

Fundos de investimento imobiliário: análise de retornos com modelos de séries temporais e fatores exógenos

Real estate investment funds: an analysis of returns using time series models and exogenous factors

Fondos de inversión inmobiliaria: análisis de retornos con modelos de series temporales y factores exógenos

Como citar:

Milani, Bruno & Adriano Mendonça Souza, Adriano M. (2026). Fundos de investimento imobiliário: análise de retornos com modelos de séries temporais e fatores exógenos. Revista Gestão & Tecnologia, vol. 26, nº 2, p. 40-69

Bruno Milani, Professor do Eixo de Gestão e Negócios do Instituto Federal de Educação, Ciência e Tecnologia Farroupilha (IFFar)
<https://orcid.org/0000-0003-4445-789X>

Adriano Mendonça Souza, Professor do Departamento de Estatística da UFSM
<https://orcid.org/0000-0002-1562-2246>

"Os autores declaram não haver qualquer conflito de interesse de natureza pessoal ou corporativa, em relação ao tema, processo e resultado da pesquisa".

Editor Científico: José Edson Lara
Organização Comitê Científico
Double Blind Review pelo SEER/OJ
Recebido em 26/11/2025
Aprovado em 02/06/2026



This work is licensed under a Creative Commons Attribution – Non-Commercial 3.0 Brazi

Resumo

Objetivo: Identificar a relação entre o retorno do Ifix, seu retorno defasado e os retornos contemporâneos dos índices Imob e Ibovespa, utilizando modelos da família ARIMA aplicados aos Fundos de Investimento Imobiliário brasileiros (FIIs).

Metodologia: Foram estimados 29 modelos da família ARIMA com ordens entre 0 e 3. A abordagem foi inspirada no CAPM por incluir índices amplos como variáveis explicativas, porém adaptada à metodologia de Box-Jenkins. Os índices utilizados foram Imob e Ibovespa, incluídos como variáveis exógenas nos modelos de séries temporais.

Originalidade/Relevância: O estudo contribui ao debate sobre os fatores que explicam o retorno dos FIIs no mercado brasileiro. Diferentemente de modelos tradicionais baseados apenas em regressões lineares, a pesquisa utiliza modelos ARIMA e extensões, permitindo avaliar simultaneamente dependência temporal e influência de variáveis de mercado.

Principais resultados: O modelo com melhor desempenho foi o ARFIMAX (2, 0.26, 2) + $r_{Imob,t}$. Verificou-se que o retorno do Imob explica melhor o retorno do Ifix do que o Ibovespa. O retorno do Ifix apresenta dependência temporal de ao menos duas defasagens, com coeficientes ϕ_1 e ϕ_2 superiores ao coeficiente associado ao Imob. Logo, o retorno passado dos FIIs exerce maior influência sobre seu retorno contemporâneo do que indicadores amplos de mercado.

Contribuições teóricas/metodológicas: O estudo evidencia a adequação de modelos ARFIMAX para análise de FIIs, demonstrando que abordagens que combinam memória longa e variáveis exógenas são mais eficazes do que modelos lineares convencionais. Reforça ainda a importância de considerar defasagens estruturais do próprio índice.

Contribuições sociais/gerenciais: Os resultados oferecem subsídios para investidores, gestores e formuladores de políticas e contribuem para estratégias de alocação mais eficientes e melhor compreensão do comportamento desse segmento no mercado financeiro brasileiro.

Palavras-chaves: Real Estate Investment Trusts (REITS). Índice Ifix. ARIMA. Modelos de Box-Jenkins.

Abstract

Objective: To identify the relationship between the return of the Ifix, its lagged return, and the contemporaneous returns of the Imob and Ibovespa indices, using ARIMA family models applied to Brazilian Real Estate Investment Funds (FIIs).

Methodology: Twenty-nine ARIMA family time series models with orders between 0 and 3 were estimated. The approach was inspired by the CAPM, as it includes broad market indices as explanatory variables, but it was adapted to the Box-Jenkins methodology. The Imob and Ibovespa indices were used as exogenous variables in the time series models.

Originality/Relevance: The study contributes to the debate on the factors that explain FIIs' returns in the Brazilian market. Unlike traditional approaches based solely on linear regressions,

this research employs ARIMA models and their extensions, allowing the simultaneous assessment of temporal dependence and market variables' influence.

Main results: The best-performing model was ARFIMAX (2, 0.26, 2) + + $r_{Imob,t}$. The results show that the Imob index better explains the Ifix returns than the Ibovespa. The Ifix exhibits temporal dependence of at least two lags, with coefficients ϕ_1 and ϕ_2 higher than the coefficient associated with Imob. Thus, past FIIs returns exert greater influence on their contemporaneous returns than broader market indicators.

Theoretical/methodological contributions: The study demonstrates the suitability of ARFIMAX models for the analysis of FIIs, showing that approaches combining long memory and exogenous variables are more effective than conventional linear models. It also reinforces the importance of considering structural lags of the index itself.

Social/managerial contributions: The results provide insights for investors, managers, and policymakers, contributing to more efficient allocation strategies and a better understanding of this segment's behavior in the Brazilian financial market.

Keywords: Real Estate Investment Trusts (REITS). Ifix Index. ARIMA. Box-Jenkins Models.

Resumen

Objetivo: Identificar la relación entre el retorno del Ifix, su retorno rezagado y los retornos contemporáneos de los índices Imob e Ibovespa, utilizando modelos de la familia ARIMA aplicados a los Fondos de Inversión Inmobiliaria brasileños (FIIs).

Metodología: Se estimaron 29 modelos de series temporales de la familia ARIMA con órdenes entre 0 y 3. El enfoque estuvo inspirado en el CAPM por incluir índices amplios como variables explicativas, pero fue adaptado a la metodología de Box-Jenkins. Los índices Imob e Ibovespa fueron utilizados como variables exógenas en los modelos de series temporales.

Originalidad/Relevancia: El estudio contribuye al debate sobre los factores que explican el retorno de los FIIs en el mercado brasileño. A diferencia de los enfoques tradicionales basados únicamente en regresiones lineales, la investigación utiliza modelos ARIMA y sus extensiones, lo que permite evaluar simultáneamente la dependencia temporal y la influencia de variables de mercado.

Principales resultados: El modelo con mejor desempeño fue el ARFIMAX (2, 0.26, 2) + + $r_{Imob,t}$. Se verificó que el retorno del Imob explica mejor el retorno del Ifix que el del Ibovespa. El Ifix presenta dependencia temporal de al menos dos rezagos, con coeficientes ϕ_1 y ϕ_2 superiores al coeficiente asociado al Imob. Así, el retorno pasado de los FIIs ejerce mayor influencia sobre su retorno contemporáneo que los indicadores amplios del mercado.

Contribuciones teóricas/metodológicas: El estudio evidencia la adecuación de los modelos ARFIMAX para el análisis de FIIs, demostrando que los enfoques que combinan memoria larga y variables exógenas son más eficaces que los modelos lineales convencionales. Además, refuerza la importancia de considerar los rezagos estructurales del propio índice.

Contribuciones sociales/gerenciales: Los resultados ofrecen insumos para inversionistas, gestores y formuladores de políticas, contribuyendo a estrategias de asignación más eficientes y a una mejor comprensión del comportamiento de este segmento en el mercado financiero brasileño.

Palabras claves: Real Estate Investment Trusts (REITs). Índice Ifix. ARIMA. Modelos de Box-Jenkins.

1 Introdução

Um fundo de investimentos pode ser compreendido como um veículo de investimentos que reúne investidores interessados em aplicar recursos em ativos financeiros. O relatório consolidado diário de fundos de investimento da Associação Brasileira das Entidades do Mercado Financeiro e de Capitais (ANBIMA), referente a dezembro de 2024, apontou que o patrimônio líquido dos Fundos de Investimento Imobiliário (FIIs) somava quase 335 bilhões de reais, o que por si só evidencia a relevância desses veículos de investimento no mercado financeiro brasileiro. Essa importância econômica se reflete em uma regulação significativa, exercida tanto pelas próprias entidades do setor, representadas pela ANBIMA, quanto pelo governo federal, por meio da Comissão de Valores Mobiliários (CVM). Não por acaso, os FIIs são também objeto recorrente de estudos no meio acadêmico.

A regulamentação mais recente sobre o tema é estabelecida pela Resolução CVM nº 175, de 23 de dezembro de 2022, cujo Art. 4º define fundo de investimento como “uma comunhão de recursos, constituído sob a forma de condomínio de natureza especial, destinado à aplicação em ativos financeiros, bens e direitos, de acordo com a regra específica aplicável a cada fundo”. O Anexo III da mesma resolução trata especificamente dos fundos imobiliários, definidos no Art. 40 como aqueles que aplicam seus recursos em direitos reais sobre bens imóveis e em determinados títulos mobiliários relacionados ao setor imobiliário.

