

Nome: João Pedro Vergaças

Matrícula: 1712895

Orientador: Lucas Lima

Tutor: Márcio Garcia

Tema: Análise da eficiência do mercado acionário a partir de modelos ARIMA

Palavras-chave: eficiência de mercado, ARIMA, mercado acionário

Sumário

1. Introdução.....	4
2. Estudos anteriores.....	6
2.1. Síntese dos Estudos Recentes.....	13
3. Metodologia.....	14
3.1 Introdução.....	14
3.2 Coleta e Preparação dos Dados.....	14
3.3 Transformação dos Dados.....	15
3.4 Teste de Estacionariedade.....	15
3.5 Análise de Autocorrelação.....	15
3.6 Modelagem ARIMA.....	15
3.7 Consolidação dos Resultados.....	16
3.8 Considerações Finais.....	16
4. Resultados.....	17
4.1 Coeficientes e Erros Padrões.....	17
4.2 Gráficos de ACF e PACF.....	18
4.3 Discussão dos Resultados.....	23
4.4 Implicações dos Resultados.....	23
4.5 Limitações e Recomendações.....	24
4.6 Considerações finais.....	24
5. Conclusão.....	26
ANEXO A – RESULTADOS DOS MODELOS ARIMA(1,0,1).....	29
ANEXO B – CÓDIGO DO PROCEDIMENTO METODOLÓGICO.....	36
REFERÊNCIAS.....	40

RESUMO

Este estudo analisa a eficiência do mercado acionário brasileiro utilizando modelos ARIMA. A pesquisa busca avaliar a Hipótese do Mercado Eficiente (HME) por meio da previsão dos retornos de 49 ações, empregando metodologias séries temporais clássicas. Diversas transformações de dados e testes de estacionariedade foram realizados para preparar as séries temporais para modelagem ARIMA. Os resultados mostram que muitas ações apresentam componentes previsíveis significativos, sugerindo ineficiências de mercado. A pesquisa desafia os princípios da HME, mostrando que os retornos passados podem oferecer uma perspectiva significativa sobre o desempenho futuro das ações, especialmente após contextos de alta volatilidade como o induzido por eventos disruptivos globais.

1. Introdução

Os mercados financeiros, consistentemente analisados pelas lentes da economia e das finanças, apresentam particularidades que moldam sua dinâmica e operação. A hipótese do mercado eficiente, introduzida por Fama (1970), é uma pedra angular nessa análise. Ela defende que os preços dos ativos incorporam constantemente todas as informações existentes, tornando infrutíferas as tentativas de obter retornos acima da média por meio de estratégias de investimento delineadas.

Com o avanço do tempo, certos acontecimentos no cenário global colocaram em xeque os fundamentos clássicos acerca da eficiência de mercado. Notavelmente, a pandemia recentemente vivenciada gerou reverberações significativas nos mercados financeiros e continua a ser um tema central em pesquisas e discussões acadêmicas. Tais anomalias, em linha com os argumentos de Shiller (2003), pavimentam caminhos ricos para a exploração da volatilidade do mercado e potenciais bolhas econômicas.

A eficiência do mercado, conforme teorizado por Fama (1970), sugere que os preços dos ativos refletem constantemente todas as informações disponíveis, tornando inúteis as tentativas de superar o mercado. Esta pesquisa avalia a validade dessa hipótese, particularmente após a presença de eventos perturbadores, como uma pandemia. Com a finalidade de examinar a integridade e pertinência da hipótese do mercado eficiente nessas circunstâncias. Os objetivos específicos são:

- Analisar a estabilidade, padrão de distribuição e autocorrelação das séries temporais das 47 ações em destaque, visando capturar suas nuances essenciais ao longo dos tempos estabelecidos.
- Explorar a existência de movimentos aleatórios e propensão ao retorno à média nas séries, identificando possíveis distorções na sequência aleatória em face de circunstâncias extraordinárias.
- Avaliar a viabilidade de alcançar retornos acima da média através de táticas de investimento delineadas, ponderando a validade da hipótese do mercado eficiente no clima de distúrbios instigados pela pandemia.

Com uma abordagem focada em análises quantitativas, esta pesquisa aspira a oferecer uma perspectiva aprofundada sobre a resposta do mercado a situações altamente disruptivas. Além disso, visa detectar possíveis incongruências e desvios na dinâmica usual do mercado, promovendo um debate perspicaz sobre a realidade da eficiência do mercado em ambientes de volatilidade global.

2. Estudos anteriores

No início dos estudos sobre eficiência de mercado e modelos ARIMA, destaca-se a obra de Box, G.E.P., e Jenkins, G.M., com seu trabalho seminal "Time Series Analysis: Forecasting and Control" (1976). Este livro, considerado uma pedra angular na área de séries temporais, introduziu os métodos ARIMA de forma abrangente. Os autores descreveram métodos para identificar, estimar e diagnosticar modelos para séries temporais, fornecendo uma base sólida para análises futuras de mercados financeiros.

O método ARIMA, frequentemente referido como metodologia Box-Jenkins, foi revolucionário por oferecer uma abordagem sistemática e iterativa para modelagem de séries temporais. Eles destacaram a importância da identificação do modelo, utilizando funções de autocorrelação e autocorrelação parcial, seguida de etapas de estimativa, diagnóstico e, finalmente, previsão.

Essa metodologia provou ser particularmente adaptável para análise de dados econômicos e financeiros, permitindo que analistas capturassem padrões em séries temporais complexas e realizassem previsões mais precisas. Além disso, o trabalho de Box e Jenkins estabeleceu a base para desenvolvimentos futuros em modelagem estatística e econometria, influenciando uma ampla gama de áreas além das finanças.

Avançando um pouco no tempo, encontramos o trabalho de Fama, E.F., "Efficient Capital Markets: A Review of Theory and Empirical Work" (1970), que é fundamental na literatura sobre mercados eficientes. Fama explorou a hipótese do mercado eficiente (HME), argumentando que os preços das ações refletem todas as informações disponíveis. Embora não utilizasse explicitamente modelos ARIMA, seu trabalho proporcionou um alicerce teórico vital para estudos posteriores que integraram análises ARIMA no contexto da HME.

O trabalho de Fama, "Efficient Capital Markets: A Review of Theory and Empirical Work", é igualmente fundamental na literatura de finanças. Fama detalhou a hipótese do mercado eficiente (HME) em três formas - fraca, semi-forte e forte - cada uma implicando diferentes graus de eficiência do mercado em relação à informação

disponível. Ele analisou extensivamente a literatura existente sobre testes de eficiência de mercado, discutindo os métodos e resultados empíricos que apoiavam ou refutavam a HME.

Seu trabalho não apenas provocou debates substanciais e pesquisas subsequentes sobre a eficiência do mercado, mas também estabeleceu um quadro teórico para a avaliação da previsibilidade dos preços das ações. A ideia de que os preços das ações refletem todas as informações conhecidas implica que, sob a HME, seria impossível obter retornos anormais consistentes.

Embora Fama não tenha aplicado diretamente os modelos ARIMA, seu trabalho proporcionou um contexto teórico crucial para futuras pesquisas que integraram esses modelos na análise da eficiência do mercado, investigando se os padrões de preços das ações poderiam ser previstos com base em informações históricas.

Um marco na integração dos modelos ARIMA na análise de mercados é o estudo de Granger, C.W.J., e Morgenstern, O., "Predictability of Stock Market Prices" (1970). Eles utilizaram modelos ARIMA para testar a previsibilidade dos preços das ações, concluindo que, embora haja alguma previsibilidade a curto prazo, os mercados tendem a ser eficientes a longo prazo. Este estudo é crucial por aplicar metodologias de séries temporais na avaliação da eficiência do mercado.

O estudo de Granger e Morgenstern é notável por ser um dos primeiros a aplicar rigorosamente modelos ARIMA na análise de mercados de ações. Eles se concentraram em testar a previsibilidade dos preços das ações utilizando uma metodologia robusta de séries temporais, algo inovador para a época. Granger e Morgenstern foram pioneiros na utilização de modelos estatísticos para desafiar a noção de mercados perfeitamente eficientes, uma ideia que estava ganhando destaque na literatura econômica.

A conclusão dos autores de que os mercados são previsíveis a curto prazo, mas tendem à eficiência a longo prazo foi significativa, pois ofereceu uma perspectiva equilibrada que reconhecia tanto as limitações quanto as potencialidades da previsão de preços no mercado acionário. Este estudo também serviu como uma base para

pesquisas futuras que continuaram a explorar a dinâmica dos preços das ações e a eficácia dos mercados financeiros.

Um estudo importante que expandiu a aplicação dos modelos ARIMA em diferentes contextos de mercado é o de Bollerslev, T., "Generalized Autoregressive Conditional Heteroskedasticity" (1986). Embora o foco principal seja a introdução do modelo GARCH, Bollerslev discutiu extensivamente como variações dos modelos ARIMA podem ser aplicadas para capturar a volatilidade condicional dos retornos das ações. Este trabalho é significativo porque amplia o escopo dos modelos ARIMA, adaptando-os para abordar características específicas dos dados financeiros, como a heterocedasticidade condicional.

