimizá-los. Os resultados revelaram que o método ARIMA superou a RNA em termos de acurácia e erro de previsão. Essa superioridade pode estar relacionada à configuração específica do modelo de RNA, que não foi completamente explorada. O estudo destaca a importância de uma análise minuciosa do modelo de RNA, levando em consideração a complexidade dos dados e as particularidades do problema ao escolher entre os métodos de previsão. Além disso, enfatiza a necessidade de pesquisas contínuas para aprimorar a interoperabilidade dos modelos de RNA e a qualidade das previsões financeiras. A busca por modelos de previsão mais robustos e precisos é crucial em um ambiente financeiro dinâmico e altamente competitivo.

Palavras-chave: Mercado Financeiro. Previsão Financeira. Análise de Modelos.

Abstract

*Pr*AMBEVedicting stock prices is a critical challenge in the financial world due to its involvement with numerous variables and complexities. In this context, this study addresses the dilemma of choosing between Autoregressive Integrated Moving Average (ARIMA) and Artificial Neural Networks (ANN) methods to forecast São Paulo stock exchange (BOVESPA) stock prices, to identify which one demonstrates higher accuracy and lower prediction errors. Weekly historical stock price data from 2018 to 2022, along with information on the US Dollar, SELIC interest rate, Dow Jones, Ibovespa, and IPCA, were collected. Both ARIMA and ANN models were applied, with extensive testing and adjustments conducted for optimization. The findings revealed that the ARIMA method outperformed ANN in terms of accuracy and prediction error. This superiority may be linked to the specific configuration of the ANN model, which was not fully explored. This study underscores the importance of a thorough analysis of the ANN model, considering data complexity and problem intricacies when choosing between prediction methods. Furthermore, it emphasizes the need for ongoing research to enhance the interoperability of ANN models and the quality of financial predictions. The pursuit of more robust and accurate forecasting models is crucial in a dynamic and highly competitive financial environment.

Keywords: Financial Market. Financial Forecasting. Model Analysis.

1 Introdução

A previsão de preços das ações é uma área de grande interesse tanto para investidores quanto para pesquisadores, uma vez que pode fornecer informações valiosas para a tomada de decisões financeiras. Nesse contexto, a BOVESPA desempenha um papel significativo como um dos principais mercados financeiros do Brasil. Com o objetivo de desenvolver métodos mais precisos e confiáveis para a previsão de preços de ações na BOVESPA, diversas abordagens têm sido exploradas, entre elas, destacam-se o método ARIMA (*Autoregressive Integrated Moving Average*) e as Redes Neurais Artificiais (RNA) (Fantin; Hadad Junior, 2021).

Diversos modelos matemáticos que buscam prever com antecedência o desempenho do preço das ações na bolsa. Esses modelos são baseados em análises de experiências

passadas dos valores desses ativos financeiros (ações). Através do uso de algoritmos e técnicas estatísticas, esses modelos buscam identificar padrões e tendências que possam indicar movimentos futuros nos preços das ações. No entanto, é importante ressaltar que a previsão de preços de ações não é uma ciência exata e está sujeita a incertezas. Portanto, os investidores devem utilizar essas previsões como parte de uma análise mais abrangente e considerar outros fatores antes de tomar decisões de investimento (Setty; Nagaraj, 2019; Smith, 2018).

Campos *et al.* (2006) desenvolveram um modelo de previsão para os preços do frango inteiro resfriado no mercado atacadista do estado de São Paulo. Para isso, eles utilizaram a metodologia ARIMA (Média Móvel Integrada Autoregressiva) ou Box-Jenkins, que é adequada para previsões de séries temporais univariadas.

Diversos estudos têm explorado o uso de redes neurais artificiais na previsão de preços de ações. Chong *et al.* (2017) apresentaram uma abordagem abrangente, onde exploraram diferentes arquiteturas de redes neurais, como as redes neurais convolucionais e recorrentes. Os autores ressaltaram a importância do pré-processamento de dados, incluindo normalização e seleção de variáveis relevantes. Por meio de estudos de caso, eles demonstraram a eficácia das redes neurais na previsão do preço de ações, superando métodos tradicionais e capturando padrões complexos nos dados históricos.

Tsantekidis *et al.* (2017) propuseram o uso de redes neurais convolucionais (RNCs) para prever os preços das ações com base nas informações do livro de ofertas limitadas. Os autores destacaram a importância dessas informações e mostraram que as RNCs são capazes de capturar padrões espaciais nos dados. Os resultados experimentais indicaram que as RNCs superaram métodos tradicionais de previsão de preços de ações, evidenciando seu potencial como abordagem promissora para prever o comportamento do mercado.

Cao *et al.* (2019) propuseram um método de previsão do preço de ações baseado em redes neurais recorrentes do tipo LSTM (*Long Short-Term Memory*). A arquitetura LSTM foi utilizada para capturar a dependência de longo prazo presente nas séries temporais do mercado de ações. Os autores aplicaram o método em dados reais e avaliaram o desempenho do modelo utilizando métricas de erro médio absoluto (MAE) e erro quadrático médio (RMSE). Os resultados evidenciaram que o modelo LSTM supera outros métodos tradicionais de previsão do preço de ações, demonstrando sua eficácia na captura de padrões complexos e na realização de previsões precisas.

Fischer e Krauss (2018) exploraram o uso de redes neurais recorrentes LSTM para a previsão do mercado financeiro. Eles propuseram uma abordagem que combina a arquitetura LSTM com técnicas de pré-processamento de dados, como diferenciação logarítmica e normalização padrão. Os experimentos foram realizados em diferentes mercados financeiros e avaliados com base em métricas de desempenho, como retorno anualizado, índice de Sharpe e máximo rebaixamento. Os resultados mostraram que o modelo LSTM alcançou um desempenho superior em comparação com outros modelos tradicionais, fornecendo previsões mais precisas e consistentes.