Uma visão abrangente do mercado de FIIs pode ser obtida por meio do índice Ifix, publicado pela Bolsa, Brasil, Balcão (B3), que tem por objetivo representar o desempenho médio dos FIIs mais negociados. Índices semelhantes são utilizados em mercados internacionais, onde fundos com características equivalentes são usualmente denominados *Real Estate Investment Trusts* (REITs). Outro índice publicado pela B3 e que está relacionado ao mercado imobiliário é o Imob, que representa a evolução do valor das empresas que exploram

este mercado. Considerando que os FIIs possuem cotas negociadas na bolsa de valores, é plausível supor que exista relação entre seus retornos e índices de mercado amplos, como o Ibovespa no caso do Brasil.

A maioria dos estudos internacionais averigua a relação entre o retorno de REITs e de índices de mercado amplos (Alcock & Steiner, 2015; Cai & Xu, 2022; Coën & Guardiola, 2025; Sukor, Sujak, & Noordin, 2020; Zhang, Li, & Roca, 2023) ou entre o retorno de REITs e de fatores macroeconômicos (Cai & Xu, 2022; Fasanya & Adekoya, 2022; Kola & Kodongo, 2017; Sukor, Sujak, & Noordin, 2020). No contexto brasileiro, estudos como Dias e Silva (2021), Milani e Ceretta (2013), Milani, Ceretta e Machado (2016) e Oliveira e Milani (2020) não encontram relação entre o retorno de FIIs e o retorno do Imob, enquanto que a relação entre o retorno de FIIs e do Ibovespa ocorre em contextos específicos.

Há ainda uma diversidade de métodos voltados à análise dos FIIs e REITs, com foco na explicação ou previsão de seus retornos. Essas análises recorrem a modelos de regressão (Alcock & Steiner, 2015; Cai & Xu, 2022; Dias & Silva, 2021; Kola & Kodongo, 2017; Loo, 2020; Oliveira & Milani, 2020; Sukor, Sujak, & Noordin, 2020), modelos de previsão (Fasanya & Adekoya, 2022), de volatilidade (Huang & Wu, 2015; Milani & Ceretta, 2013), vetores de correção de erros (Monteiro, Sebastião, & Silva, 2024) e redes neurais (Loo, 2020; Zhang et al., 2023), entre outros. Em geral, são utilizadas variáveis macroeconômicas e de mercado como explicativas, baseadas principalmente no Capital Asset Pricing Model (CAPM) de Jensen (1968) e suas extensões, em especial os modelos de três e quatro fatores de Fama e French (1993) e Carhart (1997). Os modelos complementares e suas variações são diversos e os resultados, frequentemente divergentes.

Os modelos baseados no CAPM são tipicamente estimados por regressões lineares Ordinary Least Squares (OLS) e tem como variável explicativa principal um índice que representa o mercado de ações. No entanto, o uso de regressão linear em séries temporais encontra obstáculos devido a seus pressupostos, ao passo que diversos estudos não apresentam os diagnósticos das estimações, o que levanta dúvidas sobre a validade dos critérios empregados. É comum, ainda, o uso de modelos estatísticos avançados com muitas variáveis explicativas, o que, aliado à ausência de diagnóstico, compromete a parcimônia das análises.

Uma das abordagens possíveis para analisar séries temporais de forma mais adequada é o uso de modelos da classe geral ARIMA, os quais podem ser complementados com variáveis exógenas. Ou seja, a metodologia desenvolvida por Box e Jenkins (1970) é geralmente utilizada para prever séries temporais com base no seu próprio comportamento passado, com o uso dos fatores AR e MA, mas pode incluir outras variáveis explicativas, que costumam ser denominadas exógenas. Logo, um modelo ARIMA pode abranger características do CAPM ao incluir variáveis de mercado como exógenas.

Diante desse cenário, o seguinte problema de pesquisa emerge: o retorno dos Fundos Imobiliários brasileiros pode ser explicado pelo seu retorno passado e pelo retorno contemporâneo dos índices Imob e Ibovespa? Embora originalmente concebidos para fins de previsão, os modelos da família ARIMA também permitem a compreensão do comportamento das séries temporais analisadas, o que os torna valiosos para que a questão problema seja respondida. Além da típica estimação univariada, que permite averiguar o impacto dos valores passados da própria série, há a possibilidade de estimação de modelos com variáveis exógenas, úteis para tornar o modelo comparável ao CAPM.

O estudo se justifica, primeiramente, pela importância econômica deste veículo de investimentos, por meio do qual é administrado grande montante de recursos financeiros. A literatura científica existente atualmente, além de não ser numerosa no que tange ao contexto brasileiro, não encontra consenso acerca das variáveis que explicam o retorno dos fundos imobiliários. Modelos de precificação clássicos como o CAPM e modelos análogos seriam úteis para identificar o impacto de variáveis de mercado no retorno dos FIIs, no entanto encontrariam fragilidades na estimação de regressão linear em séries temporais. Portanto, identificar quais variáveis explicam o retorno dos FIIs brasileiros demanda o uso de modelos adequados a séries temporais e que concomitantemente permitam que eles sejam explicados por variáveis de mercado. Explicar o retorno dos FIIs é de importância para o avanço da produção científica na área e para profissionais do mercado, que podem valer-se destas informações para a tomada de decisão.

2 Referencial teórico

Uma das vertentes da literatura sobre FIIs busca explicar seus retornos a partir de variáveis macroeconômicas e fatores de risco. Uma visão geral desse mercado é apresentada por Okoro e Ayaba (2023), que realizaram uma análise bibliométrica e de conteúdo da literatura acadêmica sobre riscos e desempenho em REITs no período pós-crise financeira global (2008–2022). O estudo teve como objetivo mapear tendências, temas emergentes, autores prolíficos, países e periódicos de destaque, bem como identificar lacunas na pesquisa e propor direções para investigações futuras. Os resultados mostraram que a pesquisa sobre REITs esteve fortemente concentrada em países como Austrália, Estados Unidos e Reino Unido, com significativa colaboração entre autores australianos, mas cooperação internacional limitada. Embora os estudos mais citados tenham destacado fatores como diversificação, estrutura de capital, governança corporativa e indicadores Environmental, Social and Governance (ESG) como determinantes centrais do desempenho, os autores enfatizaram lacunas importantes, incluindo a necessidade de pesquisas empíricas que integrem fatores macroeconômicos, eventos extremos como a COVID-19 e a gestão de liquidez.

De fato, uma linha de pesquisa tem explorado a relação entre os retornos dos REITs e sua dependência dos mercados acionários mais amplos. Alcock e Steiner (2015), ao analisarem REITs de ações dos EUA de 1993 a 2013, constataram que tanto a dependência linear quanto a probabilidade de agrupamento de retornos com o S&P 500 foram influenciadas por características das firmas. REITs com menor risco sistemático geralmente apresentavam menor porte, menor momentum de curto prazo, baixa rotatividade e indicadores mais fortes de desempenho no longo prazo.

Kola e Kodongo (2017) analisaram os retornos de REITs nos Estados Unidos, África do Sul e Bulgária, avaliando sua dependência em relação a fatores macroeconômicos. Foram estimadas regressões com variáveis independentes como Produto Interno Bruto (PIB), produção industrial, taxa de câmbio, inflação, taxa de juros e suas respectivas volatilidades, estimadas por um modelo GARCH (1,1). Para evitar multicolinearidade, os autores aplicaram análise de componentes principais. Os índices representativos do mercado de REITs de cada país foram

utilizados como proxies, e os resultados indicaram que quase nenhum fator macroeconômico gerou coeficientes estatisticamente significativos.

Fasanya e Adekoya (2022) investigaram a previsibilidade dos REITs, focando em três países africanos e utilizando um modelo baseado em Westerlund e Narayan (2015). As variáveis explicativas incluíram inflação, taxa de juros e taxa de câmbio, com ajustes para persistência (autocorrelação) e assimetria. Os resultados variaram entre os países, com destaque da significância da inflação em todos os casos e o melhor desempenho dos modelos propostos pelos autores em comparação com ARFIMA, medido pelo erro médio quadrado.

Além de fatores macroeconômicos, outros estudos avaliaram a relação entre o retorno dos REITs/FIIs e o retorno do mercado de ações. Sukor et al. (2020) analisaram REITs da Malásia (2011–2017), investigando sua relação com o índice Kuala Lumpur Composite Index (KLCI), taxas de juros de curto e longo prazo (baseadas em títulos públicos) e um índice de preços ao consumidor. A amostra de 13 REITs foi segmentada de acordo com tamanho, bem como entre islâmicos e não islâmicos. Os resultados de uma regressão linear mostraram que o retorno do mercado foi significativo para REITs convencionais e pequenos, com coeficiente positivo, e que a inflação apresentou coeficiente negativo ao considerar retornos ajustados por dividendos.

Uma das possibilidades para explicar o retorno dos REITs é o uso do CAPM e suas versões estendidas, como os modelos amplamente conhecidos de Fama e French (1993) e Carhart (1997). Utilizando essa abordagem, Zhang et al. (2023) estimaram regressões OLS com REITs de cinco países entre 2000 e 2022, incluindo também fatores que representavam assimetria e curtose. Apenas o fator momentum exerceu uma influência positiva e consistente sobre os retornos, embora sua magnitude variasse entre países e tipos de REITs. Em contraste, os efeitos de assimetria e curtose foram estatisticamente fracos ou inconsistentes na maioria dos casos, sugerindo que o momentum permanece um fator de risco relevante, enquanto a assimetria e a curtose desempenham um papel limitado. Os resultados se sustentam tanto no período anterior quanto posterior à pandemia.