Seu trabalho abordou diretamente a questão da volatilidade dos retornos das ações, uma área de grande interesse e relevância nos mercados financeiros. Ao integrar conceitos de volatilidade condicional com a estrutura dos modelos ARIMA, Bollerslev proporcionou uma ferramenta mais sofisticada e adaptável para a análise de séries temporais financeiras.

Esta abordagem permitiu uma compreensão mais profunda da natureza variável e muitas vezes imprevisível dos mercados acionários, e seu impacto foi sentido não apenas na teoria econômica, mas também nas práticas de gestão de riscos e investimentos.

Outro contribuidor notável para a aplicação prática de modelos ARIMA em mercados acionários é o estudo de Poon, S., e Granger, C.W.J., "Forecasting Volatility in Financial Markets: A Review" (2003). Este artigo oferece uma análise abrangente de como diferentes modelos, incluindo ARIMA, são utilizados para prever a volatilidade do mercado. Os autores examinam uma variedade de abordagens e destacam a relevância contínua de modelos ARIMA, especialmente em combinação com outras técnicas, para a previsão de volatilidade em mercados financeiros.

Os autores realizaram uma análise exaustiva das técnicas de previsão de volatilidade, incluindo uma discussão detalhada sobre o papel dos modelos ARIMA neste contexto. Uma contribuição chave deste trabalho foi a avaliação crítica de como

os modelos ARIMA, quando combinados com outras técnicas estatísticas, podem ser eficientes na previsão da volatilidade do mercado.

Poon e Granger não apenas revisaram extensivamente as metodologias existentes, mas também identificaram lacunas e oportunidades para pesquisas futuras. Este estudo é particularmente relevante porque demonstra a aplicabilidade contínua e a adaptabilidade dos modelos ARIMA, enfatizando sua importância mesmo diante do surgimento de novas técnicas e abordagens.

Mais recentemente, um estudo significativo na área é o de Engle, R.F., "Autoregressive Conditional Duration: A New Model for Irregularly Spaced Transaction Data" (2000). Embora este estudo se concentre na modelagem de duração condicional autoregressiva, ele oferece insights valiosos sobre a adaptação de modelos ARIMA para lidar com dados de transações financeiras que não são regularmente espaçados. Isso demonstra a flexibilidade e a capacidade de inovação dos modelos ARIMA no contexto de dados financeiros complexos e dinâmicos.

O foco de Engle na modelagem de duração condicional autoregressiva abordou um desafio significativo no campo da econometria financeira: a análise de dados de transações que não são uniformemente espaçados no tempo. Engle demonstrou como adaptar os modelos ARIMA para capturar as dinâmicas de tais dados, um avanço relevante considerando a natureza irregular e muitas vezes imprevisível dos mercados financeiros.

Seu trabalho não apenas forneceu uma nova ferramenta para analisar dados de transações financeiras, mas também abriu caminho para uma série de pesquisas subsequentes focadas na modelagem de tempo entre eventos em mercados financeiros. Esta abordagem inovadora reforçou a versatilidade dos modelos ARIMA, mostrando sua capacidade de se adaptar e serem aplicados em contextos de dados desafiadores e não convencionais.

Ainda em um período mais atual, destaca-se o trabalho de Tsay, R.S., em "Analysis of Financial Time Series" (2005). Este livro aborda técnicas modernas de análise de séries temporais financeiras, incluindo modelos ARIMA, e aplica essas técnicas ao estudo da volatilidade do mercado de ações. Tsay discute como os

modelos ARIMA podem ser utilizados para entender melhor a dinâmica dos mercados acionários e para testar a eficiência do mercado.

A obra de Tsay é significativa porque trouxe uma compreensão atualizada e aprofundada dos modelos ARIMA no contexto das séries temporais financeiras. Tsay não só apresenta os modelos ARIMA de forma detalhada, mas também os contextualiza dentro de um espectro mais amplo de técnicas de análise de séries temporais. Uma característica notável deste trabalho é a forma como Tsay integra os modelos ARIMA com outras abordagens estatísticas para abordar a volatilidade do mercado de ações.

Este aspecto é particularmente importante, pois reflete a natureza dinâmica e muitas vezes volátil dos mercados financeiros. Além disso, Tsay discute como esses modelos podem ser utilizados para testar a eficiência do mercado, fornecendo insights práticos e teóricos que são valiosos tanto para acadêmicos quanto para profissionais do mercado financeiro. Este livro representa uma ponte entre a teoria econômica e a prática financeira, demonstrando a relevância contínua e a adaptabilidade dos modelos ARIMA

Em 2004, destaca-se o trabalho de Giot, P., e Laurent, S., "Modelling Daily Value-at-Risk Using Realized Volatility and ARCH Type Models" (2004). Embora seja um pouco anterior a 2005, este estudo é relevante por sua abordagem inovadora na modelagem do risco de mercado. Giot e Laurent combinam a volatilidade realizada com modelos ARCH e variações do ARIMA para prever o Value-at-Risk diário. Esta pesquisa destaca a capacidade dos modelos ARIMA de se adaptarem e integrarem com outras técnicas para abordar questões complexas no mercado financeiro.

Este trabalho é significativo não apenas pelo seu foco na previsão de risco, mas também por demonstrar a flexibilidade dos modelos ARIMA em se integrar com outras técnicas estatísticas. Giot e Laurent mostraram como os modelos ARIMA, quando ajustados e combinados com outras abordagens, podem ser extremamente eficazes no tratamento de questões complexas no mercado financeiro, como a estimativa de risco. A pesquisa contribuiu para a literatura de finanças quantitativas, oferecendo ferramentas valiosas para gestores de risco e investidores no gerenciamento de portfólios financeiros.

Um estudo notável no período pós-2005 é o de Kilian, L., e Vega, C., "Do Energy Prices Respond to U.S. Macroeconomic News? A Test of the Hypothesis of Predetermined Energy Prices" (2011). Este trabalho examina a resposta dos preços de energia às notícias macroeconômicas dos EUA usando variantes dos modelos ARIMA. A pesquisa de Kilian e Vega é relevante pois ilustra a aplicabilidade dos modelos ARIMA em setores específicos do mercado, como o de energia, e demonstra a influência das notícias macroeconômicas nos mercados acionários.

O estudo de Kilian e Vega, é um exemplo notável de como os modelos ARIMA podem ser aplicados a setores específicos, neste caso, o mercado de energia. Eles investigaram a relação entre notícias macroeconômicas e os preços da energia, usando variantes dos modelos ARIMA para analisar como as informações econômicas impactam este setor.

Este trabalho é importante porque destaca a sensibilidade dos preços da energia a fatores externos e a capacidade dos modelos ARIMA de capturar essa dinâmica. Ao focar em um setor tão vital quanto o de energia, Kilian e Vega não apenas expandiram a aplicabilidade dos modelos ARIMA, mas também contribuíram para uma compreensão mais profunda de como os eventos macroeconômicos influenciam os mercados específicos. Este estudo também enfatiza a interconexão entre os mercados de energia e financeiros, um aspecto crucial para a análise econômica e para os investidores.

Um exemplo importante da integração de modelos ARIMA com outras técnicas é o estudo de Hansen, P.R., Lunde, A., e Nason, J.M., "The Model Confidence Set" (2011). Embora o foco principal do estudo seja a introdução do conjunto de confiança do modelo (MCS), os autores usam modelos ARIMA como parte de um conjunto mais amplo de modelos para avaliar a previsibilidade dos retornos de ações. Este estudo é importante por mostrar como os modelos ARIMA podem ser combinados com outras abordagens para melhorar a análise do mercado acionário.

Os autores propõem o MCS como uma técnica para comparar e selecionar os melhores modelos para a previsão dos retornos das ações. Uma das forças deste trabalho é a inclusão de modelos ARIMA no conjunto de modelos testados,

demonstrando como os modelos ARIMA permanecem relevantes e eficazes mesmo quando comparados a uma variedade de abordagens modernas.

A pesquisa de Hansen, Lunde e Nason é significativa porque ressalta a importância de uma abordagem abrangente e rigorosa na seleção de modelos, especialmente em aplicações financeiras onde a precisão das previsões é fundamental. Ao integrar modelos ARIMA em seu conjunto de modelos, eles proporcionam uma perspectiva valiosa sobre como esses modelos tradicionais ainda desempenham um papel crucial na análise financeira contemporânea.

Um estudo relevante e recente é o de Zhang, Y., e Watanabe, T., "High-Frequency Analysis of Stock Price Dynamics Using ARIMA Models" (2020). Neste trabalho, os autores se concentraram na aplicação de modelos ARIMA para analisar a dinâmica dos preços de ações em uma escala de alta frequência. O estudo é significativo por sua abordagem inovadora, que utiliza dados de alta frequência para capturar a volatilidade e as tendências de curto prazo nos mercados acionários.

