

**AVALIANDO O IMPACTO DOS INDICADORES DE FUNDOS
IMOBILIÁRIOS EM SUAS PRECIFICAÇÕES DE MERCADO:
UMA ANÁLISE BASEADA EM FERRAMENTAS DE
INTERPRETABILIDADE EM APRENDIZADO DE MÁQUINA**

Universidade Presbiteriana Mackenzie

Coordenadoria de Fomento à Pesquisa - Pró-reitoria de Pesquisa e
Pós-Graduação

Rodrigo Souza Marcondes
Apoio: PIVIC Mackenzie

Guilherme Dean Pelegrina

Unidade acadêmica do aluno (UA)

Unidade acadêmica e/ou Programa de Pós-graduação do Orientador

<10390326@mackenzista.com.br>
<guilherme.pelegrina@mackenzie.br>

RESUMO

Atualmente, há um crescente número de pessoas físicas investindo em Fundos de Investimento Imobiliário no Brasil. Como a precificação desses fundos no mercado depende da percepção dos investidores em relação às diversas características do fundo (além de situações externas aos mesmos), a análise por parte dos gestores dos indicadores que mais estão associados ao preço praticado no mercado é de grande interesse. Por exemplo, no crescimento do fundo através de emissões, cujo sucesso está diretamente relacionado ao preço de mercado sobre o valor patrimonial (P/VP), saber quais indicadores impactam nessa relação pode ser útil para direcionar ações estratégicas a fim de melhorar tal indicador. Neste contexto, este trabalho tem como objetivo investigar, por meio de técnicas de Aprendizado de Máquina, as características internas e externas aos fundos que mais são relevantes na previsão do P/VP. Para essa análise, utilizamos o modelo de floresta aleatória e extraímos a interpretabilidade a partir de um método agnóstico. A partir da aplicação da proposta em FIIs dos setores de shoppings e imóveis logísticos, verificamos que o fator de maior relevância no P/VP foi os juros reais futuros medidos pela NTN-B 2035, ou seja, uma informação externa ao fundo. No entanto, alguns fatores internos mostraram uma certa relevância, como a vacância física, DY patrimonial anualizado e número de cotistas. Sendo assim, as conclusões obtidas oferecem subsídios para que os gestores tomem decisões estratégicas quanto à valorização dos seus ativos e expansão dos fundos imobiliários.

Palavras-chave: Mercado financeiro, Fundos de investimento imobiliário, Aprendizado de máquina, Interpretabilidade.

ABSTRACT

Currently, there is a growing number of individual investors allocating capital to Real Estate Investment Funds (FIIs) in Brazil. Since the market pricing of these funds depends on investors' perception regarding the fund's various characteristics (in addition to external factors), it is of great interest for managers to analyze which indicators are most closely associated with the market price. For example, in the case of fund growth through new share issuances, whose success is directly related to the market-to-book ratio (P/VP), understanding which indicators impact this relationship can be useful to guide strategic actions aimed at improving such metric. In this context, this study aims to investigate, through Machine Learning techniques, the internal and external characteristics of FIIs that are most relevant for predicting the P/VP ratio. For this analysis, we applied the random forest model and extracted

interpretability using an agnostic method. By applying the proposed approach to FIIs in the shopping mall and logistics real estate sectors, we found that the most relevant factor for P/VP was future real interest rates measured by the NTN-B 2035, i.e., an external piece of information relative to the fund. However, some internal factors also showed certain relevance, such as physical vacancy, annualized book dividend yield (DY), and number of investors. Therefore, the conclusions obtained provide valuable insights for managers to make strategic decisions regarding the appreciation of their assets and the expansion of real estate investment funds.

Keywords: Financial market, Real estate investment funds, Machine learning, Interpretability.