De forma semelhante, Coën e Guardiola (2025) analisaram 471 REITs dos EUA ao longo de um período de 24 anos, formando portfólios definidos por porte, razão valor

patrimonial de mercado e razão dívida-valor, com o objetivo de examinar o impacto da alavancagem, da volatilidade do fluxo de caixa e do crescimento dos investimentos no contexto do modelo de Fama–French. Os resultados indicaram que a alavancagem foi um fator-chave na explicação dos retornos dos REITs, demonstrando forte poder explicativo e superando em relevância fatores tradicionais como porte e valor. A volatilidade do fluxo de caixa apresentou influência mais fraca, enquanto o crescimento dos investimentos mostrou uma relação menos consistente. O fator momentum, geralmente relevante para ações, demonstrou baixo poder explicativo para os REITs, destacando as características distintas desse segmento de mercado.

Cai e Xu (2022) examinaram o impacto da pandemia de COVID-19 nos retornos dos REITs por meio de um modelo de Fama-French estendido incorporando variáveis contábeis e macroeconômicas. Seus achados apontaram para efeitos específicos por setor: os retornos de REITs de Escritórios e Residenciais caíram significativamente, enquanto os REITs Industriais mostraram resiliência, e os REITs de Varejo foram em grande parte pouco afetados.

Huang e Wu (2015) exploraram a relação entre retornos de REITs e ações por meio de modelos de correlação condicional e GJR-GARCH, com estimativas baseadas em métodos gaussianos e cópulas. A análise utilizou dados diários (2000–2010) do índice Financial Times Stock Exchange (FTSE) REIT. Foram estimadas regressões para explicar a correlação por variáveis como juros de títulos públicos, liquidez e volatilidade, com subdivisão da amostra antes e depois da crise do subprime. O índice VIX foi o único fator significativo nos dois períodos, embora com efeitos opostos: antes da crise, um VIX elevado reduzia a correlação; após a crise, a aumentava.

Monteiro et al. (2024) empregaram os modelos Vector Autoregressive (VAR) e Time-Varying Parameters VAR (TVP-VAR) para prever os retornos de ações, títulos públicos e REITs nos EUA, com dados mensais de 1976 a 2021. As previsões fora da amostra foram avaliadas com o índice FTSE Nareit US Real Estate All-Equity REITs como proxy. Para mitigar o risco de overfitting, um algoritmo genético foi utilizado para selecionar apenas 17 preditores, dos quais três relacionados aos REITs. O modelo TVP-VAR apresentou melhor desempenho preditivo, identificando correlação entre REITs e o retorno defasado de títulos públicos, além de um preditor do índice de ações.

Nos últimos anos, algoritmos de redes neurais artificiais também vêm sendo utilizados na previsão de retornos. Loo (2020) comparou modelos baseados no CAPM, Fama e French (1993) e redes neurais, ao analisar REITs de Hong Kong. Os resultados indicaram superioridade das redes neurais, embora com variações entre os REITs. Zhang et al. (2023) aplicaram o método Group Method of Data Handling (GMDH), um algoritmo de rede neural, com variáveis de análise técnica, em 135 REITs do índice US REIT (2016–2021). O modelo apresentou erro médio quadrado significativamente inferior aos obtidos com modelos GARCH.

No contexto brasileiro, estudos utilizaram o Ifix como proxy para o mercado local de REITs. Milani e Ceretta (2013) investigaram a correlação dinâmica entre o Ifix e dois índices-chave — Imob e Ibovespa — no período de 2011 a 2013. O uso de modelos de Correlação Condicional Dinâmica (Dynamic Conditional Correlation - DCC) revelou ausência de correlação significativa, embora a associação com o Ibovespa fosse ligeiramente mais forte. Milani et al. (2016) ampliaram essa análise por meio de decomposição em ondaletas (wavelets), mostrando que, enquanto regressões OLS tradicionais não apresentaram coeficientes significativos, regressões no domínio da frequência capturaram relações de longo prazo significativas tanto com o Imob quanto com o Ibovespa.

Oliveira e Milani (2020) analisaram variáveis explicativas do retorno dos FIIs no Brasil, com base nos índices Imob, Ibovespa e diversos índices de preços, incluindo o Fundação Instituto de Pesquisas Econômicas - ZAP (FIPEZAP). De modo geral, apenas o Ibovespa e a constante foram significativos. Contudo, ao considerar um subperíodo definido por teste de quebra estrutural, os índices FIPEZAP Comercial Locação e Residencial Venda também apresentaram significância.

Dias e Silva (2021) verificaram as variáveis que explicam o retorno dos FIIs entre 2017 e o início da pandemia COVID-19. A variação do Ifix foi utilizada como proxy para o retorno dos FIIs em uma estimação de regressão linear que apontou como única variável explicativa o Imob, com coeficiente de 0,14. No entanto, ao reduzir o período amostral para coincidir com a pandemia COVID-19, foi verificado que as variáveis explicativas passaram a ser a taxa do Sistema Especial de Liquidação e Custódia (SELIC) e o índice Ibovespa.

Observa-se que parte dos estudos não identifica relação significativa entre variáveis macroeconômicas e o retorno dos FIIs, como ocorre em Kola e Kodongo (2017) e Oliveira e Milani (2020). Outros trabalhos, como os de Fasanya e Adekoya (2022) e Huang e Wu (2015), atestam que fatores como inflação e volatilidade geram coeficientes significativos. Quanto aos índices de mercado, os estudos de Milani e Ceretta (2013), Zhang et al. (2023), Coën e Guardiola (2025) e Huang e Wu (2015) não apontam que sejam variáveis explicativas significativas, ao passo que Sukor et al. (2020), Milani et al. (2016) e Oliveira e Milani (2020) apontam que há significância, mesmo que em parte dos casos. Quanto ao índice Imob, Dias e Silva (2021) não encontraram relação significativa com o Ifix, enquanto Milani et al. (2016) verificaram que é gerado coeficiente significativo quando considerado o horizonte de longo prazo.

Assim, embora a literatura sobre o tema seja vasta, ainda não há consenso sobre os fatores que explicam os retornos dos FIIs, o que sinaliza espaço para pesquisas adicionais. Estudos que utilizam um elevado número de variáveis explicativas podem acarretar problemas de multicolinearidade — muitas vezes negligenciados. Kola e Kodongo (2017) e Monteiro et al. (2024), contudo, trataram essa limitação ao aplicar métodos de seleção e redução de variáveis. Esse cenário corrobora a intenção deste estudo em utilizar modelos com número limitado de variáveis explicativas.

A adequação da metodologia de Box-Jenkins à análise financeira pode ser exemplificada pelo estudo de Agostino et al. (2018). Outro ponto relevante está no fato de que alguns estudos apontam que as variáveis que explicam o retorno dos FIIs podem se alterar ao longo do tempo, como Dias e Silva (2021) e Milani et al. (2016), e mais recentemente todos os estudos que consideraram os efeitos da pandemia COVID-19, o que demanda cuidado com quebras estruturais.

3 Materiais e método

Para representar o mercado de FIIs, utilizou-se o retorno do Índice de Fundos de Investimento Imobiliários (Ifix). Nos modelos estimados, buscar-se-á explicá-lo tanto com base no seu comportamento passado quanto por variáveis explicativas exógenas, baseadas nos

índices Imob e Ibovespa, obtidos junto ao site da B3. A Tabela 1 resume informações acerca dos índices originais.

Tabela 1

Descrição das variáveis

Índice (sigla)	Índice (nome)	Descrição
Ifix	Índice de Fundos de Investimento Imobiliários	Indicador de desempenho médio dos fundos imobiliários negociados no mercado de bolsa e de balcão organizado
Imob	Índice Imobiliário	Indicador de desempenho médio das cotações dos ativos de maior negociabilidade e representatividade dos setores da atividade imobiliária (exploração de imóveis e construção civil).
Ibovespa	Índice Bovespa B3	Carteira teórica formada por ações e units de companhias mais negociadas na B3, correspondendo a cerca de 80% do volume de negócios.

Fonte: Bolsa, Brasil, Balcão (B3, 2025).

Os índices apresentados na Tabela 1 serão transformados em séries de retornos financeiros, conforme Equação (1).

$$r_{i,t} = \frac{P_{i,t}}{P_{i,t-1}} - 1 \quad (1)$$

Em que $r_{i,t}$ é o retorno do índice i no período t ; P_t é o preço (valor original) do índice i no período t e $P_{i,t-1}$ é o preço (valor original) do índice i no período $t-1$.

Para simplificação da redação, os retornos dos índices Ifix, Imob e Ibovespa serão referidos como $r_{Ifix,t}$, $r_{Imob,t}$ e $r_{Ibov,t}$, respectivamente. Os dados utilizados são de frequência diária e abrangem os pregões ao longo do período de 02/01/2019 a 30/05/2025, totalizando 1595 observações. O número de observações é menor do que o número de dias contidos entre as datas de início e fim devido à inexistência de pregões em finais de semana e feriados.