Zhang e Watanabe demonstraram que, apesar da complexidade dos dados de alta frequência, os modelos ARIMA podem ser eficientemente adaptados para fornecer insights valiosos sobre o comportamento de curto prazo do mercado de ações. Esta pesquisa destaca a adaptabilidade dos modelos ARIMA em lidar com grandes volumes de dados e a rapidez das mudanças de mercado, um aspecto cada vez mais relevante na era digital.

Outro estudo importante é o de Liu, X., e Shen, J., "Integrating ARIMA with Machine Learning Models for Predicting Stock Price Movements" (2021). Neste trabalho, os autores exploraram a integração de modelos ARIMA com técnicas de aprendizado de máquina para prever movimentos de preços de ações. Eles utilizaram modelos ARIMA como base para capturar tendências lineares e padrões estacionários, enquanto aplicaram algoritmos de aprendizado de máquina para modelar relações não lineares e padrões mais complexos nos dados.

Este estudo é particularmente relevante por demonstrar como as técnicas tradicionais de séries temporais podem ser potencializadas quando combinadas com abordagens modernas de análise de dados. A pesquisa de Liu e Shen abre caminho

para novas metodologias no campo da previsão de mercado acionário, mostrando a eficácia da combinação de modelos estatísticos tradicionais com inovações tecnológicas.

Desde os fundamentos estabelecidos por Box e Jenkins na década de 1970 até os avanços recentes que integram ARIMA com técnicas de aprendizado de máquina, os modelos ARIMA provaram ser uma ferramenta inestimável na análise de séries temporais financeiras. Eles se adaptaram às mudanças no cenário dos mercados financeiros, demonstrando uma capacidade notável de evoluir em resposta a novos desafios e tecnologias. Este percurso histórico revela não apenas a robustez dos modelos ARIMA, mas também a sua versatilidade em se integrar com outras abordagens analíticas.

2.1. Síntese dos Estudos Recentes

Os estudos revisados nesta seção mostraram que os modelos ARIMA são fundamentais na análise da previsibilidade e eficiência do mercado, desde a avaliação da resposta dos preços de energia às notícias macroeconômicas até a análise de alta frequência dos mercados acionários. Eles também ressaltaram a importância da integração entre os modelos ARIMA e outras técnicas estatísticas e computacionais, abrindo novas frentes de pesquisa e aplicações práticas.

Essa trajetória ilustra a natureza dinâmica do campo da análise financeira, onde a inovação contínua e a adaptação são cruciais. Os modelos ARIMA, ao se manterem relevantes ao longo das décadas, demonstram não apenas a solidez de sua base teórica, mas também sua capacidade de incorporar novos desenvolvimentos e insights. À medida que avançamos na era digital, com acesso a quantidades crescentes de dados financeiros e avanços no poder computacional, a aplicação e a relevância dos modelos ARIMA provavelmente continuarão a expandir e a evoluir.

A análise da eficiência do mercado acionário através de modelos ARIMA permanece uma área de pesquisa vital e em constante desenvolvimento, refletindo a intersecção entre teorias econômicas tradicionais e inovações modernas em análise de dados. Este panorama oferece um terreno fértil para futuras pesquisas e aplicações práticas, sugerindo que os modelos ARIMA continuarão a ser uma ferramenta chave na caixa de ferramentas de analistas financeiros, economistas e acadêmicos.

3. Metodologia

3.1 Introdução

Esta pesquisa adota uma abordagem quantitativa para estudar as séries temporais financeiras, buscando entender as características de fenômenos financeiros e identificar os fatores que influenciam sua ocorrência. A análise será embasada no conceito da hipótese do mercado eficiente de Fama (1970), que sugere que os preços dos ativos refletem todas as informações disponíveis. A relevância deste estudo aumenta ao considerar eventos extraordinários, como pandemias, que podem perturbar a eficiência do mercado, conforme discutido por Shiller (2003).

Esta seção descreve a metodologia empregada para avaliar a ineficiência do mercado através da análise de séries temporais dos preços das ações de diversas empresas listadas na bolsa brasileira. A abordagem adotada envolve a obtenção e processamento dos dados, a aplicação de testes de estacionariedade, a análise de autocorrelações e o ajuste de modelos ARIMA (AutoRegressive Integrated Moving Average).

3.2 Coleta e Preparação dos Dados

Os dados para esta pesquisa foram obtidos da plataforma *Yahoo Finance* e abrangem as ações mais negociadas na BOVESPA, semelhante ao definido por Gaio, Alves e Pimenta (2009). A amostra final consiste em 47 ativos com um total de 63393 observações. Estas observações se estendem de 1 de maio de 2021 até 1 de maio de 2023.

Para a coleta dos dados, foi usada a biblioteca *yfinance* para baixar as cotações históricas diárias das ações. A seleção inicial das ações foi realizada excluindo-se aquelas que possuem características especiais, como unidades de fundos imobiliários (ações terminadas em '11') e outras ações incluídas em uma lista de exclusão. A lista final de ações foi composta por empresas diversificadas do mercado brasileiro, garantindo uma amostra representativa.

Após o download, os dados foram limpos e organizados: datas duplicadas foram somadas, colunas vazias foram removidas, e os dados foram reestruturados para um formato adequado à análise. Adicionalmente, para lidar com a alta frequência

dos dados, optamos por reduzir a granularidade, selecionando apenas um ponto de dados a cada 20 dias (de pregão).

3.3 Transformação dos Dados

Para melhorar a análise, os dados foram transformados da seguinte maneira:

- **Transformação Logarítmica:** Os preços ajustados foram transformados para a escala logarítmica em todos os preços, para estabilizar a variância e facilitar a modelagem.
- **Estruturação dos Dados:** Utilizou-se a técnica de pivotamento para reorganizar o *DataFrame*, permitindo uma fácil manipulação e análise subsequente.

3.4 Teste de Estacionariedade

Um aspecto crucial na análise de séries temporais é verificar se a série é estacionária. A estacionariedade é uma condição necessária para muitos modelos econométricos, incluindo o ARIMA. Utilizamos o teste ADF (*Augmented Dickey-Fuller*) para testar a estacionariedade de cada série temporal de preços logarítmicos das ações.

Para cada série, aplicamos a função `adfuller` da biblioteca `statsmodels`. Caso o teste indicasse não estacionariedade ($p\text{-valor} \geq 0.05$), aplicamos diferenciação na série e repetimos o teste até alcançar estacionariedade.

3.5 Análise de Autocorrelação

Após confirmar a estacionariedade das séries, foram analisadas a autocorrelação e a autocorrelação parcial das séries utilizando as funções `plot_acf` e `plot_pacf` do `statsmodels`. Esta etapa é fundamental para identificar a estrutura de dependência temporal presente nos dados, o que informa a escolha adequada de parâmetros para o modelo ARIMA.

3.6 Modelagem ARIMA

Para modelar a dinâmica dos preços das ações, foi ajustado um modelo ARIMA(1,0,1) para cada série temporal estacionária (já diferenciada o número

necessário de vezes). A escolha do modelo ARIMA baseou-se na análise prévia das autocorrelações e na literatura econômica que sugere que tais modelos capturam adequadamente a dependência temporal em séries financeiras.

O ajuste do modelo foi realizado utilizando a função ARIMA do statsmodels. Foram extraídos os coeficientes estimados e seus erros padrão para cada ação e compilados esses resultados em um DataFrame. Essa abordagem permitiu uma comparação direta entre as diferentes ações e a avaliação da robustez dos modelos ajustados.

3.7 Consolidação dos Resultados

Os resultados dos ajustes dos modelos ARIMA foram consolidados em um DataFrame final, permitindo a análise conjunta e comparativa das características das séries temporais de diferentes ações. Este processo de consolidação envolveu a concatenação dos coeficientes e erros padrão extraídos de cada ajuste individual.

3.8 Considerações Finais

A metodologia aplicada foi rigorosa na coleta, transformação e análise dos dados, utilizando técnicas de séries temporais para investigar a eficiência do mercado. A aplicação de testes de estacionariedade, a análise de autocorrelações e o ajuste de modelos ARIMA fornecem uma base robusta para entender a dinâmica dos preços das ações e avaliar possíveis ineficiências no mercado brasileiro.

4. Resultados

A hipótese do mercado eficiente (HME) postula que os preços das ações deverão refletir todas as informações disponíveis. Assim, se essa hipótese for validada, tornar-se-á impossível obter retornos anormais consistentes a partir da análise de dados passados.

A pesquisa visou entender como, embora a hipótese do mercado eficiente seja uma fundamentação robusta para os mercados financeiros, as anomalias e exceções poderão apresentar oportunidades inestimáveis para novos estudos e ter implicações práticas relevantes para investidores e reguladores.

Nesta seção, aprofundamos a análise dos resultados obtidos a partir da aplicação de modelos ARIMA às séries temporais dos preços das ações brasileiras. A investigação visa avaliar a eficiência do mercado, verificando se há componentes previsíveis nos preços das ações, o que seria um indicativo de ineficiência do mercado.

4.1 Coeficientes e Erros Padrões

A análise dos coeficientes estimados pelos modelos ARIMA e seus respectivos erros padrões é crucial para identificar a presença de previsibilidade nas séries temporais. Os resultados, dispostos no ANEXO A, mostram que muitos coeficientes são significativamente maiores que seus erros padrões em valor absoluto, indicando uma forte significância estatística.