1. INTRODUÇÃO

É notável o crescente interesse dos brasileiros em iniciarem seus investimentos na Bolsa de Valores. Dentre os possíveis ativos financeiros, os Fundos de Investimento Imobiliário (FIIs) se mostram como um dos investimentos que mais atraem pessoas físicas, por exemplo, para complementar uma renda passiva na aposentadoria (DAS CUBERO et al., 2024). Como apontou o relatório da B3 de dezembro de 2024 (B3, 2024), o total de investidores em FIIs cresceu 14% apenas no ano anterior. Isso reforça a importância deste ativo financeiro tanto para compor a gama de investimentos dos brasileiros quanto para a análise por parte dos gestores e administradores de tais fundos, uma vez que os mesmos possuem como interesse o desenvolvimento deste mercado.

Via de regra, um FII no Brasil cresce a partir de emissões de novas cotas. Suponha que, hoje, a cota unitária de um fundo (seu valor de mercado) custe R\$ 100,00 na bolsa de valores. Ou seja, este seria o valor que os investidores estariam precificando o ativo. Além disso, suponha que tal cota possua um valor patrimonial (avaliado de acordo com seus imóveis, por exemplo) de R\$ 90,00 por cota. Em resumo, o procedimento de emissão de cotas consiste em (emitir e) vender novas cotas do fundo, geralmente dando preferência de compra aos já investidores do fundo, estabelecendo um valor de venda para tais cotas. Salvo algumas exceções, esse valor de venda é menor que o valor de mercado e maior que o valor patrimonial (em nosso exemplo, entre R\$90,00 e R\$ 100,00), para que a emissão atraia o interesse dos investidores em comprar novas cotas “com desconto” e cujo valor patrimonial não seja diluído. Ou seja, a razão entre o valor de mercado, precificado pelos investidores na bolsa de valores, e o valor patrimonial indica um elemento crucial no potencial crescimento de um FII.

Representaremos, aqui, esse indicador por P/VP (Preço/Valor Patrimonial). Note que, se esse indicador for maior que 1, há a possibilidade de sucesso na emissão de novas cotas, uma vez que pode se estabelecer um valor de venda maior que o patrimonial e menor que o de mercado. Por outro lado, se for menor que 1, provavelmente não será um atrativo para os investidores pessoas físicas, visto que elas pagariam mais caro do que está valendo no mercado e o patrimônio dos que já possuem cotas do fundo seria diluído. Vale ressaltar que há diversos outros parâmetros envolvidos no sucesso ou fracasso de uma emissão. Neste artigo, discutimos apenas a relação valor de mercado/valor patrimonial pois será utilizada em nossas análises.

Claramente, o P/VP sofre flutuações diárias devido ao valor de mercado variar. Embora fundos imobiliários sejam considerados, por muitos, menos voláteis em comparação com outros ativos financeiros (SCOLESE et al., 2015; ALMEIDA et al., 2021), há momentos em que certos fundos ficam com a relação $P/VP > 1$ e, em outros momentos, $P/VP < 1$. Diversos fatores podem estar associados a tais variações, desde fatores externos aos fundos (como a taxa básica de juros do país) até fatores internos (como o valor do provento distribuído ou o total da dívida do fundo). Do ponto de vista do gestor de um FII, nada pode ser feito em relação aos fatores externos ao fundo. No entanto, surge como uma análise interessante avaliar quais fatores internos podem ser melhorados a fim de aumentar a precificação do fundo pelos investidores na bolsa de valores. Como consequência, há o aumento da relação P/VP e, dessa forma, o gestor tem a possibilidade de emitir novas cotas e crescer o fundo.