Inicialmente, o teste de Bai-Perron (Bai & Perron, 1998, 2003) será calculado para averiguar a estabilidade das séries ao longo do tempo, indicando possíveis quebras estruturais. Caso existam quebras estruturais, o período de análise será reavaliado, de forma a assegurar a constância dos parâmetros ao longo do tempo.

Em seguida, as estatísticas descritivas e a correlação de Pearson (1895) serão calculadas, visando apresentar as características básicas das variáveis. A análise da correlação, é relevante

em função das duas variáveis exógenas, que exigem cuidado para não gerar multicolineariedade.

A análise subsequente consistirá nos testes de estacionariedade de Dickey-Fuller (1979) e Phillips-Perron (1988), assim nos testes de autocorrelação de Box-Ljung (Box & Ljung, 1978) e Runs (Wald & Wolfowitz, 1940). Os referidos testes são fundamentais para verificar a adequação das séries aos modelos que se objetiva estimar.

Nos momentos de estimação de modelos de previsão, a amostra será segregada entre período de treino e período de teste. O período de treino será utilizado para efetivamente estimar os modelos e calcular seus coeficientes, enquanto o período de teste, correspondente ao período final da amostra, será utilizado para gerar previsões com o método de *rolling forecast*. Neste método, as estimações são atualizadas a cada observação do período de teste.

Com o período de treino definido, serão estimados modelos da família ARIMA, categorizados como ARIMA (Box & Jenkins, 1970), ARFIMA (Granger & Joyeux, 1980), ARIMAX (Box & Tiao, 1975; Hosking, 1981) e ARFIMAX (Baillie, 1996), com ordens entre 0 a 3. A seleção do melhor modelo dentro de cada categoria será realizada com base nos critérios de informação de Akaike (AIC – Akaike, 1974) e de Bayesiano de Schwarz (BIC – Schwarz, 1978). Com o melhor modelo de cada categoria, serão efetuadas previsões para o período de teste (previsão fora da amostra), utilizando os parâmetros estimados no período de treino. As previsões serão avaliadas pelos critérios de Erro Absoluto Médio (Mean Absolute Error – MAE), Raiz do Erro Quadrático Médio (Root Mean Squared Error – RMSE) e Taxa de Acertos (Hit Ratio).

A análise do melhor modelo de cada categoria, bem como do melhor modelo escolhido na etapa final, permitirá compreender melhor o comportamento dos retornos dos fundos imobiliários brasileiros, indicando quais dos fatores em questão o influenciam, sejam exógenos ou endógenos. O Capítulo 4 apresentará os resultados obtidos.

4. Resultados

O capítulo de resultados será dividido em três partes. A seção 4.1 apresentará a análise preliminar dos dados, detalhando o tratamento inicial e a formação da base efetivamente

utilizada. Em seguida, a seção 4.2 apresentará as estimações dos modelos da família ARIMA. Por fim, a seção 4.3 trará a análise das previsões realizadas com os modelos selecionados.

4.1 Análise preliminar dos dados

As séries temporais financeiras podem apresentar comportamentos distintos ao longo do tempo, uma vez que as relações entre variáveis econômicas podem se modificar em diferentes períodos. Quando não há estabilidade na série, os parâmetros estimados podem deixar de ser válidos para todo o intervalo analisado. A análise de quebras estruturais tem justamente o propósito de identificar pontos em que ocorrem mudanças significativas no padrão da série. Neste estudo, essa análise foi realizada por meio do teste de Bai-Perron, conforme Equação (01), cujos resultados são apresentados na Tabela 2.

Tabela 2
Resultados do teste de Quebra Estrutural de Bai-Perron

Nº de Quebras	Pontos de Quebras				Ajuste	
					RSS*	BIC**
0					118228951	22427
1			1092		36046532	20547
2	239		1099		27520074	20131
3	239	868	1107		26116751	20062
4	239	615	868	1107	25533123	20041
5	239	615	868	1107	1356	25417344

Fonte: Elaborado pelo autor com base em Bai e Perron (1998; 2003)

*RSS = *Residual Sum of Squares* (Soma dos Quadrados dos Resíduos); **BIC = *Bayesian Information Criterion* (Critério de Informação Bayesiano)

O teste de Bai-Perron indica inicialmente de zero a cinco pontos de quebra. A quantidade de pontos de quebra a serem considerados pode ser avaliada pelas estatísticas BIC e soma dos quadrados dos resíduos (*Residual Sum of Squares* – RSS), cujos gráficos são apresentados na Figura 1.

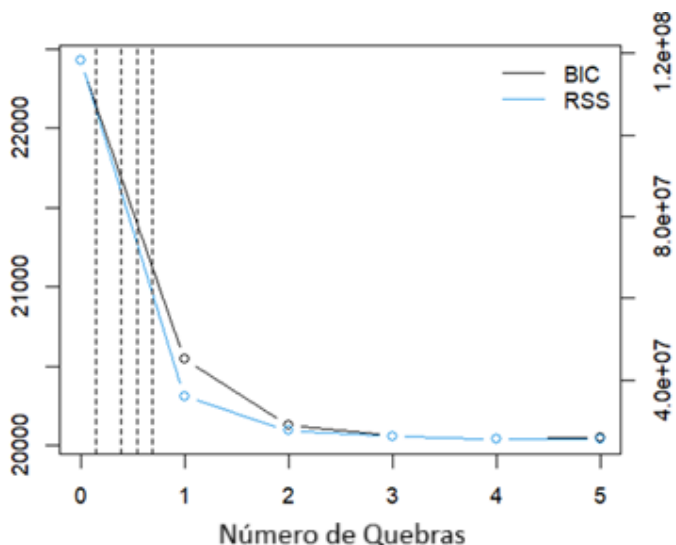


Figura 1: Soma dos quadrados dos resíduos (Teste de Bai-Perron)

Os valores de BIC e da Soma dos Quadrados dos Resíduos (RSS), apresentado na Figura 1, reduzem-se consideravelmente ao se considerar uma quebra estrutural, e continuam diminuindo, embora em menor intensidade, ao se incluir uma segunda quebra. No entanto, a redução não é expressiva com a introdução de uma terceira quebra, o que indica que o modelo mais parcimonioso é aquele com duas quebras estruturais. As quebras estruturais identificadas correspondem às observações $n=239$ (13/12/2019) e $n=1099$ (02/06/2023). Optou-se por considerar nas análises posteriores apenas os dados após a observação 1099, para garantir a estabilidade dos parâmetros dos modelos.

As análises a seguir baseiam-se, portanto, no período entre 02/06/2023 e 30/05/2025. Devido ao objetivo de realizar previsões fora da amostra, definiu-se o período de treino entre as observações 1099 e 1515 (02/06/2023 a 31/01/2025) e o período de teste entre as observações 1516 e 1595 (01/02/2025 a 30/05/2025). Os modelos serão estimados com o período de treino e as previsões serão realizadas aplicando-os ao período de teste.

Definido o intervalo de análise, bem como os períodos de treino e de teste, apresenta-se a Tabela 3, que traz as estatísticas descritivas.

Tabela 3

Estatísticas Descritivas das séries de $r_{Ifix,t}$, $r_{Imob,t}$ e $r_{Ibov,t}$

Variável	Média	Desvio Padrão	Mediana	Mínimo	Máximo	Amplitude	Assimetria*	Curtose**
r_{Ifix}	0,03	0,41	0,02	-1,94	2,48	4,41	0,43	6,93
r_{Imob}	0,05	1,61	0,10	-6,80	5,37	12,17	12,17	0,82
r_{Ibov}	0,04	0,92	0,03	-3,20	3,07	6,27	6,27	0,65

*Assimetria não padronizada; **Excesso de curtose não padronizado.

As médias de retorno foram positivas, evidenciando que todos os índices tiveram variação positiva no período. O desvio padrão dos retornos é consideravelmente menor no caso dos FIIs, o que é decorrente da natureza deste tipo de investimento, voltado ao mercado imobiliário, que supostamente é menos arriscado do que o mercado de ações. Pelo mesmo motivo, os retornos do Imob e do Ibovespa são mais dispersos e com amplitude maior. O fato de que o desvio padrão e a amplitude dos retornos do Ibovespa são menores do que os dos retornos do Imob pode ser justificado pelo fato de ser uma carteira mais diversificada, pois representa o mercado como um todo. A maior assimetria positiva dos retornos do Imob deve-se ao fato de este ser um índice de preços, que por sua natureza apresenta mais comumente variações positivas. Chama a atenção a alta curtose do retorno do Ifix, que pode ser originada pela alternância de retornos pequenos e eventos extremos ocasionados por choques macroeconômicos.

A análise descritiva das séries é complementada pelas Figuras 2 e 3, que apresentam as séries em nível e em primeira diferença (retorno).