A comparação entre esses dois métodos se mostra relevante, pois cada um possui características distintas e pode fornecer percepções complementares para a previsão de preços das ações. O método ARIMA é um modelo estatístico que leva em consideração componentes autorregressivas; de média móvel e de diferenciação para capturar padrões temporais e sazonalidades nos dados. Segundo Box *et al.* (2015), neste método é exigido que a série seja estacionária (séries estacionárias são conjuntos de dados temporais em

que as propriedades estatísticas, como média e variância, permanecem constantes ao longo do tempo, facilitando a análise e modelagem estatística).

Por outro lado, as RNA, especialmente as Redes Perceptron Multicamadas (MLP), são modelos computacionais inspirados no funcionamento do cérebro humano, capazes de aprender relações não lineares complexas presentes nos dados (Yuvaraj *et al.*, 2018).

A escolha do método de previsão adequado é de extrema importância, pois pode afetar diretamente a precisão das previsões e, conseqüentemente, a lucratividade dos investimentos. Portanto, a investigação comparativa entre ARIMA e RNA na previsão de preços das ações na BOVESPA tem o intuito de avaliar o desempenho e a eficácia de cada método, considerando a natureza dos dados e o contexto do mercado financeiro.

Nesse estudo, foram utilizados dados históricos das cotações semanais de quatro ações negociadas na BOVESPA e no período de 2018 a 2022. As variáveis consideradas incluíram informações como preço de fechamento das ações, volume de negociação, índices de mercado e variáveis econômicas relevantes representativas dos fundamentos de mercado.

A questão central de pesquisa foi: “Qual método, ARIMA ou RNA, apresenta melhor desempenho na previsão de preços das ações na BOVESPA?”. Desse modo, o objetivo principal deste estudo foi realizar uma análise comparativa detalhada dos dois métodos, considerando critérios como acurácia das previsões, robustez estatística e capacidade de capturar padrões complexos nos dados.

A análise comparativa entre os dois métodos busca auxiliar investidores e profissionais do mercado financeiro a tomar decisões precisas, com base em informações mais confiáveis sobre o comportamento dos preços das ações na BOVESPA.

2 Desenvolvimento

2.1 Metodologia

Neste estudo, foram adotadas duas metodologias para a previsão dos valores de ações: a primeira utilizando o Modelo de Box-Jenkins (ARIMA) e a segunda, utilizando Redes Neurais Artificiais Perceptron Multicamadas (RNA_MLP).

2.1.1 Previsão pelo Modelo de Box-Jenkins (ARIMA)

A abordagem pelo Modelo de Box-Jenkins (ARIMA) para realizar previsões é composta por três passos, conforme descrito por Análise Macro (2023) e Box *et al.* (2015):

I - Identificação de estacionariedade: verifica-se se a série é estacionária. Caso não seja, são realizadas diferenciações até que a série se torne estacionária. O número de diferenciações necessárias é denotado como “d” no modelo ARIMA.

II - Estimativa e teste: com o valor de “d” obtido no passo anterior, são determinados os valores adequados para os parâmetros “p” e “q” do modelo ARIMA. Isso é feito através

de análises gráficas da Função de Autocorrelação (FAC) e da Função de Autocorrelação Parcial (FACP) em relação ao atraso. A estimação dos parâmetros pode ser realizada utilizando mínimos quadrados ou outros métodos, porém, neste estudo não foi utilizado o método de estimativa não-linear. O modelo estimado deve se ajustar bem aos dados, com os resíduos do modelo se comportando como ruído branco. Caso contrário, é necessário refazer o processo para identificar outro modelo.

III - Previsão: o modelo obtido nos passos anteriores é utilizado para realizar previsões. É importante ressaltar que as previsões podem não ser precisas, uma vez que a modelagem matemática é complexa e idealizada para lidar com incertezas.

De acordo com Aires *et al.* (2018), um indicador comum de erro de previsão é a diferença entre o valor observado (Z_t) e o valor previsto (\hat{Z}_t) no tempo correspondente ($t = 1, \dots, n$). Existem várias ferramentas para avaliar a qualidade do ajuste e o desempenho de um modelo de previsão, incluindo o coeficiente de ajustamento R^2 , a raiz quadrada do erro médio quadrático (RMSE), o erro médio absoluto percentual (MAPE), o erro médio absoluto (MAE) e o BIC normalizado.

As equações (1) e (2) representam matematicamente os erros de ajustamentos do modelo.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(Z_{obs} - \hat{Z}_{pred})^2}{n}} \quad (1)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Z_{obs} - \hat{Z}_{pred}}{Z_{obs}} \right| \quad (2)$$

Onde n é o número de períodos da série temporal e $| \cdot |$ é o valor absoluto da variável

O BIC normalizado, também conhecido como Critério de Schwarz, é um critério de informação bayesiano que considera a densidade a posteriori dos parâmetros do modelo ajustado. O melhor modelo é aquele que apresenta o menor valor do BIC (Souza *et al.*, 2022).

A equação (3) representa matematicamente o grau de ajustamento do modelo pelo BIC normalizado.

$$BIC = T \times \ln(\sigma_{\epsilon, ML}^2) + N \times \ln(T) \quad (3)$$

Onde N é o número de parâmetros estimados, T é o número de observações da série temporal, $\ln(\cdot)$ representa o logaritmo natural de (\cdot) , e $\sigma_{\epsilon, ML}^2$ é a estimativa de máxima verossimilhança de ϵ . Quanto menores essas medidas, melhor será o desempenho do modelo de previsão, indicando um menor erro nas previsões.

A escolha das ações da (Ambev) - *Americas' Beverage Company* (ABEV3), Bradesco - Banco Brasileiro de Descontos (BBCD4), (Itaú-Unibanco) - Banco Itaú-Unibanco (ITUB4) e Petrobrás - Petróleo Brasileiro SA (PETR4) para análises e simulações justifica-se pelas suas posições consolidadas e significativas no mercado financeiro brasileiro, sendo ativos amplamente negociados na BOVESPA. Essas empresas representam setores estratégicos e são frequentemente observadas por investidores devido à sua

relevância na economia brasileira. O estudo utiliza variáveis independentes baseadas em dados históricos semanais dessas ações, coletados no período de 02 de janeiro de 2018 a 31 de dezembro de 2022, totalizando 255 observações. Esses dados incluem informações cruciais sobre os preços das ações, oferecendo uma visão abrangente do comportamento passado desses ativos.