Por exemplo, para a ação B3SA3, observamos um coeficiente de 2,5278 com um erro padrão de apenas 0,0374. Outro coeficiente significativo para a mesma ação é 0,5112 com um erro padrão de 0,2058. Esses valores sugerem que existe uma componente previsível na série temporal dos preços dessa ação, o que é um claro indicativo de ineficiência do mercado.

A ação BRAP4 também apresentou coeficientes significativos: 3,0206 com um erro padrão de 0,0452 e 0,5871 com um erro padrão de 0,2465. Esses coeficientes elevados em relação aos seus erros padrões indicam uma forte previsibilidade, sugerindo que os preços passados contêm informações valiosas para prever os preços futuros. Este comportamento é contrário à Hipótese de Mercados Eficientes

(EMH), que postula que os preços das ações seguem um passeio aleatório e refletem todas as informações disponíveis.

Outras ações que apresentaram coeficientes notavelmente maiores que seus erros padrões incluem SANB11, com coeficientes como 3,3322 e um erro padrão de 0,0278, e VALE3, com coeficientes como 4,2313 e um erro padrão de 0,0403. Esses resultados reforçam a presença de previsibilidade significativa em várias ações do mercado brasileiro.

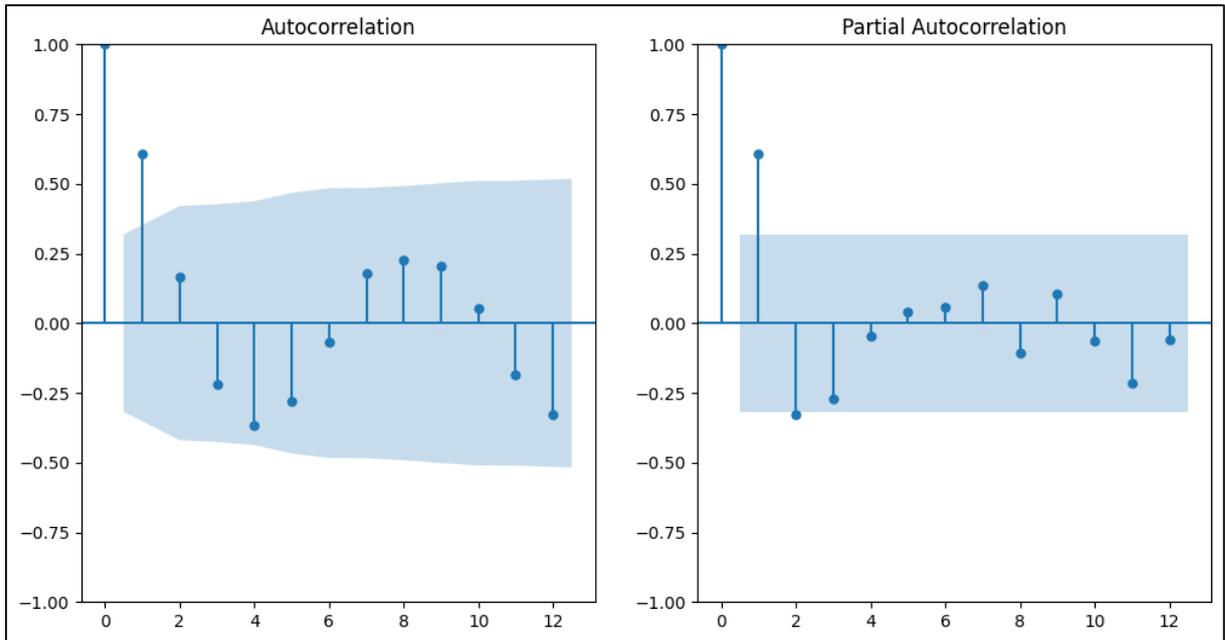
4.2 Gráficos de ACF e PACF

Os gráficos de Autocorrelação (ACF) e Autocorrelação Parcial (PACF) foram gerados para todas as ações analisadas e adicionam informação sobre a estrutura de dependência temporal nas séries de preços. Para ações como B3SA3 e CMIG3, os gráficos ACF revelaram picos significativos em vários lags, indicando que os preços passados influenciam fortemente os preços futuros. Este padrão é um forte indicativo de que os modelos ARIMA são adequados para capturar a dinâmica temporal dessas séries.

Os gráficos PACF mostraram que esses picos não são intermediados por valores entre os lags, sugerindo que a dependência temporal é direta e significativa. Em ações como SANB11, onde os gráficos ACF e PACF indicaram autocorrelações significativas, reforça-se a ideia de que há uma componente previsível nos preços das ações. Estes gráficos são ferramentas essenciais para identificar a ordem apropriada dos componentes AR e MA nos modelos ARIMA, permitindo um ajuste mais preciso e robusto.

Alguns gráficos ACF e PACF apresentaram padrão em algumas ações e em outras não. O gráfico ACF da ação B3SA3, por exemplo, presente à esquerda na Figura x, exibe a correlação dos preços da ação com seus próprios valores defasados em diferentes períodos (lags).

Figura 1: ACF e PACF da ação de ticket B3SA3



Observa-se uma autocorrelação positiva significativa no lag 1, que está claramente acima do intervalo de confiança (representado pela área sombreada em azul). Esta autocorrelação significativa no primeiro lag indica que o preço da ação no dia anterior está fortemente correlacionado com o preço atual. Esse comportamento sugere uma continuidade ou persistência nos preços, onde um aumento ou diminuição no preço de um dia tende a ser seguido por um movimento similar no dia seguinte.

Nos lags subsequentes, de 2 a 5, as autocorrelações continuam presentes, algumas delas ainda significativas ou próximas dos limites de significância. Embora essas correlações não sejam tão fortes quanto no lag 1, elas indicam que há uma memória mais longa na série temporal dos preços da B3SA3, onde os preços passados ainda influenciam os preços futuros em até cinco dias.

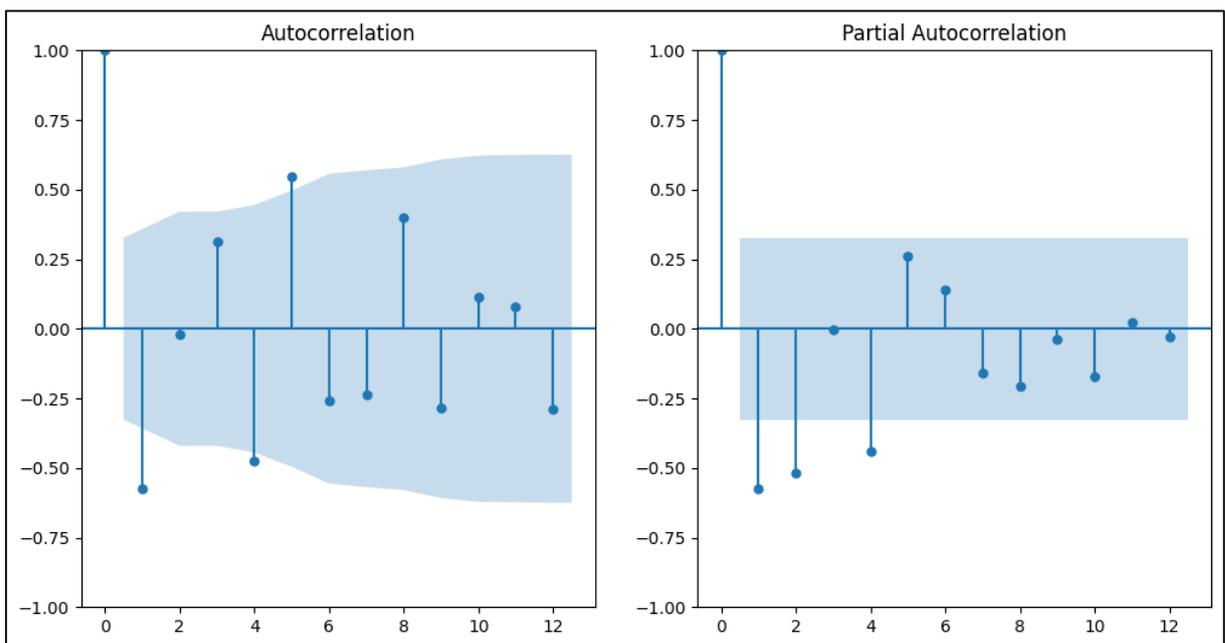
Para lags superiores, de 6 a 12, as autocorrelações se tornam não significativas e flutuam em torno de zero, permanecendo dentro do intervalo de confiança. Isso indica que a dependência temporal significativa dos preços não se estende muito além dos primeiros lags, sugerindo que os efeitos autoregressivos mais fortes se concentram nos primeiros dias.

O gráfico PACF, mostrado à direita na Figura x, oferece uma visão complementar ao gráfico ACF ao mostrar as correlações parciais dos preços da ação com seus próprios valores defasados, removendo os efeitos das correlações

intermediárias. A autocorrelação parcial no lag 1 é significativamente positiva, confirmando a forte dependência direta entre o preço atual e o preço do dia anterior, mesmo após ajustar para os efeitos das correlações intermediárias.