Imob

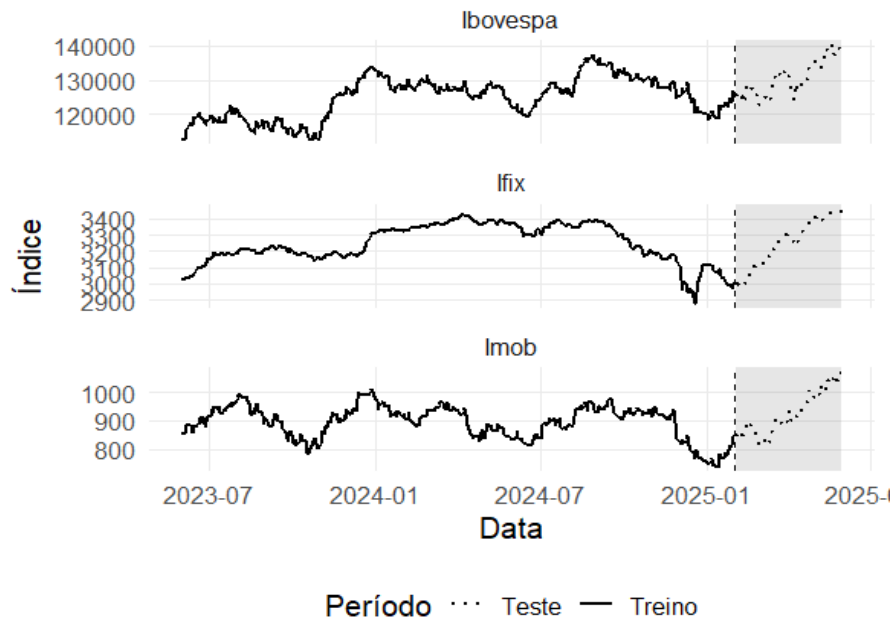


Figura 2: Gráficos das séries temporais dos Índices Ibovespa, Ifix e Imob

Na Figura 2, verifica-se que as séries de Ibovespa e Imob apresentam certa semelhança em seu comportamento, considerando que as tendências de ascensão e queda ocorrem aproximadamente ao mesmo tempo. Para todas as séries, vários ciclos de ascensão e queda ocorrem ao longo do período analisado, de forma que seus pontos mais baixos ocorrem pouco antes do final do período de treino. Antes do princípio do período de teste, começa uma tendência de ascensão, de maneira que próximo ao final do período de teste ocorre o ponto máximo.

No caso da variável Ifix, as oscilações ocorrem de forma mais suave, refletindo a estabilidade esperada de um investimento ligado ao mercado imobiliário. Porém, no final do ano de 2024 ocorre também o seu ponto mínimo, seguido de uma tendência de ascensão no período de teste, como ocorre nas demais séries. A Figura 3 apresenta os gráficos correspondentes às séries de retorno.

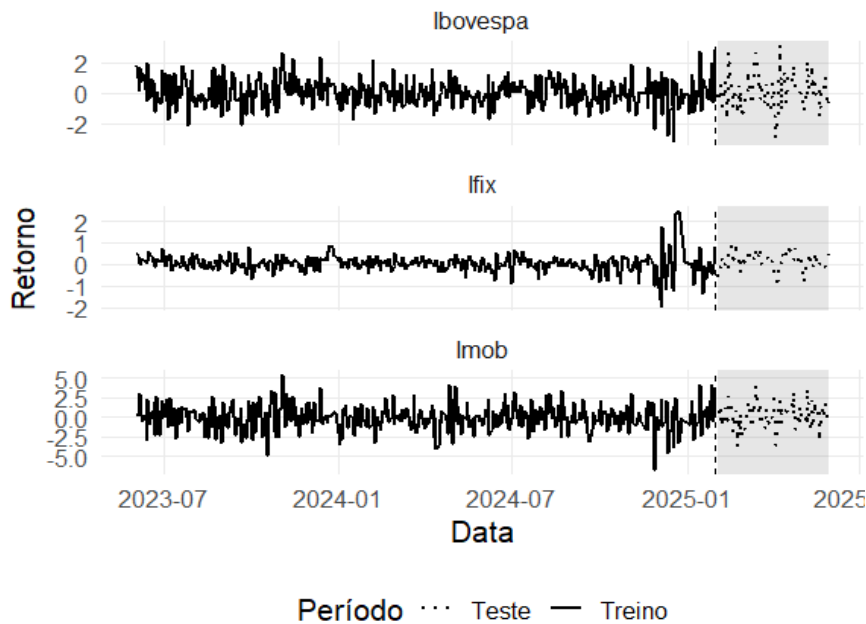


Figura 3: Gráficos das séries temporais dos retornos dos Índices Ibovespa, Ifix e Imob

Na Figura 3, chama a atenção o fato de que a variabilidade do Imob é superior ao Ibovespa, corroborando o maior desvio-padrão apresentado nas estatísticas descritivas. Até o final de 2024, a variação do Ifix é consideravelmente menor do que a dos outros índices. Contudo, próximo ao final do período de treino, as três séries apresentam seus momentos de maior volatilidade, fenômeno que afeta também o Ifix.

A estimação de modelos com mais de duas variáveis inspira cuidados com a possibilidade de multicolineariedade. Para investigar as características das variáveis que poderiam ocasionar este problema, foi calculada a correlação de Pearson, apresentada na Tabela 4.

Tabela 4

Coefficientes de correlação entre as séries de retornos

Variável	$r_{Ifix,t}$	$r_{Imob,t}$	$r_{Ibov,t}$
r_{Ifix}	1,00	0,16***	0,13***
r_{Imob}		1,00	0,78***
r_{Ibov}			1,00

*** p-valor<0,01

Percebe-se que o retorno do Ifix apresenta correlação significativa, mas de pequena magnitude, com os retornos de Imob e Ibov, o que reforça a necessidade de utilizar modelos que não expliquem Ifix apenas com base nestas duas variáveis. Por outro lado, os retornos de Imob e Ibov apresentam correlação relevante entre eles, com coeficiente maior e também significativo.

Outra característica relevante na análise de séries temporais é a estacionariedade, que foi avaliada pelos testes ADF e Phillips-Perron. Seus resultados se encontram na Tabela 5.

Tabela 5

Testes de Estacionariedade das séries de retornos

Variável	Dickey-Fuller		Phillips-Perron	
	ADF	p-valor	T	p-valor
r_{Ifix}	-7,45	0,00	-317,25	0,00
r_{Imob}	-6,79	0,00	-495,54	0,00
r_{Ibov}	-7,08	0,00	-506,01	0,00

Fonte: elaborado pelos autores com base em Dickey e Fuller (1979) e Phillips e Perron (1988)

Os testes de Dickey-Fuller e Phillips-Perron rejeitaram a hipótese nula de raiz unitária em todos os casos, a julgar pelos seus p-valores próximos à zero. Isto significa que as séries podem ser consideradas estacionárias, o que já era esperado tendo em vista que as séries de retorno constituem a primeira diferença dos índices originais Ifix, Imob e Ibovespa.

A análise da autocorrelação foi realizada com os testes de Box-Ljung e Runs, de forma que seus resultados se apresentam na Tabela 6.

Tabela 6

Testes de autocorrelação

Variável	Box-Ljung		Runs Test	
	χ^2	p-valor	Z	p-valor
r_{Ifix}	102,80	0,00	-4,85	0,00
r_{Imob}	25,12	0,01	0,99	0,32
r_{Ibov}	8,35	0,59	0,09	0,93

Fonte: elaborado pelo autor com base em Box e Ljung (1978) e Wald e Wolfowitz (1940)

Os testes de Box-Ljung e Runs rejeitaram a hipótese nula de inexistência de autocorrelação nos retornos do Ifix. Em contraste, os retornos do Ibovespa não apresentaram evidências de autocorrelação, enquanto os resultados para o retorno do Imob foram mistos: um dos testes rejeitou a hipótese nula, enquanto o outro não. As características de não normalidade e autocorrelação, frequentemente observadas em séries temporais, indicam a inadequação de modelos de regressão OLS para esse tipo de dado, o que contraria pressupostos de modelos tradicionais como o CAPM.

Diante disso, justifica-se o uso de modelos de séries temporais, como os da família ARIMA, os quais, assim como as regressões OLS, requerem a estacionariedade — condição atendida pelas séries analisadas. Logo, a seção 4.2 apresenta os coeficientes estimados por diversos modelos da classe geral ARIMA.

4.2 Estimações de modelos de séries temporais

Inicialmente, foram estimados modelos ARIMA com $d=0$, ou seja, equivalentes a modelos ARMA. Apesar de as séries analisadas representarem os retornos de índices financeiros — isto é, a primeira diferença dos respectivos índices — optou-se por considerar que $d=0$ porque as séries já haviam sido diferenciadas, ou seja, transformadas em retornos, desde o início do processo de análise. Diversas estimações preliminares, omitidas a posteriori, não foram capazes de gerar coeficientes lineares significativos em caso algum, o que levou à decisão de excluir a constante de todas as estimações apresentadas nesta seção. A Tabela 7 apresenta os coeficientes estimados para os modelos ARIMA e ARIMAX.