A escolha do período de análise visa abranger um intervalo substancial, permitindo a identificação de padrões e tendências ao longo do tempo. Esse horizonte temporal mais longo também contribui para uma análise mais robusta, considerando diferentes condições de mercado e eventos econômicos. Quanto às variáveis dependentes, foram selecionadas as previsões dos preços dos ativos financeiros ABEV3, BBCD4, ITUB4 e PETR4, denominados, respectivamente de ações da Ambev, Banco Bradesco, Itaú-Unibanco e Petrobrás, para o período de 01 a 31 de janeiro de 2023.

Cada ativo financeiro passou por uma simulação específica, resultando em quatro cenários distintos que fornecem insights valiosos sobre as projeções de preços. Essa abordagem individualizada permite uma análise mais detalhada e focalizada em cada ativo, levando em consideração suas características únicas e os diversos fatores que podem influenciar seu desempenho. Em resumo, a escolha dessas ações consolidadas e a abordagem metodológica adotada visam proporcionar uma análise abrangente e significativa, contribuindo para uma compreensão mais profunda das tendências e comportamentos do mercado financeiro brasileiro.

2.1.2 Previsão pelo método das RNA_MLP

Como linguagem de programação foi usado o pacote estatístico *Statistical Package for the Social Sciences* (SPSS) para implementar a metodologia de previsão dos preços dos ativos financeiros em estudo, seguindo os seguintes passos (Strelhow; Câmara, 2011):

- Coleta de dados: coleta dos dados históricos semanais dos preços das ações que se desejava prever. Estes dados podem ser obtidos por meio de fontes públicas, como bancos de dados financeiros ou APIs (conjunto de regras e protocolos que permitem a interação e a comunicação entre diferentes sistemas de software no contexto financeiro);
- Pré-processamento dos dados: Os dados coletados precisaram ser pré-processados para garantir que estivessem em um formato adequado para a entrada na rede neural. Isso pode envolver a remoção de dados ausentes, normalização dos valores, entre outros;
- Divisão dos dados: Os dados históricos são divididos em conjuntos de treinamento, validação e teste. O conjunto de treinamento é usado para treinar a rede neural, o conjunto de validação para ajustar os hiperparâmetros do modelo e o conjunto de teste para avaliar o desempenho final da rede;
- Construção do modelo da RNA_MLP: Criada com várias camadas ocultas, utilizando uma biblioteca ou framework de aprendizado de máquina. Os parâmetros da rede, como

número de neurônios por camada e a taxa de aprendizado foram ajustados durante o treinamento;

- Treinamento da rede: O modelo de RNA_MLP foi treinado usando o conjunto de treinamento. Durante o treinamento, os pesos da rede foram ajustados iterativamente para minimizar uma função de perda, como o erro médio quadrático;
- Avaliação e ajuste: Após o treinamento, o desempenho do modelo foi avaliado usando o conjunto de validação. Foram analisadas métricas de desempenho, como o erro médio absoluto ou o coeficiente de determinação (R^2), para verificar a qualidade das previsões;
- Teste e previsão: Uma vez o modelo treinado e ajustado, ele foi aplicado ao conjunto de teste para realizar previsões de preços de ações. Foi avaliado o desempenho final do modelo com base nas métricas de avaliação escolhidas;
- Análise dos resultados: Os resultados das previsões foram analisados em relação aos preços reais das ações. Foram identificadas possíveis tendências e padrões, bem como eventuais limitações do modelo e;
- Aperfeiçoamento do modelo: Com base nas análises dos resultados, foram feitos ajustes e melhorias no modelo de RNA_MLP. Não houve necessidade de modificação da arquitetura da rede.

Para a comparação dos resultados dos dois modelos de previsão ARIMA e RNA_MLP, com os valores observados dos preços dos ativos financeiros foram calculados e comparados os erros entre as previsões desses dois modelos para os valores observados. Esses erros consistem em mensurar o distanciamento dos valores previstos pelos dois modelos em relação aos valores observados que, segundo Aires *et al.* (2018), seria a avaliação da qualidade do ajuste (acurácia), e do desempenho de um modelo de previsão, dado pelo Erro Percentual Médio Absoluto (MAPE). Quanto menor for essa medida, melhor será o desempenho do modelo de previsão tendo em vista que essa medida avalia o quanto o modelo está errando (Riahi *et al.*, 2013).

As variáveis dependentes são representadas pelos dados históricos dos valores das ações, coletados semanalmente, que incluem informações passadas sobre os preços das quatro ações, já denominadas de Ambev, Bradesco, Itaú-Unibanco e Petrobrás, negociados na BOVESPA. As variáveis independentes selecionadas representam a variabilidade do Dólar, Dow Jones, Ibovespa, IPCA e SELIC, todos os valores no período 02 de janeiro de 2018 a 31 de dezembro de 2022, num total de 255 observações. Essas variáveis foram usadas para treinar a RNA_MLP. Como variáveis dependentes as previsões dos preços das quatro ações Ambev, Bradesco, Itaú-Unibanco e Petrobrás na BOVESPA, no período 01 a 31 de janeiro de 2023.

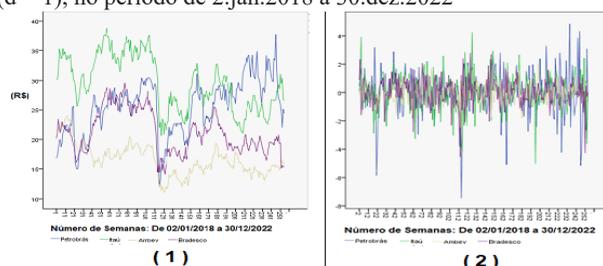
2.2 Discussão

Foram coletados os valores dos quatro ativos financeiros Ambev, Bradesco, Itaú-Unibanco e Petrobrás, com periodicidade semanal, no período de 02 de janeiro de 2018 a 30 de dezembro de 2022, totalizando 255 observações em cada série (BOVESPA, 2023), para realizar previsões desses

valores no período de 02 a 30 de janeiro de 2023, utilizando os modelos ARIMA e RNA_MLP.