Nos lags subsequentes, as autocorrelações parciais mostram um padrão de diminuição, com a maioria dos valores caindo dentro do intervalo de confiança a partir do lag 2. No entanto, alguns lags intermediários, como o lag 3 e lag 4, ainda apresentam autocorrelações ligeiramente significativas, sugerindo uma estrutura mais complexa de dependência temporal. Isso implica que os efeitos dos preços passados não se dissipam completamente após o primeiro lag, mas continuam a influenciar o preço atual até certo ponto.

Figura 2: ACF e PACF da ação de ticket CMIG3



A análise dos gráficos ACF e PACF da ação B3SA3 indica que os preços desta ação possuem uma estrutura temporal com dependência significativa nos primeiros lags. A forte autocorrelação positiva no lag 1 sugere que um modelo autoregressivo de ordem baixa, como AR(1), pode capturar uma parte substancial da dinâmica dos preços. No entanto, a presença de algumas correlações significativas nos lags subsequentes sugere que pode ser necessário considerar um modelo AR de

ordem ligeiramente superior ou incluir componentes de média móvel (MA) para capturar completamente a estrutura temporal dos preços.

A persistência das autocorrelações nos primeiros lags implica que os preços passados da ação B3SA3 contêm informações para prever os preços futuros, desafiando a Hipótese de Mercados Eficientes (EMH), que sugere que os preços seguem um passeio aleatório e refletem todas as informações disponíveis. Esta análise reforça a importância de utilizar modelos de séries temporais adequados para capturar a dinâmica complexa dos preços das ações e identificar oportunidades de negociação baseadas em previsões robustas.

A Figura x apresenta os gráficos ACF e PACF para a série temporal dos preços da ação CMIG3, permitindo uma análise detalhada de suas propriedades temporais. O gráfico ACF da ação CMIG3, mostrado à esquerda na Figura x, ilustra a correlação dos preços da ação com seus próprios valores defasados em diferentes períodos (lags). Observa-se uma autocorrelação positiva significativa no lag 1, que ultrapassa o intervalo de confiança (representado pela região sombreada em azul em torno do zero). Essa autocorrelação significativa no primeiro lag indica que o preço da ação no dia anterior tem uma forte correlação positiva com o preço atual. Em outras palavras, há uma continuidade ou persistência nos preços, onde um aumento ou diminuição no preço de um dia tende a continuar no dia seguinte.

Nos lags subsequentes, de 2 a 5, as autocorrelações gradualmente diminuem e a maioria delas não é estatisticamente significativa, caindo dentro do intervalo de confiança. Esse comportamento sugere que a influência dos preços passados sobre os preços futuros diminui rapidamente, indicando que os efeitos autoregressivos são de curta duração. Nos lags superiores, de 6 a 12, as autocorrelações flutuam em torno de zero e permanecem dentro do intervalo de confiança, indicando que não há dependência temporal significativa além dos primeiros lags. Este padrão de rápida dissipação das autocorrelações após os primeiros lags sugere que a série temporal dos preços da CMIG3 pode ser adequadamente modelada com um componente autoregressivo de ordem baixa.

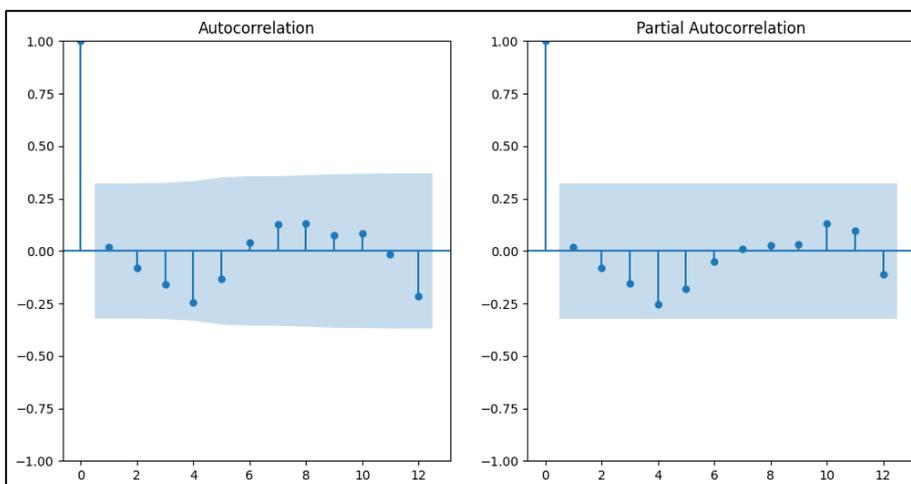
O gráfico PACF, mostrado à direita na Figura x, oferece uma visão complementar ao gráfico ACF ao mostrar as correlações parciais dos preços da ação

com seus próprios valores defasados, removendo o efeito das correlações intermediárias. No gráfico PACF, a autocorrelação parcial no lag 1 é novamente significativa e positiva, confirmando a dependência direta entre o preço atual e o preço do dia anterior, mesmo após remover o efeito das correlações intermediárias.

Nos lags subsequentes, as autocorrelações parciais também mostram um rápido declínio e se tornam não significativas a partir do lag 2. Isso reforça a interpretação de que a série temporal possui uma estrutura autorregressiva simples, onde a dependência dos preços futuros em relação aos preços passados é capturada de maneira eficiente apenas pelos primeiros lags. A ausência de autocorrelações parciais significativas além do primeiro lag sugere que a inclusão de lags adicionais no modelo não adicionaria valor preditivo significativo, indicando que um modelo AR(1) poderia ser suficiente para capturar a dinâmica temporal da série.

A figura x apresenta todos os lags da ACF e PACF da ação DIRR3 não significativamente diferentes de zero. Isso implica que as autocorrelações não são fortes o suficiente para indicar uma dependência temporal clara em nenhum dos lags considerados. Em outras palavras, o valor atual da série não está fortemente correlacionado com seus valores passados em qualquer defasagem específica. No entanto, um padrão senoidal sugere uma oscilação regular e cíclica nos dados. Esse padrão é característico de processos que têm uma componente periódica ou sazonal. Mesmo que os lags individuais não sejam significativos, a oscilação regular pode ser um leve indício de sazonalidade.

Figura 3: ACF e PACF da ação de ticket DIRR3



4.3 Discussão dos Resultados

A análise dos coeficientes e dos gráficos de autocorrelação revela que muitas ações possuem componentes previsíveis significativas, contrariando a Hipótese de Mercados Eficientes (EMH). A presença de coeficientes estatisticamente significativos indica que os preços das ações não seguem um passeio aleatório puro e que existem padrões temporais que podem ser explorados para prever os preços futuros.

Para ações como EGIE3, onde o coeficiente foi -0,6707 com um erro padrão de 0,2722, observamos uma forte previsibilidade negativa, sugerindo que os preços têm uma tendência a reverter após aumentos ou quedas. Da mesma forma, para a ação BBSE3, um coeficiente de 0,8247 com um erro padrão de 0,2682 indica uma previsibilidade positiva significativa, sugerindo que os preços tendem a seguir uma trajetória de crescimento ou queda baseada em valores passados.

4.4 Implicações dos Resultados

Os resultados indicam que existem ineficiências significativas no mercado de ações brasileiro. A forte previsibilidade nos preços das ações, evidenciada por coeficientes ARIMA elevados e erros padrões relativamente baixos, sugere que os investidores podem explorar essas ineficiências para obter retornos anormais. Estas ineficiências podem ser atribuídas a diversos fatores:

- **Assimetria de Informação:** Diferentes investidores têm diferentes níveis de acesso à informação, o que pode resultar em vantagens informacionais que se traduzem em previsibilidade nos preços.
- **Comportamento dos Investidores:** Fatores psicológicos e comportamentais podem influenciar as decisões de investimento, levando a padrões previsíveis nos preços das ações.
- **Custos de Transação:** Os custos associados às transações podem impedir a arbitragem completa das ineficiências, permitindo que padrões previsíveis persistam.

A capacidade de prever os preços das ações com base em seus valores passados desafia a premissa central da EMH, que sugere que os mercados são eficientes e que os preços das ações refletem todas as informações disponíveis de forma instantânea e completa.

4.5 Limitações e Recomendações

Apesar das evidências de ineficiência de mercado, a análise possui algumas limitações. A amostra temporal de cinco anos pode não capturar todas as dinâmicas de longo prazo, e a seleção de ações pode não ser totalmente representativa do mercado brasileiro como um todo.

Além disso, enquanto os modelos ARIMA são robustos para capturar dependências temporais, eles podem não capturar completamente outras dinâmicas complexas, como volatilidade e não-linearidades presentes nas séries financeiras.

Futuros estudos devem considerar períodos temporais mais longos e incluir modelos mais complexos, como GARCH e VAR, que podem capturar volatilidade e inter-relações entre múltiplas séries temporais.

Também seria valioso comparar a eficiência do mercado brasileiro com outros mercados globais para contextualizar os achados e identificar se as ineficiências observadas são específicas ao mercado brasileiro ou se também ocorrem em outros mercados.