Tabela 7
Coeficientes estimados para os Modelos ARIMA

Modelo	Parâmetro	Coefficiente	P-Valor	Box-Ljung (χ^2)	Box-Ljung (p-valor)	AIC	BIC
ARIMA(1, 0, 0)	$\phi_1(r_{Ifix,t-1})$	0,35	0,00	0,02	0,99	392,78	400,84
ARIMAX(1, 0, 0) + $r_{Ibov} + r_{Imob}$	$\phi_1(r_{Ifix,t-1})$	0,36	0,00	0,20	0,90	386,38	402,51
	$\beta_1(r_{Ibov,t})$	-0,06	0,05				
	$\beta_2(r_{Imob,t})$	0,06	0,00				
ARIMAX(1, 0, 0) + r_{Imob}	$\phi_1(r_{Ifix,t-1})$	0,35	0,00	0,06	0,97	388,06	400,16
	$\beta_2(r_{Imob,t})$	0,03	0,01				

Fonte: elaborado pelo autor com base em Box e Jenkins (1970), Box e Tiao (1975) e Hosking (1981)

Foram estimados 10 modelos ARIMA com diferentes combinações das ordens p e q , variando de 0 a 3. Para cada modelo, foram calculadas as estatísticas AIC, BIC e o teste de autocorrelação de Box-Ljung. No entanto, o único modelo que apresenta todos os coeficientes angulares estatisticamente significativos e concomitantemente não rejeita a hipótese nula de ausência de autocorrelação nos resíduos é o ARIMA (1,0,0). É o único modelo que atende plenamente aos pressupostos desse tipo de modelagem, indicando dependência em relação aos retornos passados, mas não em relação aos erros passados. Por essa razão, este modelo foi selecionado como a base para a estimação com variáveis exógenas, as quais caracterizam modelos ARIMAX.

Tais modelos podem ser compreendidos como extensões do modelo ARIMA, nos quais foram adicionadas as variáveis exógenas descritas no Quadro 1, de forma alternada. Apenas os modelos ARIMAX (1,0,0) + $r_{Ibov,t}$ + $r_{Imob,t}$ e ARIMAX (1,0,0) + $r_{Imob,t}$ geraram coeficientes significativos e não rejeitam a hipótese nula de ausência de autocorrelação, de forma que o primeiro apresentou o menor AIC e o segundo, o menor BIC.

Considerando a intenção de escolher o melhor ARIMA e o melhor modelo ARIMAX para a fase subsequente, na qual serão realizadas as previsões fora da amostra, os três modelos dispostos na Tabela 6 serão levados, tendo em vista o empate nos critérios para a escolha do modelo com variáveis exógenas.

Outro modelo amplamente utilizado é o ARFIMA, caracterizado pela diferenciação fracionária. O grau de diferenciação fracionária foi calculado pelas funções do pacote *fracdiff* do R, resultado em $d=0,2602$. A partir da definição de d , foram estimados 10 modelos com parâmetros p e q variando de 0 a 3, com a intenção de escolher o melhor para incluir as variáveis exógenas. O modelo que apresenta diferenciação fracionária e paralelamente inclui variáveis exógenas é denominado ARFIMAX. Os resultados dos modelos ARFIMA e ARFIMAX são apresentados na Tabela 8.

Tabela 8
Coeficientes estimados para os modelos ARFIMA e ARFIMAX

(continua)

Modelo	Parâmetro	Coefficiente	P-Valor	Box-Ljung (χ^2)	Box-Ljung (p-valor)	AIC	BIC
ARFIMA(1, 0,26, 0)	$\phi_1(r_{fix,t-1})$	0,11	0,02	1,56	0,46	403,47	411,54
	$\phi_1(r_{fix,t-1})$	0,85	0,00				
ARFIMA(1, 0,26, 2)	$\theta_1(\varepsilon_{t-1})$	-0,76	0,00	4,53	0,34	396,18	412,31
	$\theta_2(\varepsilon_{t-2})$	-0,17	0,00				
ARFIMA(2, 0,26, 1)	$\phi_1(r_{fix,t-1})$	1,03	0,00	3,67	0,45	395,92	412,05
	$\phi_2(r_{fix,t-2})$	-0,17	0,00				
	$\theta_1(\varepsilon_{t-1})$	-0,94	0,00				
ARFIMA(2, 0,26, 2)	$\phi_1(r_{fix,t-1})$	0,43	0,00	8,95	0,11	382,36	402,53
	$\phi_2(r_{fix,t-2})$	-0,89	0,00				
	$\theta_1(\varepsilon_{t-1})$	-0,30	0,00				
	$\theta_2(\varepsilon_{t-2})$	0,87	0,00				
ARFIMA(3, 0,26, 3)	$\phi_1(r_{fix,t-1})$	1,31	0,00	13,78	0,06	379,08	407,32
	$\phi_2(r_{fix,t-2})$	-1,25	0,000				
	$\phi_3(r_{fix,t-3})$	0,78	0,00				
	$\theta_1(\varepsilon_{t-1})$	-1,23	0,00				
	$\theta_2(\varepsilon_{t-2})$	1,13	0,00				
ARFIMAX (2, 0,26, 2) + $r_{Ibov,t}$	$\theta_3(\varepsilon_{t-3})$	-0,83	0,00	9,60	0,09	380,18	404,38
	$\phi_1(r_{fix,t-1})$	0,45	0,00				
	$\phi_2(r_{fix,t-2})$	-0,90	0,00				
	$\theta_1(\varepsilon_{t-1})$	-0,32	0,00				
	$\theta_2(\varepsilon_{t-2})$	0,87	0,000				
ARFIMAX (2, 0,26, 2) + $r_{Imob,t}$	$\beta_1(r_{Ibov,t})$	0,04	0,04	8,51	0,13	368,50	392,70
	$\phi_1(r_{fix,t-1})$	0,46	0,00				
	$\phi_2(r_{fix,t-2})$	-0,90	0,00				
	$\theta_1(\varepsilon_{t-1})$	-0,32	0,00				
	$\theta_2(\varepsilon_{t-2})$	0,87	0,00				
	$\beta_2(r_{Imob,t})$	0,04	0,00				

Tabela 8
Coeficientes estimados para os modelos ARFIMA e ARFIMAX

(continuação)

Modelo	Parâmetro	Coefficiente	P-Valor	Ljung-Box (X2)	Ljung-Box (P-valor)	AIC	BIC
ARFIMAX (3, 0,26, 3) + $r_{Ibov,t}$	$\phi_1(r_{Ifix,t-1})$	1,32	0,00	13,98	0,05	375,55	407,81
	$\phi_2(r_{Ifix,t-2})$	-1,26	0,00				
	$\phi_3(r_{Ifix,t-3})$	0,78	0,00				
	$\theta_1(\varepsilon_{t-1})$	-1,25	0,00				
	$\theta_2(\varepsilon_{t-2})$	1,15	0,00				
	$\theta_3(\varepsilon_{t-3})$	-0,83	0,00				
	$\beta_1(r_{Ibov,t})$	0,05	0,02				
ARFIMAX (3, 0,26, 3) + $r_{Imob,t}$	$\phi_1(r_{Ifix,t-1})$	1,32	0,00	12,15	0,10	362,94	395,20
	$\phi_2(r_{Ifix,t-2})$	-1,27	0,00				
	$\phi_3(r_{Ifix,t-3})$	0,78	0,00				
	$\theta_1(\varepsilon_{t-1})$	-1,24	0,00				
	$\theta_2(\varepsilon_{t-2})$	1,14	0,00				
	$\theta_3(\varepsilon_{t-3})$	-0,83	0,00				
	$\beta_2(r_{Imob,t})$	0,05	0,00				

Fonte: elaborado pelo autor com base em Granger e Joyeux (1980) e Baillie (1996)

Os modelos com diferenciação fracionária com melhor ajuste entre os que apresentaram todos os coeficientes angulares significativos e ausência de autocorrelação serial foram ARFIMA (2, 0.26, 2), com menor BIC, e ARFIMA (3, 0.26, 3), com menor AIC. Tais modelos foram eleitos para a inclusão de variáveis exógenas, de forma que foram incluídas alternadamente as variáveis exógenas $r_{Imob,t}$ e $r_{Ibov,t}$, originando seis combinações. Na Tabela 8, foram apresentados apenas os quatro modelos que tiveram todos coeficientes significativos e ausência de autocorrelação nos resíduos.

Os melhores modelos ARFIMAX são ARFIMAX (2, 0.26, 2) + $r_{Imob,t}$ (menor BIC) e ARFIMAX (3, 0.26, 3) + $r_{Imob,t}$ (menor AIC). Tais modelos serão retidos para a realização das previsões fora da amostra. Um resumo das estatísticas BIC e AIC dos melhores modelos obtidos é fornecida pela Tabela 9.