Ao examinar os padrões nas quatro séries históricas em análise, constatou-se que elas não exibiam estacionariedades, indicando teoricamente a inviabilidade de realizarem previsões confiáveis utilizando o modelo ARIMA (p, d, q) nessas séries (Figura 1, parte 1).

Figura 1 - Representações gráficas das séries de valores das ações a Petrobrás, Itaú_unibasnc, Ambev e Bradesco: (1): Séries não estacionárias e (2): Séries estacionárias após uma diferenciação ($d = 1$), no período de 2.jan.2018 a 30.dez.2022

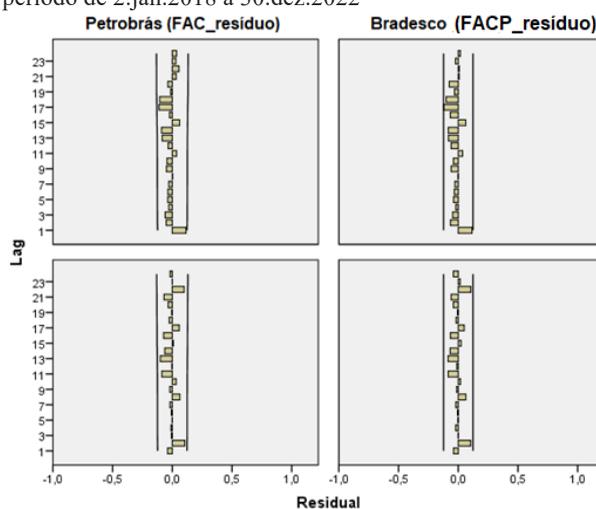


Fonte: dados da pesquisa.

Para viabilizar a aplicação do método ARIMA foi necessário realizar uma única diferenciação em cada uma das séries ($d = 1$) para torná-las estacionárias. Dessa forma, o parâmetro “ d ” dos quatro modelos ARIMA (p, d, q) foi estabelecido como $d = 1$, resultando inicialmente no modelo ARIMA ($p, 1, q$), com estacionariedade dos quatro modelos e médias em torno de 0 (zero) (Figura 1, parte 2).

Em seguida, para determinar os parâmetros (p) e (q), foram analisados os correlogramas das Funções de Autocorrelação (FAC) e das Funções de Autocorrelação Parcial (FACP) das séries já diferenciadas ($d = 1$), primeira para as ações Petrobrás e Bradesco (Figura 2).

Figura 2 - Gráficos dos correlogramas das funções de autocorrelação (FAC) e das funções de autocorrelação parcial (FACP) das séries de valores das ações da Petrobrás e do Bradesco, modelo ARIMA (0, 1, 0) para as duas séries, no período de 2.jan.2018 a 30.dez.2022



Fonte: dados da pesquisa.

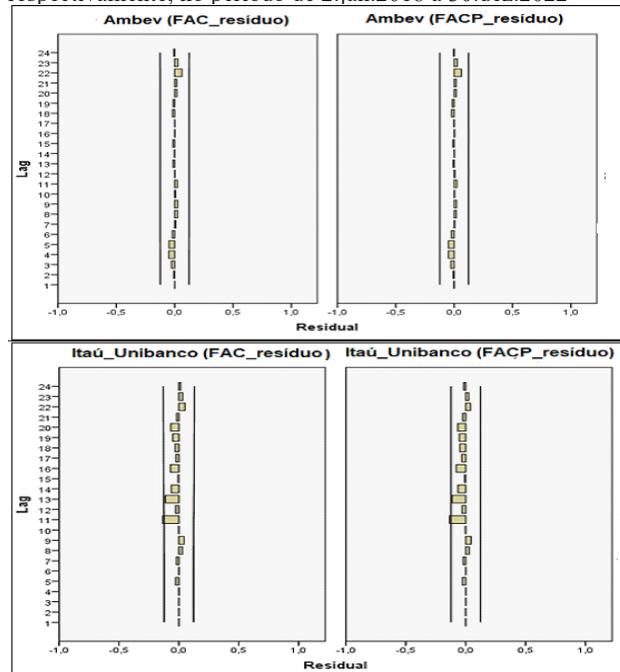
Observando a Figura 2 constatou-se que o modelo ARIMA (0, 1, 0), para as duas ações, Petrobrás e Bradesco,

tanto para FAC quanto para FACP, não apresentaram picos fora dos intervalos de confiança, com os parâmetros $p = q = 0$, resultando no modelo ARIMA (0, 1, 0) para ambas as ações, para realizar as previsões futuras.

Prosseguindo com as análises dos resultados das outras duas ações, Ambev e Itaú-Unibanco e realizar o diagnóstico de resíduos para essas duas ações, a fim de validar os modelos ARIMA obtidos. Inicialmente, a ação Ambev apresentou pico fora do intervalo de confiança no lag 14, indicando a utilização modelo ARIMA (14, 1, 14) para essa ação. De modo semelhante, a ação Itaú-Unibanco apresentou picos fora do intervalo de confiança nos lag 2 e lag 11, resultando em dois modelos, ARIMA (2, 1, 2) e ARIMA (11, 1, 11). Neste caso, optou-se pelo modelo ARIMA (2, 1, 2) por apresentar os menores erros de ajustes.

A Figura 3 apresenta os gráficos dos correlogramas das funções de autocorrelação (FAC) e das funções de autocorrelação parcial (FACP) dos modelos ARIMA (14, 1, 14) e ARIMA (2, 1, 2), respectivamente, das ações Ambev e Itaú-Unibanco.

Figura 3 - Gráficos dos correlogramas das funções de autocorrelação (FAC) e das funções de autocorrelação parcial (FACP) das séries de valores das ações da Ambev e Itaú-Unibanco, modelos ARIMA (14, 1, 14) e ARIMA (2, 1, 2), respectivamente, no período de 2.jan.2018 a 30.dez.2022



Fonte: dados da pesquisa.