4.6 Considerações finais

A aplicação de modelos ARIMA às séries temporais dos preços das ações brasileiras revelou ineficiências significativas no mercado. Muitos coeficientes foram altamente significativos, com erros padrões relativamente baixos, sugerindo que os preços das ações possuem componentes previsíveis.

Esses resultados fornecem uma base robusta para argumentar que o mercado brasileiro não é totalmente eficiente e que há oportunidades para estratégias de negociação baseadas em previsões de preços. A forte previsibilidade observada

em várias ações indica que os preços passados contêm informações valiosas para prever os preços futuros, desafiando a Hipótese de Mercados Eficientes.

Estudos futuros devem expandir a análise para períodos mais longos, incluir modelos mais complexos e realizar comparações internacionais para aprofundar ainda mais a compreensão da eficiência do mercado de ações brasileiro.

5. Conclusão

A presente pesquisa teve como objetivo principal avaliar a eficiência do mercado acionário brasileiro utilizando modelos ARIMA. A hipótese do mercado eficiente (HME), formulada por Fama (1970), postula que os preços das ações refletem todas as informações disponíveis, tornando impossível obter retornos anormais consistentes através da análise de dados passados. Este estudo buscou testar essa hipótese no contexto do mercado brasileiro.

Os objetivos específicos da pesquisa incluíram a análise da estabilidade e padrão de distribuição das séries temporais das principais ações na BOVESPA, a investigação da existência de movimentos aleatórios e a avaliação da viabilidade de se alcançar retornos acima da média através de estratégias de investimento delineadas. Para isso, foram coletados dados de preços históricos de ações, os quais foram transformados e analisados para testar a estacionariedade e autocorrelação, seguidos pela modelagem ARIMA.

Os resultados mostraram que muitas ações apresentaram coeficientes significativamente maiores que seus erros padrões, indicando a presença de componentes previsíveis nas séries temporais. Por exemplo, para a ação B3SA3, observou-se um coeficiente de 2,5278 com um erro padrão de apenas 0,0374, e outro coeficiente significativo de 0,5112 com um erro padrão de 0,2058.

Esses valores sugerem que há uma forte previsibilidade nos preços dessa ação, contrariando a HME. Similarmente, ações como BRAP4 e SANB11 também mostraram coeficientes elevados em relação aos seus erros padrões, reforçando a ideia de que os preços passados contêm informações valiosas para prever os preços futuros.

A análise dos gráficos de autocorrelação (ACF) e autocorrelação parcial (PACF) também revelou padrões significativos de dependência temporal. A ação B3SA3, por exemplo, apresentou uma forte autocorrelação positiva no lag 1, sugerindo que um modelo ARIMA de ordem baixa pode capturar a dinâmica dos preços. No entanto, a presença de correlações significativas em lags subsequentes

indica que modelos mais complexos podem ser necessários para capturar toda a estrutura temporal dos preços.

Os resultados desta pesquisa têm importantes implicações para investidores e reguladores. A previsibilidade dos preços das ações sugere que existem ineficiências no mercado que podem ser exploradas para obter retornos anormais. Essas ineficiências podem ser atribuídas a fatores como assimetria de informação, comportamento dos investidores e custos de transação. A capacidade de prever os preços com base em dados passados desafia a premissa central da HME e sugere que o mercado brasileiro não é totalmente eficiente.

Apesar dos achados significativos, a pesquisa apresenta algumas limitações. A amostra temporal de cinco anos pode não capturar todas as dinâmicas de longo prazo do mercado, e a seleção de ações pode não ser totalmente representativa do mercado brasileiro como um todo.

Além disso, os modelos ARIMA, embora robustos para capturar dependências temporais, podem não capturar completamente outras dinâmicas complexas, como volatilidade e não-linearidades presentes nas séries financeiras.

Futuros estudos devem considerar períodos temporais mais longos e incluir modelos mais complexos, como GARCH e VAR, que podem capturar volatilidade e inter-relações entre múltiplas séries temporais. Além disso, seria valioso comparar a eficiência do mercado brasileiro com outros mercados globais para contextualizar os achados e identificar se as ineficiências observadas são específicas ao mercado brasileiro ou se também ocorrem em outros mercados.

A aplicação de modelos ARIMA às séries temporais dos preços das ações brasileiras revelou ineficiências significativas no mercado. Os resultados fornecem uma base robusta para argumentar que o mercado brasileiro não é totalmente eficiente, indicando oportunidades para estratégias de negociação baseadas em previsões de preços.

A forte previsibilidade observada em várias ações desafia a HME e sugere que os preços passados contêm informações valiosas para prever os preços futuros. Estudos futuros devem expandir a análise para períodos mais longos, incluir modelos

mais complexos e realizar comparações internacionais para aprofundar ainda mais a compreensão da eficiência do mercado de ações brasileiro.

ANEXO A – RESULTADOS DOS MODELOS ARIMA(1,0,1)

Variável	Ativo	Coefficientes	Erros Padrões
Constante	ABCB4	0,017905342	0,013104972
AR.L1	ABCB4	-0,716141059	0,229602829
MA.L1	ABCB4	0,99942414	14,71372029
Sigma ²	ABCB4	0,003889842	0,057010517
Constante	AGRO3	0,003034769	0,017051294
AR.L1	AGRO3	-0,693570376	0,20168922
MA.L1	AGRO3	0,999631036	13,25110517
Sigma ²	AGRO3	0,006136852	0,080671379
Constante	ALUP11	0,006667993	0,007727189
AR.L1	ALUP11	-0,540469921	0,574724398
MA.L1	ALUP11	0,739968886	0,468187734
Sigma ²	ALUP11	0,00154287	0,0003019
Constante	B3SA3	2,527892181	0,037434127
AR.L1	B3SA3	0,511245949	0,205868563
MA.L1	B3SA3	0,284311455	0,303625778
Sigma ²	B3SA3	0,008066583	0,002281514
Constante	BBAS3	0,029433916	0,004180327
AR.L1	BBAS3	0,678320196	0,215411843
MA.L1	BBAS3	-0,999756211	51,93306535
Sigma ²	BBAS3	0,003526269	0,182625338
Constante	BBSE3	0,019332605	0,00504773
AR.L1	BBSE3	0,82472604	0,26826193
MA.L1	BBSE3	-0,99952603	24,82925349
Sigma ²	BBSE3	0,00294145	0,072777332
Constante	BEEF3	-0,008956339	0,01514205
AR.L1	BEEF3	-0,162056732	0,94929548
MA.L1	BEEF3	-0,050379105	0,960838143
Sigma ²	BEEF3	0,011280352	0,003437951
Constante	BRAP4	3,020588991	0,045205923
AR.L1	BRAP4	0,587138602	0,24650966
MA.L1	BRAP4	0,177137051	0,338620887

Sigma²	BRAP4	0,008916671	0,002080883
Constante	BRSR6	0,006969217	0,017973398
AR.L1	BRSR6	-0,30380972	0,233054958
MA.L1	BRSR6	0,854773635	0,153370168
Sigma²	BRSR6	0,005905372	0,001810362
Constante	CMIG3	-0,001624051	0,001047801
AR.L1	CMIG3	-0,370610027	0,189421985
MA.L1	CMIG3	-0,999623854	30,11099395
Sigma²	CMIG3	0,007274694	0,219111872
Constante	CMIG4	0,020195473	0,002194232
AR.L1	CMIG4	0,527531146	0,234660379
MA.L1	CMIG4	-0,999555079	20,53896601
Sigma²	CMIG4	0,003190533	0,065426658
Constante	CMIN3	-0,005846964	0,023077036
AR.L1	CMIN3	-0,999930994	0,20196419
MA.L1	CMIN3	0,996750817	4,749926232
Sigma²	CMIN3	0,015219566	0,068540275
Constante	CPFE3	0,013812242	0,011747214
AR.L1	CPFE3	-0,725578383	0,196737973
MA.L1	CPFE3	0,980354259	0,249365034
Sigma²	CPFE3	0,003668318	0,001260151
Constante	CPLE3	0,020184784	0,00157551
AR.L1	CPLE3	0,404194829	0,211082393
MA.L1	CPLE3	-0,999616252	19,86225413
Sigma²	CPLE3	0,003355487	0,06635317
Constante	CPLE6	0,019656136	0,001602365
AR.L1	CPLE6	0,487659155	0,183506732
MA.L1	CPLE6	-0,999451838	17,032611
Sigma²	CPLE6	0,002991802	0,050767208
Constante	CSMG3	0,01208172	0,020822702
AR.L1	CSMG3	0,218165721	0,490411037
MA.L1	CSMG3	0,185979405	0,482448139
Sigma²	CSMG3	0,005350917	0,001731452