Com base no contexto acerca da emissão de fundos imobiliários mencionado acima, o objetivo principal deste artigo consiste em investigar, a partir de métodos de Aprendizado de Máquina, qual o impacto de cada característica externa e interna dos fundos (indicadores financeiros que os caracterizam no mercado) na relação P/VP prevista pelo modelo. Como fundos de setores diferentes possuem indicadores diferentes, em nossas análises os indicadores são avaliados fixando um setor e coletando as informações de um conjunto de FIIs deste setor ao longo do tempo. Dentre os diversos setores existentes no mercado de FIIs, selecionamos os principais veículos voltados para os segmentos de shoppings e imóveis logísticos. Os FIIs de shoppings investem em centros comerciais que geram receita principalmente por meio da locação de espaços para lojistas e cobrança de aluguel percentual sobre as vendas. Esses fundos costumam ter uma correlação positiva com o desempenho do varejo e com a atividade econômica do país, já que o aumento no consumo beneficia as vendas dos lojistas e, por consequência, a receita do fundo. Já os FIIs logísticos investem em galpões e centros de distribuição, voltados ao atendimento de empresas de diversos setores, como e-commerce, varejo, agronegócio e indústria. A demanda por espaços logísticos tem crescido nos últimos anos, impulsionada principalmente pela expansão do comércio eletrônico e pela necessidade das empresas de manter cadeias de suprimento eficientes. Esses fundos geralmente firmam contratos de longo prazo (built-to-suit ou contratos atípicos), o que proporciona maior previsibilidade de receita. Além disso, sua performance tende a ser menos sensível à oscilação do consumo no curto prazo, apresentando um perfil mais defensivo em relação a outros segmentos.

De posse dos dados, aplicamos o modelo de Floresta Aleatória para prever o P/VP e extraímos os impactos de cada característica considerada no modelo. Como a interpretabilidade deste modelo não é trivial, os impactos relativos serão extraídos a partir de uma abordagem agnóstica.


2. REFERENCIAL TEÓRICO

Esta seção descreve a teoria envolvida neste estudo. Discutimos, primeiramente, aspectos básicos sobre os fundos imobiliários e seus indicadores (focando nos que utilizamos em nossos experimentos). Em seguida, abordamos o regressor baseado na Floresta Aleatória e a como são interpretados os impactos dos atributos (indicadores) no modelo obtido.

2.1. Fundos de Investimento Imobiliário e seus indicadores

Muitos acreditam que os FIIs são produtos novos, seja pelo crescimento do setor nos últimos anos, seja pelo crescimento do número de CPFs que possuem algum investimento na bolsa de valores. Todavia, os FIIs foram introduzidos no mercado brasileiro em 25 de junho de 1993, data na qual foi estabelecida a base legal para sua formação através da Lei nº 8.668/93 (CATROCCHIO, 2024). No entanto, mesmo com a criação da lei em 1993, os investidores só tiveram acesso ao investimento em FII no dia 15 de outubro de 1999, quando entrou em funcionamento o FII Shopping Higienópolis - SHPH11 (ALMEIDA, 2024). Antes dele, existiam apenas fundos voltados para grandes investidores e utilizados para auxiliar no planejamento tributário de incorporadores. Ao passo que na época os fundos eram mais exclusivos, hoje eles estão mais popularizados e acessíveis ao público geral. A mudança, por exemplo, na base de valor das cotas (reduzindo de R\$1.000 por cota para R\$100) também contribuiu para o aumento da liquidez e para que pequenos investidores pudessem acessar esse ativo (BARONI; CORREA, 2022). A Figura 1 ilustra a crescente evolução do setor, apontando o histórico do valor de mercado dos fundos imobiliários de 2011 à 2023. Como apontado pelo estudo realizado pela B3 (2024), o investimento em FIIs é dominado pelas pessoas físicas, as quais detêm 74% do saldo no produto.