Observando a Figura 3 constatou-se que os modelos ARIMA (14, 1, 14), da ação da Ambev e ARIMA (2, 1, 2) da ação do Bradesco, tanto para FAC quanto para FACP, não apresentaram picos fora dos intervalos de confiança, podendo os dois modelos serem usados para se fazer as previsões futuras.

Com base nos resultados obtidos, o próximo passo foi realizar os ajustes dos modelos e os testes de Ljung-Box dos

valores das ações utilizando cada um desses modelos, pois já foram realizados os diagnósticos dos resíduos para todos os modelos, indicando os correlogramas de FAC e FACP dos resíduos que as correlações entre os valores de cada variável (ação) em estudo não foram significativas, rejeitando assim, a hipótese nula de existência de correlações. Isso significa que os resíduos se assemelharam a ruídos brancos, confirmando-se que cada modelo é capaz de realizar uma boa estimação dos respectivos dados do problema em análise.

O cálculo dos ajustes e teste de Ljung-Box foram realizados com o modelo ARIMA (0, 1, 0) para as variáveis (ações) da Petrobrás e Bradesco (BBCD4), no período 02 de janeiro de 2018 a 31 de dezembro de 2022 podem ser encontrados na Quadro 1.

Quadro 1 - Estatísticas de ajustes dos modelos e teste de Ljung-Box para os valores das ações da Petrobrás e Bradesco, no período de 02/01/2018 a 31/12/2022

Modelo	Estatísticas de ajuste do modelo				Teste de Ljung-Box		
	R ²	RMSE	MAPE (%)	BIC Normalizado	Estatísticas	gl*	p**
Petrobrás	0,884	1,591	4,686	0,951	19,821	18	0,341
Bradesco	0,926	0,987	3,695	-0,005	13,225	18	0,778

*: gl = grau de liberdade; p** = nível de significância.

Fonte: dados da pesquisa.

No Quadro 1 observa-se que os resultados do modelo ARIMA (0, 1, 0), aplicado às ações da Petrobrás e do Bradesco, demonstraram bons ajustes, pois para a ação da Petrobrás, o coeficiente de determinação R² foi de 88,40%, indicando uma excelente variância explicada estacionária. Além disso, o valor do RMSE foi de 1,591, o BIC Normalizado foi de 0,951 e o MAPE foi de 4,69%, todos eles apontando para um ajuste satisfatório do modelo. No caso da ação do Bradesco, os resultados também foram favoráveis, com um coeficiente de determinação R² de 92,60%, RMSE de 0,987, BIC Normalizado de -0,005 e MAPE de 3,70%, indicando que o modelo também se ajusta bem aos dados dessa variável (ação).

Quanto às estatísticas do teste de Ljung-Box, cuja hipótese nula H_0 afirmava que o modelo adotado não apresenta falhas de ajuste, obteve-se um valor $p = 0,341$ para a ação Petrobrás e $p = 0,778$ para ação Bradesco. Ambos os valores são não significativos, superando o limite de 0,05, o que significa que se aceita a hipótese nula H_0 de que não há falhas de ajuste no modelo (Análise Macro, 2023). Portanto, concluiu-se que o modelo ARIMA (0, 1, 0) proposto é capaz de estimar os valores das ações da Petrobrás e do Bradesco no período de 02 a 30 de janeiro de 2023, precisamente nos dias 02, 09, 16, 23 e 30 de janeiro de 2023, abrangendo um total de cinco semanas após a última observação registrada dessas ações no banco de dados em 30 de dezembro de 2022.

Os resultados das previsões dos valores das ações da Petrobrás e Bradesco, pelo modelo ARIMA (0, 1,

0), estão apresentados o Quadro 2, juntamente com os limites superiores e inferiores de confiança (LSC e LIC, respectivamente).

Quadro 2 - Previsões, pelo modelo ARIMA(0, 1, 0), dos valores das ações da Petrobrás e do Bradesco na BOVESPA, bem como os limites superiores e inferiores de confiança LSC e LIC, respectivamente, nas cinco semanas de janeiro de 2023

Variável	Janeiro/ 2023	Dias				
		02	09	16	23	30
Petrobrás	Previsão (R\$)	24,53	24,56	24,59	24,62	24,65
	LSC* (R\$)	27,66	28,99	30,02	30,89	31,66
	LIC** (R\$)	21,40	20,13	19,16	18,35	17,64
Bradesco	Previsão (R\$)	15,35	15,33	15,31	15,29	15,27
	LSC (R\$)	17,29	18,08	18,68	19,18	19,62
	LIC (R\$)	13,41	12,58	11,95	11,41	10,93

*: Limite Superior de Confiança; **: Limite Inferior de Confiança.

Fonte: dados da pesquisa.

De modo semelhante analisou-se o modelo ARIMA (14, 1, 14) para os valores da ação da Ambev, no período 02 de janeiro de 2018 a 31 de dezembro de 2022, destacando que o modelo é capaz de realizar uma boa estimação para o conjunto de dados do problema, com $R^2 = 94,70\%$, indicando um bom ajuste do modelo, e o valor do erro MAPE = 3,695% indica um erro pequeno em relação aos dados do problema. Já quanto à estatística de Ljung-Box, em que a hipótese nula H_0 afirmava que: o modelo adotado não exibe falha de ajuste, apresentou valor de $p = 0,425 > 0,05$ (não significativo), aceitando-se a hipótese nula H_0 de que, realmente, não existem falhas de ajustes no modelo. Desse modo, o modelo é capaz de estimar os valores das ações da Ambev no período de 02 a 30 de janeiro de 2023, no total de cinco semanas após o último valor observado dessa ação no banco de dados, em 30 de dezembro de 2022 (Quadro 3).

Quadro 3 - Previsão do modelo ARIMA (14, 1, 14) dos valores da ação Ambev (ABEV3), de 02 a 30 de janeiro de 2023

Modelo	Janeiro/ 2023	Dias				
		02	09	16	23	30
Ambev	Previsão (R\$)	15,56	15,33	15,03	14,79	14,75
	LSC* (R\$)	16,82	17,02	17,03	17,04	17,22
	LIC** (R\$)	14,30	13,65	13,03	12,55	12,28

*: Limite Superior de Confiança; **: Limite Inferior de Confiança.