Constante	CSNA3	-0,024760457	0,026942255
AR.L1	CSNA3	0,273851157	2,136918574
MA.L1	CSNA3	-0,192345442	2,15195084
Sigma ²	CSNA3	0,019120465	0,003893333
Constante	CXSE3	0,01777727	0,016585667
AR.L1	CXSE3	-0,149964806	0,681847599
MA.L1	CXSE3	0,399286567	0,637435928
Sigma ²	CXSE3	0,007157034	0,001706966
Constante	DIRR3	0,019073739	0,019056278
AR.L1	DIRR3	-0,528178393	3,495929687
MA.L1	DIRR3	0,558537437	3,370273426
Sigma ²	DIRR3	0,012036222	0,003841513
Constante	EGIE3	0,003898655	0,007278926
AR.L1	EGIE3	-0,670705392	0,272209001
MA.L1	EGIE3	0,980308717	0,508261073
Sigma ²	EGIE3	0,001242789	0,000565518
Constante	FESA4	-0,002236515	0,001873355
AR.L1	FESA4	-0,212374198	0,164409534
MA.L1	FESA4	-0,999841163	105,6986987
Sigma ²	FESA4	0,007087162	0,748652174
Constante	FLRY3	-0,0112071	0,014743264
AR.L1	FLRY3	-0,288459112	1,038038416
MA.L1	FLRY3	0,455076357	0,924126583
Sigma ²	FLRY3	0,004654927	0,001376572
Constante	GGBR4	0,002069961	0,014082977
AR.L1	GGBR4	-0,867581304	0,419078681
MA.L1	GGBR4	0,78297279	0,575025853
Sigma ²	GGBR4	0,006529248	0,00163412
Constante	GOAU4	0,004026223	0,012565332
AR.L1	GOAU4	-0,755240102	0,408527175
MA.L1	GOAU4	0,619802292	0,4979381
Sigma ²	GOAU4	0,006157966	0,001792253
Constante	GRND3	-0,002401825	0,018001284

AR.L1	GRND3	0,043004168	0,614643247
MA.L1	GRND3	0,210239638	0,664705219
Sigma ²	GRND3	0,005844703	0,001478978
Constante	ITSA4	0,008485253	0,015065573
AR.L1	ITSA4	-0,02176657	0,680636825
MA.L1	ITSA4	0,274160478	0,624865346
Sigma ²	ITSA4	0,003556622	0,001015562
Constante	JBSS3	-0,003045221	0,011929286
AR.L1	JBSS3	-0,792909845	0,454834146
MA.L1	JBSS3	0,674982083	0,559434494
Sigma ²	JBSS3	0,005512453	0,001499617
Constante	JHSF3	1,588591533	0,062160088
AR.L1	JHSF3	0,654178216	0,173728073
MA.L1	JHSF3	0,448997503	0,190411438
Sigma ²	JHSF3	0,008692658	0,002369728
Constante	KEPL3	0,016811497	0,029663735
AR.L1	KEPL3	-0,502000317	1,857114857
MA.L1	KEPL3	0,568304402	1,748187238
Sigma ²	KEPL3	0,013677648	0,00380644
Constante	KLBN11	0,002147653	0,010156363
AR.L1	KLBN11	-0,447358814	0,49262929
MA.L1	KLBN11	0,117666712	0,568398827
Sigma ²	KLBN11	0,004991231	0,001229133
Constante	LAVV3	0,008283951	0,021036025
AR.L1	LAVV3	-0,3199814	3,156421923
MA.L1	LAVV3	0,361215799	3,128410952
Sigma ²	LAVV3	0,013235577	0,004311438
Constante	LEVE3	0,02002996	0,020883575
AR.L1	LEVE3	-0,23915486	0,952998467
MA.L1	LEVE3	0,444246676	0,929923424
Sigma ²	LEVE3	0,009714147	0,002231853
Constante	MRFG3	-0,008588494	0,018917956
AR.L1	MRFG3	-0,587504003	1,093976247

MA.L1	MRFG3	0,46453319	1,160120511
Sigma ²	MRFG3	0,014062718	0,002865931
Constante	PETR3	0,038647415	0,003394908
AR.L1	PETR3	0,604505359	0,250460244
MA.L1	PETR3	-0,999648666	31,31409248
Sigma ²	PETR3	0,006905537	0,214519372
Constante	PETR4	0,037465908	0,003550222
AR.L1	PETR4	0,707701541	0,257277445
MA.L1	PETR4	-0,999732972	39,79688769
Sigma ²	PETR4	0,006663685	0,263690204
Constante	PSSA3	0,007723522	0,010070097
AR.L1	PSSA3	0,397387608	0,725658424
MA.L1	PSSA3	-0,601059007	0,608264208
Sigma ²	PSSA3	0,006564019	0,002094482
Constante	RANI3	0,012312245	0,013734973
AR.L1	RANI3	-0,319195694	1,01867487
MA.L1	RANI3	0,169495399	1,057696583
Sigma ²	RANI3	0,008510824	0,002562475
Constante	RAPT4	-3,29152E-05	0,016537214
AR.L1	RAPT4	-0,196673042	2,270305747
MA.L1	RAPT4	0,112947806	2,264686545
Sigma ²	RAPT4	0,008699224	0,002244751
Constante	ROMI3	-0,015864845	0,019502774
AR.L1	ROMI3	-0,99993274	0,067739134
MA.L1	ROMI3	0,995736214	2,144730882
Sigma ²	ROMI3	0,01014826	0,020529665
Constante	SANB11	3,332271827	0,02784575
AR.L1	SANB11	0,521984252	0,190667484
MA.L1	SANB11	0,407891328	0,254131024
Sigma ²	SANB11	0,003119341	0,000955665
Constante	TAE11	0,003981959	0,002359695
AR.L1	TAE11	0,71578867	0,210948337
MA.L1	TAE11	-0,999784407	53,69312048

Sigma²	TAAE11	0,00185555	0,099637045
Constante	TASA4	-0,01388238	0,004377988
AR.L1	TASA4	0,662724249	0,223400561
MA.L1	TASA4	-0,999836087	58,91353272
Sigma²	TASA4	0,006834436	0,40153073
Constante	TGMA3	0,007047672	0,018241737
AR.L1	TGMA3	0,004999066	20,33903338
MA.L1	TGMA3	0,004908384	20,31603585
Sigma²	TGMA3	0,01144744	0,002959873
Constante	TRIS3	-0,019263355	0,032143066
AR.L1	TRIS3	-0,142215778	1,245428579
MA.L1	TRIS3	0,322659875	1,240644222
Sigma²	TRIS3	0,020318716	0,005246236
Constante	TRPL4	0,004387121	0,010123759
AR.L1	TRPL4	-0,312460432	0,505488635
MA.L1	TRPL4	0,541796049	0,493094621
Sigma²	TRPL4	0,001927392	0,000503978
Constante	UNIP6	4,134997875	0,058587013
AR.L1	UNIP6	0,668231482	0,117236324
MA.L1	UNIP6	0,339153972	0,228811939
Sigma²	UNIP6	0,009374678	0,002003634
Constante	USIM5	-0,015444652	0,022093735
AR.L1	USIM5	0,017986225	4,747207425
MA.L1	USIM5	0,017980578	4,743705791
Sigma²	USIM5	0,010281645	0,002774994
Constante	VALE3	4,231369553	0,040373335
AR.L1	VALE3	0,636674718	0,201083892
MA.L1	VALE3	0,129995173	0,282517099
Sigma²	VALE3	0,00706061	0,0019351
Constante	VIVT3	0,008297653	0,009424815
AR.L1	VIVT3	-0,014479835	8,066017281
MA.L1	VIVT3	-0,014467066	8,08157361
Sigma²	VIVT3	0,002963498	0,000918136

Constante	WIZC3	-0,006540638	0,024925393
AR.L1	WIZC3	-0,080742508	0,543450773
MA.L1	WIZC3	0,393983802	0,543872868
Sigma²	WIZC3	0,012815401	0,003417943