Figura 1 – Evolução do valor de mercado dos FIIs (em milhões de reais)



Fonte: ECONOMATICA, 2023

Os fundos imobiliários podem ser analisados a partir de diversos indicadores internos, como (CVM, 2015; BARONI; BASTOS, 2019; REIS, 2023):

- *Cotação*: Preço da última negociação de um ativo em determinado momento;
- *Patrimônio Líquido (PL)*: Valor pertencente aos cotistas, composto por capital subscrito e lucros acumulados, ajustado por custos e prejuízos. O PL cresce com os lucros e decresce com a distribuição de dividendos. Além disso, outras variações do PL podem estar associadas ao mecanismo de marcação a mercado que ocorrem nos FIIs. No caso dos fundos de tijolo, esta variação ocorre por conta da reavaliação anual de seus ativos. Já no caso dos fundos de papel, a marcação de seus ativos ocorre pelo preço de mercado, determinado pelo seu administrador com base em critérios como o spread das taxas em relação a títulos públicos e a liquidez do papel;
- *Número de Cotistas*: Número de investidores, por CPF, que possuem ao menos uma cota de determinado FII;
- *Quantidade de Cotas*: Total de cotas emitidas, seja por IPO ou Follow-on;
- *Quantidade de Cotas/Cotista*: Indica a pulverização das cotas FII em relação ao número de cotistas;
- *Volume*: Refere-se à quantia de recursos financeiros negociados, expressa em reais (R\$), de um determinado FII ao longo de um período específico. Quanto maior o volume negociado, maior

a liquidez do ativo, o que, por sua vez, tende a resultar em menor volatilidade e menor risco associado à negociação das cotas no mercado secundário;

- *Receita*: Dinheiro que o fundo recebe, em um determinado período, com aluguéis, vendas, juros, correção monetária, etc.;
- *Receita/Cota*: Receita total dividida pela quantidade de cotas de determinado fundo;
- *Despesas*: São os custos operacionais que o fundo tem para manter suas atividades, como remuneração do gestor e do administrador, custódia, auditoria, escrituração e outras despesas inerentes à gestão do fundo;
- *Despesa/Cota*: Despesa total dividida pela quantidade de cotas de determinado fundo;
- *Resultado/Cota*: Refere-se ao lucro, calculado pela diferença entre as receitas e as despesas, dividido pela quantidade total de cotas emitidas;
- *Proventos*: Valor total distribuído aos cotistas, dividido pela quantidade total de cotas de determinado fundo. Por lei, os FIIs devem distribuir a seus cotistas, no mínimo, 95% dos lucros auferidos pelo regime de caixa a cada semestre;
- *VP/Cota*: Valor patrimonial de um FII dividido pela quantidade total de cotas emitidas;
- *DY Patrimonial Anualizado*: Indicador calculado pela razão entre o provento distribuído e o valor patrimonial por cota (VP/cota), com o resultado devidamente anualizado por meio da fórmula: $(1 + \text{Provento}/(\text{VP}/\text{Cota}))^{12} - 1$. O objetivo deste indicador é mensurar a capacidade de geração de resultados do FII ao longo de um determinado período;
- *Vacância Física*: Área bruta locável (ABL) que ainda não foi devidamente ocupada por algum inquilino. É representada pela fórmula: $\text{ABL Desocupada} / \text{ABL Total}$;
- *P/VP*: Valor de mercado de um determinado fundo dividido pelo seu valor patrimonial. É considerado um dos principais indicadores de *valuation* para se avaliar a atratividade do investimento em um FII.

As informações sobre esses indicadores podem ser retiradas de diversas páginas online sobre investimentos, como o *Status Invest* (<https://statusinvest.com.br/>) e o *Funds Explorer*


(<https://www.fundsexplorer.com.br/>), ou através da análise dos relatórios gerenciais de cada fundo, geralmente publicados mensalmente pelas gestoras. Tais indicadores, assim como outras características do próprio fundo, como a confiança na gestora, se já houveram emissões fracassadas ou outros acontecimentos associados à reputação do fundo, podem servir para avaliar o preço de mercado e avaliar a relação com o P/VP em um certo período de tempo.