Fonte: dados da pesquisa.

Na análise dos modelos ARIMA (2, 1, 2) da variável (ação) Itaú-Unibanco, foram encontrados os indicadores de ajuste, como $R^2 = 0,926$ e MAPE = 3,272%, indicando que o modelo possui um bom ajuste e apresenta um erro pequeno em relação aos dados do problema. A estatística de Ljung-Box não indicou falhas de ajuste no modelo. Assim,

concluiu-se que o modelo ARIMA (2, 1, 2) é capaz de realizar uma boa estimação dos valores das ações do Itaú-Unibanco (Quadro 4).

Quadro 4 - Previsão do modelo ARIMA (2, 1, 2) dos valores da ação do Itaú-Unibanco, de 02 a 30 de janeiro de 2023

Ação	Janeiro/ 2023	Dias				
		02	09	16	23	30
Itaú - Unibanco	Previsão (R\$)	26,12	26,08	26,00	25,98	25,96
	LSC* (R\$)	28,63	29,52	30,40	31,15	31,82
	LIC** (R\$)	23,61	22,63	21,61	20,81	20,10

*: Limite Superior de Confiança; **: Limite Inferior de Confiança.

Fonte: dados da pesquisa.

Nessa etapa, após a aplicação do modelo ARIMA para previsão dos valores das ações da Petrobrás, Bradesco, Ambev e Itaú-Unibanco, o foco foi direcionado para a implementação das Redes Neurais Artificiais Multilayer Perceptron (RNA_MLP). Essa implementação visa explorar novas abordagens e avaliar as performances das RNA_MLP em comparação com os modelos ARIMA anteriormente utilizados.

Nas quatro simulações das RNA_MLP utilizou-se as variáveis independentes Ambev, Bradesco, Itaú-Unibanco, Petrobrás, Dólar, Dow_Jones Industrial Average (Dow Jones), Índice da Bolsa de Valores de São Paulo (Ibovespa), IPCA e taxa do Sistema Especial de Liquidação e de Custódia (SELIC), com todos os valores referidos ao período de 02 de janeiro de 2018 a 31 de dezembro de 2022, num total de 255 observações. As variáveis independentes foram usadas para treinar a rede. Como variáveis dependentes, foram tomadas as quatro previsões dos preços das ações da Ambev, Bradesco, Itaú-Unibanco e Petrobrás, nos dias 02, 09, 16, 23 e 30 de janeiro de 2023.

As variáveis da camada de entrada foram analisadas de forma padronizada, a quantidade de observações utilizadas para treinamento e para teste foram definidas e otimizadas pelo próprio *software* (SPSS), com a sugestão de que se usasse 70% do banco de dados para treinamento e 30% para teste. A função de ativação das camadas ocultas foi do tipo tangente hiperbólica. A camada de saída utilizou o método de reescalonamento padronizado, a função de ativação foi do tipo identidade.

O Quadro 5 apresenta os parâmetros das quatro redes RNA_MLP utilizadas nas previsões dos valores das quatro ações da Ambev, Bradesco, Itaú-Unibanco e Petrobrás, nos dias 02, 09, 16, 23 e 30 de janeiro de 2023.

Quadro 5 - Parâmetros das quatro RNA_MLP utilizadas nas previsões dos valores das quatro ações da Ambev, Bradesco, Itaú-Unibanco e Petrobrás, nos dias 02, 09, 16, 23 e 30 de janeiro de 2023

Parâmetros das Redes	Variáveis			
	Ambev	Bradesco	Itaú-Unibanco	Petrobrás
Amostras - Treinamento	169 Observações	182 Observações	174 Observações	178 Observações
Amostras - Teste	86 Observações	73 Observações	81 Observações	77 Observações
Dados Excluídos	5 Observações	6 Observações	6 Observações	5 Observações
Amostras - Total	260 Observações	261 Observações	261 Observações	260 Observações
Camadas de Entradas	5 Unidades (Dolar, Dow Jones, IBOVESP, IPCA e SELIC)	5 Unidades (Dolar, Dow Jones, IBOVESP, IPCA e SELIC)	5 Unidades (Dolar, Dow Jones, IBOVESP, IPCA e SELIC)	5 Unidades (Dolar, Dow Jones, IBOVESP, IPCA e SELIC)
Camadas Ocultas	1 Camada com 7 Unidades	1 Camada com 5 Unidades	1 Camada com 4 Unidades	1 Camada com 10 Unidades
Camadas de Saídas	1 Unidade – Valor da Ação			
Erros Relativos - Treinamento	8,7%	10,8%	11,7%	10,7%
Erros Relativos - Teste	9,9%	8,6%	8,9%	10,6%

Fonte: dados da pesquisa.

No Quadro 5 cabem algumas análises a respeito das configurações gerais das aplicações das RNA_MLP na previsão dos valores das ações da Ambev, Bradesco, Itaú-Unibanco e Petrobrás, relativamente às amostras, arquiteturas das redes neurais artificiais e os erros relativos.

Amostras:

- ✓ As amostras de treinamentos são os conjuntos de dados usados para treinar as redes neurais artificiais. Cada empresa tem um número específico de observações nas amostras de treinamentos (Ambev: 169, Bradesco: 182, Itaú: 174, Petrobrás: 178).
- ✓ As amostras de testes são os conjuntos de dados usados para avaliar os desempenhos das redes neurais artificiais após os treinamentos. Cada empresa tem um número específico de observações nas amostras de teste (Ambev: 86, Bradesco: 73, Itaú: 81, Petrobrás: 77).
- ✓ Dados excluídos representam observações removidas durante o processo, possivelmente devido a problemas ou redundâncias (Ambev: 5, Bradesco: 6, Itaú: 6, Petrobrás: 5).
- ✓ Amostra total é a soma da amostra de treinamento e de teste (Ambev: 260, Bradesco: 261, Itaú: 261, Petrobrás: 260).
- ✓ Arquitetura da Rede Neural:
- ✓ Camadas de Entradas: Todas as empresas têm uma camada de entrada com 5 unidades representando diferentes variáveis (Dolar, Dow Jones, IBOVESP, IPCA e SELIC).
- ✓ Camada Oculta: Cada empresa tem uma camada oculta com um número específico de unidades (Ambev: 7, Bradesco: 5, Itaú: 4, Petrobrás: 10).
- ✓ Camada de Saída: Todas as empresas têm uma camada de saída com 1 unidade representando o valor da ação.