Tabela 9

Resumo dos critérios de informação dos modelos de previsão

Família	Modelo	AIC	BIC
ARIMA	ARIMA(1, 0, 0)	392,78	400,84
ARIMAX	ARIMAX(1, 0, 0) + $r_{Ibov,t}$ + $r_{Imob,t}$	386,38	402,51
	ARIMAX(1, 0, 0) + $r_{Imob,t}$	388,06	400,16
ARFIMA	ARFIMA(2, 0,26, 2)	382,36	402,53
	ARFIMA(3, 0,26, 3)	379,08	407,32
ARFIMAX	ARFIMAX (2, 0,26, 2) + $r_{Imob,t}$	368,50	392,70*
	ARFIMAX (3, 0,26, 3) + $r_{Imob,t}$	362,94**	395,20

Fonte: elaborado pelo autor com base em Akaike (1974) e Schwarz (1978)

*Menor BIC; **Menor AIC

Entre os modelos com variáveis exógenas com melhor ajuste, apenas um incluiu a variável $r_{Ibov,t}$, enquanto todos incluíram a variável $r_{Imob,t}$. Ao comparar os modelos ARIMAX com o modelo ARIMA selecionado, percebe-se que a inclusão das variáveis exógenas diminui AIC e BIC, com exceção do BIC do modelo ARIMAX (1, 0, 0) + $r_{Ibov,t}$ + $r_{Imob,t}$. A mesma dinâmica ocorre ao comparar os modelos ARFIMAX com os modelos ARFIMA, nos quais a inclusão de variáveis exógenas diminui os valores de AIC e BIC em todos os casos. Entre todos os modelos, os que apresentam menor AIC e BIC, respectivamente, são ARFIMAX (3, 0.26, 3) + $r_{Imob,t}$ e ARFIMAX (2, 0.26, 2) + $r_{Imob,t}$.

De forma geral, pode-se entender que a inclusão da variável $r_{Imob,t}$ fez com que as estatísticas AIC e BIC diminuíssem, o que é relevante, uma vez que tais métricas penalizam a inclusão de variáveis. É possível inferir que, além do retorno passado, a variável $r_{Imob,t}$ é também importante para explicar o retorno do Ifix, o que não necessariamente ocorre com a variável Ibov. Além disso, há dependência de longo prazo, considerando que os melhores modelos são os que apresentam diferenciação fracionária.

Dando continuidade à avaliação, os melhores modelos escolhidos foram utilizados em previsões, com o objetivo de, por fim, eleger o modelo mais eficiente. Estes procedimentos são apresentados na seção 4.3.

4.3 Análise de Previsão

Foram realizadas previsões com os sete melhores modelos obtidos nos passos descritos na seção 4.2, conforme Tabela 9. As previsões foram realizadas com base no método de *rolling*

forecast, no qual as estimações são atualizadas a cada observação do período de teste. Para avaliar a qualidade das previsões, foram utilizados os critérios de MAE, RMSE e Hit Ratio. A Tabela 10 apresenta os resultados desta etapa.

Tabela 10
Avaliação das Previsões

Modelo	MAE	RMSE	Hit Ratio (%)
ARIMA(1, 0, 0)	0,27	0,35	67,50
ARIMAX(1, 0, 0) + $r_{Ibov,t}$ + $r_{Imob,t}$	0,26	0,34	73,75
ARIMAX(1, 0, 0) + $r_{Imob,t}$	0,26	0,34	66,25
ARFIMA(2, 0,26, 2)	0,26	0,35	68,75
ARFIMA(3, 0,26, 3)	0,27	0,36	67,50
ARFIMAX(2, 0,26, 2) + $r_{Imob,t}$	0,25*	0,33**	78,75***
ARFIMAX(3, 0,26, 3) + $r_{Imob,t}$	0,26	0,34	77,50

* Menor MAE; **Menor RMSE; ***Menor Hit Ratio

Entre os modelos escolhidos, o que apresenta menor MAE, RMSE e o maior Hit Ratio é o ARFIMAX (2, 0,26, 2) + $r_{Imob,t}$, ou seja, é considerado o modelo com melhor qualidade preditiva sob todos os critérios utilizados. É interessante observar que este foi o modelo com o menor BIC e o segundo menor AIC, conforme apresentado na Tabela 9, evidenciando que se destaca tanto pela capacidade de explicar quanto de prever os retornos dos fundos imobiliários

De forma geral, é possível sumarizar os resultados com a indicação de que o retorno dos FIIs depende do seu retorno passado em dois períodos e que a variável $r_{Imob,t}$ é relevante para explicar seus retornos, o que não ocorre com a variável Ibovespa.

5 Discussão dos resultados e considerações finais

Considerando a importância dos fundos imobiliários brasileiros (FIIs), cujo *benchmark* é o índice Ifix, o estudo teve como objetivo principal identificar a relação entre o retorno do índice Ifix, seu retorno defasado e os retornos contemporâneos dos índices Imob e Ibovespa, usando modelos da família ARIMA.

A análise de quebras estruturais evidenciou alterações na estabilidade dos parâmetros ao longo do tempo, permitindo delimitar o período adequado para a estimação dos modelos. O

cuidado com a estabilidade dos parâmetros é relevante, já que estudos como os de Dias e Silva (2021) e Milani et al. (2016) apontam que as variáveis que explicam o retorno dos FIIs podem se alterar ao longo do tempo.

Os testes aplicados sobre a série reforçaram essa necessidade: a rejeição da hipótese nula nos testes de normalidade e autocorrelação indicou, respectivamente, que a distribuição dos resíduos não segue o padrão gaussiano e que há dependência temporal a ser modelada. Por outro lado, os resultados positivos nos testes de estacionariedade confirmaram que a série satisfaz uma condição essencial para a aplicação de modelos da classe Box-Jenkins. Em conjunto, esses achados fornecem evidências da adequação e da viabilidade do uso de modelos ARIMA para capturar a dinâmica dos dados.

As estatísticas descritivas indicaram diferenças entre as dinâmicas do retorno do Ifix e dos demais índices, o que foi corroborado pelo baixo coeficiente de correlação entre $r_{Ifix,t}$ e o retorno dos dois índices de mercado, $r_{Ibov,t}$ e $r_{Imob,t}$, o que está em linha com o encontrado por Milani e Ceretta (2013). No entanto, há correlação forte entre $r_{Imob,t}$ e $r_{Ibov,t}$ (quase 0,78). Como os modelos selecionados ao final incluíram apenas uma variável exógena, a multicolineariedade não foi considerada um problema.

Para alcançar o objetivo, foram ajustados diversos modelos com ordens de 0 a 3, tanto univariados quanto com variáveis exógenas. Mais especificamente, foram estimados dez modelos ARIMA, três ARIMAX, dez ARFIMA e seis ARFIMAX, totalizando 29 modelos.

No que tange ao ajuste dos modelos, avaliados pelas estatísticas AIC e BIC, verificou-se que os que apresentaram melhor adequação são ARFIMAX (2, 0.26, 2) + $r_{Imob,t}$ e ARFIMAX (3, 0.26, 3) + $r_{Imob,t}$. A realização de previsões de acordo com o método de *rolling forecast* apontou que o modelo ARFIMAX (2, 0.26, 2) + $r_{Imob,t}$ é o mais eficiente. Ainda que o objetivo principal da pesquisa seja explicar os retornos, a análise da capacidade preditiva é relevante, pois fornece evidências adicionais sobre a validade do modelo. Ademais, o modelo de melhor desempenho preditivo é também um dos dois com melhor ajuste, o que reforça a consistência entre as análises.

Estes resultados tem importantes implicações tanto do ponto de vista acadêmico quanto de gestão. O CAPM preconiza que o retorno de um ativo financeiro pode ser explicado pelo

retorno de um índice de mercado, que representa o risco sistemático. Estudos em fundos imobiliários de mercados internacionais, como os de Alcock e Steiner (2015), Sukor et al. (2020), Zhang et al. (2023) e Monteiro et al. (2024) aplicaram o modelo CAPM e/ou suas extensões, com resultados divergentes quanto à relevância do índice de mercado.

No contexto dos FIIs, um índice de mercado amplo como o Ibovespa pode não ser o *benchmark* mais adequado, devido às características específicas deste tipo de investimento. Para avaliar essa dinâmica, o presente estudo optou por incluir entre as variáveis explicativas, além do retorno do Ibovespa, o retorno do Imob. Os resultados obtidos demonstraram que, no período analisado, o retorno do Imob é mais adequado para explicar o retorno dos FIIs, considerando o ajuste dos modelos, contrariando Milani e Ceretta (2013), Oliveira e Milani (2020) e Dias e Silva (2021).

Não obstante, identificou-se que a série apresenta dependência temporal de pelo menos duas defasagens, evidenciada pelo fato de o melhor modelo ajustado ser um ARFIMAX (2, 0.26, 2). Destaca-se que, neste modelo, os coeficientes ϕ_1 e ϕ_2 são consideravelmente superiores ao coeficiente β_2 , indicando que o retorno passado dos fundos imobiliários impacta mais no seu retorno contemporâneo do que o retorno do índice Imob, dentro da especificação do modelo. Esta característica é de grande relevância e indica que estudos futuros devem levar em consideração o efeito do retorno defasado do Ifix.

Do ponto de vista da gestão, a evidência de que o Imob explica melhor os retornos dos FIIs do que o Ibovespa indica que gestores devem se orientar por indicadores mais próximos da realidade do setor imobiliário. Como os coeficientes ϕ_1 e ϕ_2 foram mais relevantes que β_2 , conclui-se que o retorno passado dos FIIs pesa mais na formação do retorno contemporâneo do que o retorno do Imob. Isso sugere que o gestor deve monitorar ciclos internos do mercado de FIIs, ajustando estratégias com base na própria trajetória dos fundos.