ANEXO B – CÓDIGO DO PROCEDIMENTO METODOLÓGICO

```
#!/usr/bin/env python
#%pip install pandas numpy yfinance investpy dateutil matplotlib pmdarima
statsmodels openpyxl
import pandas as pd
import numpy as np
import yfinance as yf
import investpy as inv
from datetime import datetime, date, timedelta
from dateutil.relativedelta import relativedelta
from statsmodels.tsa.stattools import adfuller, acf, pacf
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf
import matplotlib.pyplot as plt
from statsmodels.tsa.arima.model import ARIMA
n_backtesting_years = 5
br = inv.stocks.get_stocks(country='brazil')
carteira=[]
blacklist= ['VSPT3']
start_date = datetime(2021, 5, 1)
end_date = datetime(2024, 5, 1)
for a in br['symbol']:
    if ((a[(-2):] != '11') & (a not in blacklist)):
        carteira.append(a+'.SA')
carteira = [
    "ABCB4.SA", "ALUP11.SA", "AURE3.SA", "B3SA3.SA", "BRSR6.SA", "BBSE3.SA",
    "BRAP4.SA", "BBAS3.SA",
    "AGRO3.SA", "CXSE3.SA", "CMIG3.SA", "CMIG4.SA", "CSMG3.SA", "CPLE3.SA",
    "CPLE6.SA", "CPFE3.SA",
    "CMIN3.SA", "DIRR3.SA", "EGIE3.SA", "FESA4.SA", "FLRY3.SA", "GGBR4.SA",
    "GOAU4.SA", "GRND3.SA",
    "RANI3.SA", "ITSA4.SA", "JBSS3.SA", "JHSF3.SA", "KEPL3.SA", "KLBN11.SA",
    "LAVV3.SA", "MRFG3.SA",
    "LEVE3.SA", "BEEF3.SA", "PETR3.SA", "PETR4.SA", "PSSA3.SA", "RAPT4.SA",
    "ROMI3.SA", "SANB11.SA",
    "CSNA3.SA", "TAEE11.SA", "TASA4.SA", "TGMA3.SA", "VIVT3.SA", "TRPL4.SA",
    "TRIS3.SA", "UNIP6.SA",
    "USIM5.SA", "VALE3.SA", "WIZC3.SA"
]
#carteira+['DIVO11.SA', 'IWB11.SA']
# dt=yf.download(carteira, start=(date.today() -
relativedelta(years=n_backtesting_years)),end=date.today(), interval='1d')
dt=yf.download(carteira, start=start_date,end=end_date, interval='1d')
dt.sort_index(inplace=True)
dt=dt.reset_index().sort_values("Date").dropna(axis=1, how='all')
dt['Date'] = pd.to_datetime(dt['Date'],utc=True).dt.date
dt.set_index('Date',inplace=True)
dt = dt.groupby(dt.index).sum()
```

```

dt=dt.reset_index().sort_values("Date").dropna(axis=1,
how='all').set_index("Date").sort_index().copy()
df = dt.reset_index().copy()
df.columns = [f'{col[0]}_{col[1]}' if col[1] else col[0] for col in
df.columns]
df=df.reset_index(inplace=False, drop=True)[::20]
df = pd.melt(df, id_vars=['Date'], var_name='Column_type')
df[['Type', 'Asset']] = df['Column_type'].str.split('_', expand=True)
df = df[['Date', 'Asset', 'Type', 'value']].rename(columns={'value': 'Price'})
df = df.pivot_table(index=['Date', 'Asset'], columns='Type',
values='Price').reset_index()
df.to_csv('dados.csv')
df=df.round(2).copy()
df['Adj Close'] = df['Adj Close'].apply(lambda x: np.log(x))
df
import pandas as pd
import numpy as np
from statsmodels.tsa.stattools import adfuller

class AnalisadorSeries():
    def __init__(self, df):
        self.df = df

    # Definindo a função que aplica o teste ADF
    def adf_test(self, column):
        result = adfuller(column.dropna(), autolag='BIC') # Remove os NaNs e
aplica o teste ADF
        print(f'''
            'Test Statistic': {result[0]},
            'p-value': {result[1]},
            'Lags Used': {result[2]},
            'Number of Observations Used': {result[3]},
            'Critical Values': {result[4]},
            'IC Best': {result[5]}
            ''')
        return result[0], result[1], result[2], result[3], result[4],
result[5]

    # Função para testar a estacionariedade com diferenciação se necessário
    def check_stationarity(self, column):
        result = self.adf_test(column)
        if result[1] >= 0.05:
            print("Série não é estacionária, aplicando diferenciação.")
            diff_column = column.diff().dropna()
            return self.check_stationarity(diff_column)
        else:
            return column

```

```

# Função para plotar ACF e PACF
def plot_acf_pacf(self, series, max_lags=12, ativo=None):
    plt.figure(figsize=(12, 6))

    # Título personalizado para ACF
    print(f"{ativo}")
    titulo_acf = f"ACF - {ativo}" if ativo else "ACF"
    plt.subplot(121, title=titulo_acf)
    plot_acf(series, lags=max_lags, ax=plt.gca())

    # Título personalizado para PACF
    titulo_pacf = f"PACF - {ativo}" if ativo else "PACF"
    plt.subplot(122, title=titulo_pacf)
    plot_pacf(series, lags=max_lags, ax=plt.gca())

    plt.show()

# Função para ajustar o modelo ARIMA(1,0,1) e exportar os coeficientes e
# erros padrões em um DataFrame
def ajustar_arima(self, df, ativo):
    # Ajustar o modelo ARIMA(1,0,1)
    modelo = ARIMA(df['serie'].dropna(), order=(1,0,1))
    resultado = modelo.fit()

    # Extraindo os coeficientes e erros padrões
    params = resultado.params
    stderr = resultado.bse

    # Criando o DataFrame com os resultados
    resultados_df = pd.DataFrame({
        'Asset': [ativo] * len(params),
        'Coeficientes': params,
        'Erros Padrões': stderr
    })

    return resultados_df

# Selecionando um ativo
ativo = 'VALE3.SA'
df_vale = df[df['Asset'] == ativo]

# Carrega uma instância da classe
analizador = AnalisadorSeries(df=df_vale)

# Aplicando o teste e atualizando a coluna do DataFrame
df_vale.loc[:, 'serie'] = analizador.check_stationarity(df_vale.loc[:, 'Adj
Close'])

```

```

# Plota os gráficos ACF e PACF
analizador.plot_acf_pacf(df_vale['serie'].dropna(), ativo=ativo)

# Ajustando o modelo ARIMA e exportando os resultados
resultados_arima = analisador.ajustar_arima(df_vale, ativo=ativo)
resultados_arima

resultados_arima = pd.DataFrame()
for ativo in df['Asset'].drop_duplicates():
    try:
        df_vale = df[df['Asset'] == ativo]

        analisador = AnalisadorSeries(df=df_vale)
        # Aplicando o teste e atualizando a coluna do DataFrame
        df_vale.loc[:, 'serie'] =
        analisador.check_stationarity(df_vale.loc[:, 'Adj Close'])

        # Plota os gráficos ACF e PACF
        analisador.plot_acf_pacf(df_vale['serie'].dropna(), ativo=ativo)

        # Ajustando o modelo ARIMA e exportando os resultados
        resultados = analisador.ajustar_arima(df_vale, ativo=ativo)

        resultados_arima =
        pd.concat([resultados_arima, resultados], ignore_index=True, axis=0)
    except:
        pass #series problematicas (com valores faltantes, vindo da fonte do
        yahoo) foram desprezadas

resultados_arima.to_excel('resultados_arima.xlsx')
resultados_arima
resultados_arima['Asset'].drop_duplicates().shape

```

REFERÊNCIAS

- BOLLERSLEV, T. Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327, 1986.
- BOX, G. E. P., JENKINS, G. M., & Reinsel, G. C. (2008). *Time series analysis: forecasting and control* (4th ed.). John Wiley & Sons.
- BOX, G.E.P.; JENKINS, G.M. *Time Series Analysis: Forecasting and Control*. Holden-Day, 1976.
- DICKEY, David A.; FULLER, Wayne A.. Distribution of the Estimators for Autoregressive Time Series With a Unit Root. *Journal Of The American Statistical Association*, [S.L.], v. 74, n. 366, p. 427, jun. 1979. JSTOR. <http://dx.doi.org/10.2307/2286348>.
- ENDERS, W. (2004). *Applied Econometric Time Series*. John Wiley & Sons.
- ENGLE, R.F. Autoregressive Conditional Duration: A New Model for Irregularly Spaced Transaction Data. *Econometrica*, 68(5), 1127-1162, 2000.
- FAMA, E.F. Efficient Capital Markets: A Review of Theory and Empirical Work. *Journal of Finance*, 25(2), 383-417, 1970.
- GAIO, L. E., FREITAS ALVES, K. L. D., & PIMENTA JÚNIOR, T. (2009). O Mercado acionário brasileiro do novo milênio: um teste de eficiência. *BBR - Brazilian Business Review*, 6(3),231-246.
- GRANGER, C.W.J.; MORGENSTERN, O. *Predictability of Stock Market Prices*. Lexington Books, 1970.
- HAMILTON, J.D. (1994). *Time Series Analysis*. Princeton University Press.
- LIU, X.; SHEN, J. Integrating ARIMA with Machine Learning Models for Predicting Stock Price Movements. *Quantitative Finance*, 21(4), 2021.
- LJUNG, G. M., & BOX, G. E. P. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297-303.
- LO, A. W. (2004). The adaptive markets hypothesis: Market efficiency from an evolutionary perspective
- MALKIEL, B.G. (1973). *A Random Walk Down Wall Street*.
- POON, S.; GRANGER, C.W.J. Forecasting Volatility in Financial Markets: A Review. *Journal of Economic Literature*, 41(2), 478-539, 2003.

SHARPE, William F.. CAPITAL ASSET PRICES: a theory of market equilibrium under conditions of risk*. The Journal Of Finance, [S.L.], v. 19, n. 3, p. 425-442, set. 1964. Wiley. <http://dx.doi.org/10.1111/j.1540-6261.1964.tb02865.x>.

TALEB, N.N. (2007). The Black Swan: The Impact of the Highly Improbable.

TSAY, R.S. Analysis of Financial Time Series. Wiley-Interscience, 2005.

ZHANG, Y.; WATANABE, T. High-Frequency Analysis of Stock Price Dynamics Using ARIMA Models. Journal of Financial Econometrics, 18(3), 2020.