Erros Relativos:

- ✓ Erro Relativo de Treinamento: Indica a precisão do modelo nos dados de treinamento. É o percentual de erro em relação aos valores reais (Ambev: 8,7%, Bradesco: 10,8%, Itaú: 11,7%, Petrobrás: 10,7%).
- ✓ Erro Relativo de Teste: Indica a precisão do modelo nos

dados de teste. É o percentual de erro em relação aos valores reais (Ambev: 9,9%, Bradesco: 8,6%, Itaú: 8,9%, Petrobrás: 10,6%).

Essas informações fornecem uma visão geral da configuração e desempenho das redes neurais artificiais para prever os valores das ações das empresas listadas na Bolsa de Valores de São Paulo.

Para as previsões das quatro ações em estudo utilizando RNA_MLP, diferentemente das previsões por meio dos modelos ARIMA, não necessitou a realização de testes estatísticos para validações de modelos, já que no método a previsão é gerada a partir da rede treinada com os dados, no período de 02 de janeiro de 2018 a 30 de dezembro de 2022, período anterior à previsão, mês de janeiro de 2023.

No Quadro 6 estão os valores das previsões dos valores das ações Petrobrás, Bradesco, Ambev e Itaú-Unibanco para os dias 02, 09, 16, 23 e 30 de janeiro de 2023, utilizando o modelo de RNA_MLP

Quadro 6 - Valores das previsões dos valores das ações da Ambev, Bradesco, Itaú-Unibanco e Petrobrás para os dias 02, 09, 16, 23 e 30 de janeiro de 2023, utilizando o modelo de RNA_MLP

Ação	Previsão	Dias de janeiro de 2023				
		02	09	16	23	30
Petrobrás	Prev (R\$)	25,13	26,83	26,52	27,45	28,09
Bradesco	Prev (R\$)	14,07	14,67	15,67	17,71	17,14
Ambev	Prev (R\$)	16,19	15,97	15,85	15,79	15,82
Itaú-Unibanco	Prev (R\$)	28,60	28,39	28,52	28,70	28,48

Fonte: dados da pesquisa.

Para estabelecer uma comparação entre os métodos ARIMA e RNA_MLP, tabela 6, realizou-se uma análise dos valores dessas ações previstos para os cinco períodos do mês de janeiro de 2023 pelos dois métodos em relação aos valores observados na BOVESPA nesses mesmos períodos. A fim de quantificar a precisão das previsões, calculou-se o erro MAPE

(Mean Absolute Percentage Error) para cada ação, em cada método, comparando os valores previstos com os valores observados.

Os resultados dessas comparações foram registrados na última linha da tabela 7, onde cada ação possui seu

respectivo erro MAPE para ambos os métodos. O erro MAPE é uma medida que expressa a diferença percentual absoluta média entre os valores previstos e os valores observados. Quanto menor o valor do MAPE, mais precisa é a previsão.

Quadro 7 - Previsões, pelos modelos Box-Jakins (ARIMA) e (RNA_MLP), dos valores das ações da Ambev, Bradesco, Itaú-Unibanco, Petrobrás na BOVESPA, bem como os limites superiores e inferiores de confiança LSC e LIC, respectivamente, os dias 02, 09, 16, 23 e 30 de janeiro de 2023

2023	Valores Observados				Valores Obtidos pelo ARIMA				Valores Obtidos pela RNA_MLP			
jan	PETR4	BBCD4	ABEV3	ITUB 4	PETR4	BBCD4	ABEV3	ITUB4	PETR4	BBCD4	ABEV3	ITUB4
2	23,74	14,30	23,74	25,99	24,53	15,35	15,56	26,12	25,13	14,07	16,19	25,17
9	24,57	13,82	24,57	26,33	24,56	15,33	15,33	26,08	26,83	14,67	15,97	25,18
16	26,37	15,14	26,37	24,33	24,59	15,31	15,03	26,00	26,52	15,67	15,85	25,34
23	25,62	15,15	25,62	23,68	24,62	15,29	14,79	25,98	27,45	17,71	15,79	25,65
29	24,79	15,06	24,79	25,19	24,65	15,27	14,75	25,96	28,09	17,14	15,82	25,50
MAPE (%)					2,92	4,34	2,37	4,22	7,22	8,39	4,32	4,24

Fonte: dados da pesquisa.

Essa análise comparativa permite avaliar o desempenho relativo dos métodos ARIMA e RNA_MLP na previsão de preços de ações. Os resultados da tabela 7 fornecem informações importantes para determinar qual método apresenta maior acurácia e confiabilidade na previsão desses ativos financeiros. A comparação entre os métodos ARIMA (*AutoRegressive Integrated Moving Average*) e RNA (Redes Neurais Artificiais) é de grande importância no campo da análise de séries temporais.

Ambos os métodos são amplamente utilizados para previsão e modelagem de dados temporais, cada um com suas vantagens e desvantagens. Ao realizar uma comparação entre ARIMA e RNA, pode-se observar que o método ARIMA apresentou menores erros do que os da RNA, o que pode ser surpreendente, pois, geralmente, as redes neurais artificiais são consideradas modelos mais flexíveis e poderosos para lidar com dados complexos e não-lineares. No entanto, a razão para essa ocorrência pode estar relacionada ao modelo específico de RNA aplicado, apesar de que a escolha ocorreu após exaustivas simulações.

As RNA são altamente configuráveis e flexíveis, mas essa característica também pode ser uma desvantagem, pois, ao se trabalhar com redes neurais é necessário realizar vários testes e ajustes para encontrar a arquitetura e os parâmetros mais adequados ao conjunto de dados em questão. A escolha inadequada da estrutura ou a configuração incorreta dos parâmetros pode levar a resultados menos precisos.