O parâmetro de diferenciação fracionária ($d=0,26$) indica presença de memória longa, ou seja, choques no mercado de FIIs tendem a persistir. Essa evidência é especialmente relevante para a gestão de risco, sugerindo que os gestores devem considerar horizontes mais longos na modelagem da volatilidade e no cálculo de métricas como *Value-at-Risk* (VaR).

Entre as principais limitações deste estudo, é possível mencionar o uso de um período específico, o que pode restringir a generalização dos resultados. Mudanças estruturais no mercado de FIIs, como alterações regulatórias ou choques macroeconômicos, podem modificar a relação entre os índices analisados. Pesquisas futuras poderiam considerar janelas temporais distintas ou mais longas, bem como análises em subperíodos para capturar efeitos de quebras estruturais.

Outra limitação diz respeito ao fato de que a análise se concentrou em modelos da família ARFIMA e ARFIMAX, que capturam memória longa e dependência temporal. Entretanto, outros modelos podem também ser adequados para lidar com características dos retornos financeiros, como volatilidade condicional e assimetrias. Outrossim, o estudo analisou o retorno do índice Ifix como agregado do mercado de FIIs, embora os fundos imobiliários apresentem heterogeneidade relevante (fundos de tijolo, fundos de papel, híbridos, entre outros). Trabalhos futuros poderiam desagregar a análise para avaliar se a dinâmica identificada é homogênea entre os diferentes segmentos.

Referências

- Agostino, I. S., Noronha, M. O., Marasca, L., Santos, E. P., & Souza, A. M. (2018). Análise e modelagem do Índice de Sustentabilidade Empresarial (ISE) a partir da metodologia de Box-Jenkins. *Revista FSA*, 15(9), 112–129. <http://dx.doi.org/10.12819/2018.15.5.6>
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723. <https://doi.org/10.1109/TAC.1974.1100705>
- Alcock, J., & Steiner, E. (2015). What determines the systematic risk of REITs? Real Estate Research Institute.
- ANBIMA – Associação Brasileira das Entidades dos Mercados Financeiro e de Capitais. (n.d.). <http://www.anbima.com.br>
- ANBIMA – Associação Brasileira das Entidades dos Mercados Financeiro e de Capitais. (2015). Deliberação nº 62 do Conselho de Regulação e Melhores Práticas de Fundos de Investimento.
- B3 – Brasil, Bolsa, Balcão. (n.d.). Market data e índices. https://www.b3.com.br/pt_br/market-data-e-indices/
- Bai, J., & Perron, P. (1998). Estimating and testing linear models with multiple structural changes. *Econometrica*, 66(1), 47–78. <https://doi.org/10.2307/2998540>
- Bai, J., & Perron, P. (2003). Computation and analysis of multiple structural change models. *Journal of Applied Econometrics*, 18(1), 1–22. <https://doi.org/10.1002/jae.659>

- Baillie, R. T. (1996). Long memory processes and fractional integration in econometrics. *Journal of Econometrics*, 73(1), 5–59. [https://doi.org/10.1016/0304-4076\(95\)01732-1](https://doi.org/10.1016/0304-4076(95)01732-1)
- Box, G. E. P., & Jenkins, G. M. (1970). *Time series analysis: Forecasting and control*. San Francisco: Holden-Day.
- Box, G. E. P., & Ljung, G. M. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297–303. <https://doi.org/10.1093/biomet/65.2.297>
- Box, G. E. P., & Tiao, G. C. (1975). Intervention analysis with applications to economic and environmental problems. *Journal of the American Statistical Association*, 70(349), 70–79. <https://doi.org/10.1080/01621459.1975.10480264>
- Cai, Y., & Xu, K. (2022). Net impact of COVID-19 on REIT returns. *Journal of Risk and Financial Management*, 15(8), 359. <https://doi.org/10.3390/jrfm15080359>
- Carhart, M. M. (1997). On persistence in mutual fund performance. *The Journal of Finance*, 52(1), 57–82. <https://doi.org/10.1111/j.1540-6261.1997.tb03808.x>
- Coën, A., & Guardiola, P. (2025). Common risk factors in REIT returns: New insights. *The North American Journal of Economics and Finance*, 102447. <https://doi.org/10.1016/j.najef.2025.102447>
- Comissão de Valores Mobiliários. (2023). Resolução CVM nº 175, de 23 de dezembro de 2022. Diário Oficial da União.
- Dias, E. I., & Silva, A. C. M. (2021). Análise do desempenho dos Fundos Imobiliários no Brasil de 2017 à pandemia Covid-19. *Revista Vianna Sapiens*, 12(2), 22–22. <https://doi.org/10.31994/rvs.v12i2.813>
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(366), 427–431. <https://doi.org/10.1080/01621459.1979.10482531>
- Fama, E. F., & French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33(1), 3–56. [https://doi.org/10.1016/0304-405X\(93\)90023-5](https://doi.org/10.1016/0304-405X(93)90023-5)
- Fasanya, I. O., & Adekoya, O. B. (2022). Macroeconomic risk factors and REITs returns predictability in African markets: Evidence from a new approach. *Scientific African*, 17. <https://doi.org/10.1016/j.sciaf.2022.e01292>
- Granger, C. W. J., & Joyeux, R. (1980). An introduction to long-memory time series models and fractional differencing. *Journal of Time Series Analysis*, 1(1), 15–29. <https://doi.org/10.1111/j.1467-9892.1980.tb00297.x>
- Hosking, J. R. M. (1981). Fractional differencing. *Biometrika*, 68(1), 165–176. <https://doi.org/10.1093/biomet/68.1.165>
- Huang, M., & Wu, C. (2015). Economic benefits and determinants of extreme dependences between REIT and stock returns. *Review of Quantitative Finance and Accounting*, 44, 299–327. <https://doi.org/10.1007/s11156-013-0407-3>
- Jensen, M. C. (1968). The performance of mutual funds in the period 1945–1964. *The Journal of Finance*, 23(2), 389–416. <https://doi.org/10.2307/2325404>
- Kola, K., & Kodongo, O. (2017). Macroeconomic risks and REITs returns: A comparative analysis. *Research in International Business and Finance*, 42, 1228–1243. <https://doi.org/10.1016/j.ribaf.2017.07.061>

- Loo, W. K. (2020). Predictability of HK-REITs returns using artificial neural network. *Journal of Property Investment & Finance*, 38(4), 291–307. <https://doi.org/10.1108/JPIF-07-2019-0090>
- Milani, B., & Ceretta, P. S. (2013). Do Brazilian REITs depend on real estate sector companies or overall market? *Economics Bulletin*, 33, 2948–2957.
- Milani, B., Ceretta, P. S., & Machado, M. (2016). Brazilian REITs performance: An analysis of higher moments and time scales influence. *WSEAS Transactions on Business and Economics*, 1109–9526.
- Monteiro, A. S., Sebastião, H., & Silva, N. (2024). Prediction and allocation of stocks, bonds, and REITs in the US market. *Computational Economics*, 1–40. <https://doi.org/10.1007/s10614-024-10589-2>
- Okoro, C., & Ayaba, M. M. (2023). Research trends and directions on real estate investment trusts' performance risks. *Sustainability*, 15(6), 5436. <https://doi.org/10.3390/su15065436>
- Oliveira, J., & Milani, B. (2020). Variáveis que explicam o retorno dos fundos imobiliários brasileiros. *Revista Visão: Gestão Organizacional*, 9(1), 17–33. <http://dx.doi.org/10.33362/visao.v9i1.2051>
- Pearson, K. (1895). Notes on regression and inheritance in the case of two parents. *Proceedings of the Royal Society of London*, 58, 240–242. <https://doi.org/10.1098/rspl.1895.0041>
- Phillips, P. C. B., & Perron, P. (1988). Testing for a unit root in time series regression. *Biometrika*, 75(2), 335–346. <https://doi.org/10.1093/biomet/75.2.335>
- Schwarz, G. (1978). Estimating the dimension of a model. *The Annals of Statistics*, 6(2), 461–464.
- Sukor, M. E. A., Sujak, Z. A., & Noordin, K. (2020). Conventional REITs, Islamic REITs and macroeconomic variables in Malaysia: A review. *ISRA International Journal of Islamic Finance*, 12(1), 131–143. <https://doi.org/10.1108/IJIF-08-2018-0089>
- Wald, A., & Wolfowitz, J. (1940). On a test whether two samples are from the same population. *The Annals of Mathematical Statistics*, 11(2), 147–162.
- Westerlund, J., & Narayan, P. (2015). Testing for predictability in conditionally heteroskedastic stock returns. *Journal of Financial Econometrics*, 13(2), 342–375. <https://doi.org/10.1093/jfinec/nbu001>
- Zhang, W., Li, B., Liew, A. W. C., Roca, E., & Singh, T. (2023). Predicting the returns of the US real estate investment trust market: Evidence from the group method of data handling neural network. *Financial Innovation*, 9(1), 98. <https://doi.org/10.1186/s40854-023-00486-2>
- Zhang, W., Li, B., & Roca, E. (2023). Moments and momentum in the returns of securitized real estate: A cross-country study of risk factors driving real estate investment trusts before and during COVID-19. *Heliyon*, 9(8). <https://doi.org/10.1016/j.heliyon.2023.e18476>