Por outro lado, o ARIMA é um modelo paramétrico que segue uma abordagem exigindo maiores requisitos matemáticos. A metodologia ARIMA é baseada em identificar padrões de autocorrelação e ajustar os coeficientes do modelo para minimizar o erro de previsão. Isso permite uma maior compreensão do comportamento dos dados e torna mais fácil a seleção do modelo mais adequado.

A simplicidade e a interpretabilidade do ARIMA podem ser fatores importantes em certos contextos. Se os dados seguirem um padrão mais linear e estacionário, o ARIMA pode

ser uma escolha mais eficaz do que as redes neurais artificiais, especialmente quando há limitações de dados disponíveis. No entanto, é importante ressaltar que a comparação entre ARIMA e RNA depende do conjunto de dados específico e do problema em questão. Em algumas situações, as redes neurais artificiais podem superar o ARIMA em termos de precisão e capacidade de capturar relações não-lineares.

Portanto, ao realizar uma comparação entre ARIMA e RNA e encontrar resultados inesperados, é crucial analisar cuidadosamente o modelo de RNA utilizado. É importante considerar a complexidade dos dados, a disponibilidade de informações históricas e as características do problema para determinar qual método é mais apropriado para uma determinada tarefa de previsão ou modelagem.

Embora as redes neurais tenham mostrado resultados promissores na previsão do preço de ações, existem desafios a serem superados. Um dos desafios é a complexidade e a não linearidade do mercado financeiro, que exigem abordagens mais sofisticadas. Além disso, a interpretabilidade dos modelos de redes neurais também é uma questão importante, já que muitos modelos de aprendizado são caixas-pretas. Pesquisas futuras devem explorar maneiras de melhorar a interpretabilidade dos modelos de redes neurais, bem como integrar outras fontes de informações, como notícias e mídias sociais, para melhorar a precisão das previsões.

3 Conclusão

O método ARIMA releva que quando comparado as Redes Neurais Artificiais (RNA) se destaca na previsão de preços de ações devido aos menores erros indicando que o resultado pode ser atribuído à configuração específica da RNA, exigindo ajustes meticulosos.

A escolha entre os métodos depende da natureza dos dados e do contexto financeiro. Apesar do potencial das RNA, desafios como a complexidade do mercado e a necessidade de interpretabilidade devem ser considerados.

O presente estudo serve como referência para a seleção do

método mais apropriado, destacando a importância da evolução contínua na pesquisa para aprimorar a interpretabilidade das RNA e incorporar informações adicionais, visando uma previsão mais precisa e informada.

Referências

AIRES, D.B.; DAMETTO, R.C.; CREPADI, A.F. Previsão de séries temporais financeiras utilizando redes neurais artificiais: um comparativo na crise de 2008. *GEPROS. Gestão da Produção, Oper. Sist.*, v.13, n.1, p.177-206, 2018, doi: 10.15675/gepros.v13i1.2016.

ANÁLISE MACRO – Econometria e Machine Learning. 2023. Modelo Arima e Metodologia Box-Jenkins. Disponível em: <https://analisemacro.com.br/econometria-e-machine-learning/modelos-arima-e-metodologia-box-jenkins/>. Acesso em: 25 nov. 2023.

BOVESPA – Bolsa de valores de São Paulo. Cotação de Ações. Disponível em: <https://br.financas.yahoo.com/quote/%5EBVSP/components?p=%5EBVSP&guccounter=1>. Acesso em 1 mar. 2023.

BOX, G.E.P.; JENKINS, G.M.; REINSEL, G.C. *Time series analysis: forecasting and control*. Wiley, 2015.

CAMPOS, P.A.C.; CLEMENTE, A.; CORDEIRO, A.A.L. Aplicação do modelo ARIMA para previsão do preço do frango inteiro resfriado no grande atacado do estado de São Paulo. In: CONGRESSO BRASILEIRO DE CUSTOS – Belo Horizonte, MG, Brasil, 2006.

CAO, Y. et al. Stock price prediction method based on LSTM neural network. *Journal of Physics: Conference Series*, 1168(4), 042092, 2019.

CHONG, E.; HAN, S.; LI, Y. Deep learning networks for stock market analysis and prediction: Methodology, data representations,

and case studies. *Expert Systems with Applications*, v.83, p.187-205, 2017.

FANTIN, C. O.; HADAD JUNIOR, E. Stock Price Forecast, with Multi Layer Perceptron Artificial Neural Networks. *IJSBAR*, v.60, n.5, p.62-77, 2021.

FISCHER, T.; KRAUSS, C. Deep learning with long short-term memory neural networks for financial market predictions. *Euro. J. Oper. Res.*, v.270, n.2, p.654-669, 2018.

RIahi, N.; Hosseini-Motlagh, S.; Teimourpour, B.A. Three-phase Hybrid Times Series Modeling Framework for Improved Hospital Inventory Demand Forecast. *Int. J. Hosp. Res.*, v.2, n.3, p.133-142, 2013.

SETTY, V.; NAGARAJ, U. Deep Learning for Stock Market Prediction: a review. *Int. J. Adv. Comp. Sci. Applic.*, v.10, n.1, 2019.

SMITH, J. Predicting Stock Prices Using Multilayer Perceptron Neural Networks. *J. Finance Invest. Anal.*, v.7, n.4, p.12-25, 2018.

SOUZA, C.C. et al. Previsão de produção de cana-de-açúcar e seus derivados, através de ARIMA, no período de 2020 a 2025, na macrorregião Centro-Sul do Brasil. *Res. Soc. Develop.*, v.11, n.4 2022. doi: <http://dx.doi.org/10.33448/rsd-v11i4.27048>.

STRELHOW, M.R.W.; CÂMARA, S.G. Descobrimos a estatística usando o SPSS. *Aletheia*, n.35/36, 2011.

TSANTEKIDIS, A. et al. Forecasting stock prices from the limit order book using convolutional neural networks. In *Proceedings of the European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, p.117-122, 2017.

YUVARAJ, D.; DEEPA, P.; GOVINDARAJAN, A. Artificial neural networks for stock market prediction: a systematic literature review. *Int. J. Intelligent Syst. Applic.*, v.10, n.9, p.1-13, 2018.