Além dos indicadores internos, podem ser consideradas informações externas, como as curvas de juros, projeções de inflação, PIB e outros indicadores macroeconômicos. A interpretação desses dados confere maior robustez à análise dos FIIs, uma vez que tais veículos estão diretamente expostos à economia real. Por exemplo: i) Um cenário de atividade econômica aquecida tende a favorecer a ocupação dos imóveis e o aumento do consumo das famílias; ii) Uma inflação elevada pode resultar em reajustes significativos nos contratos de locação, elevando a receita dos fundos e, em alguns casos, reduzindo a capacidade de pagamento do inquilino; iii) Uma alta na taxa de juros aumenta a atratividade dos investimentos em renda fixa, podendo ocasionar uma fuga de capital dos ativos considerados de maior risco, como os FIIs.

Para a análise do impacto das características externas na relação P/VP dos FIIs, reunimos dados históricos da taxa real de juros no Brasil, representada pela taxa de compra do título do Tesouro Nacional NTN-B 2035 (Tesouro IPCA+ com vencimento em 2035). O objetivo é capturar, por meio da interpretação das variações históricas dessa taxa, as condições e perspectivas econômicas predominantes em cada período. Por exemplo, elevações na taxa de juros real tendem a provocar uma desaceleração da atividade econômica, impactando negativamente a ocupação dos imóveis e o desempenho dos ativos de renda variável.

Adicionalmente, esse movimento aumenta a atratividade dos investimentos em renda fixa, considerados por muitos investidores como opções mais seguras, o que pode resultar em fuga de capital dos Fundos de Investimento Imobiliário (FIIs). Essa realocação de recursos contribui para a desvalorização das cotas no mercado secundário e, conseqüentemente, para a redução da razão P/VP desses fundos. A escolha do título NTN-B 2035 (Tesouro IPCA+ 2035) para a análise em questão se justifica por ser um título com vencimento de longo prazo, possuir longo histórico de negociação e ser considerado um ativo livre de risco. Conforme demonstrado na Figura 2, é possível observar a correlação negativa existente entre os juros reais e o IFIX (indicador do desempenho médio das cotações dos fundos imobiliários negociados na B3).

Figura 2 – Comparação entre Taxa NTN-B 2035 (juros real) e IFIX



Fonte: Elaboração própria

2.2. Floresta aleatória e impacto das variáveis de entrada

Considere uma base de dados com n amostras $\mathbf{x}_i$, $i = 1, 2, \dots, n$. Cada amostra é descrita por um conjunto de m atributos, ou seja, $\mathbf{x}_i = [x_{i,1}, x_{i,2}, \dots, x_{i,m}]$ (também chamados de variáveis de entrada). Além disso, para cada amostra $\mathbf{x}_i$, temos um valor associado y_i (também chamado de variável de saída). Problemas de regressão consistem em estabelecer uma relação $f(\mathbf{x}_i) = \hat{y}_i \approx y_i$ (linear ou não-linear, dependendo do modelo adotado) de tal forma que o valor obtido pela relação $f(\mathbf{x}_i) = \hat{y}_i$ seja o mais próximo possível de y_i para todo $i = 1, 2, \dots, n$. Uma forma de medir se o modelo se ajustou bem aos dados é a partir do cálculo do coeficiente de determinação R^2 , dado por

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2},$$


onde $\bar{y}$ representa a média dos valores observados. Em resumo, essa métrica de desempenho indica a proporção da variância total da variável dependente que é explicada pelo modelo. O $R^2 \in [0,1]$ e quanto maior o valor, melhor o ajuste proporcionado pelo modelo.

Na literatura, há diversas técnicas de Aprendizado de Máquina que podem ser usadas como regressores (SARKER, 2021; KUMAR; BHATNAGAR, 2022). Podemos classificar tais técnicas em dois grupos: técnicas simples e interpretáveis, e técnicas complexas e de difícil interpretação (MOLNAR, 2023). Geralmente, técnicas simples resultam em modelos com

desempenhos inferiores às técnicas complexas. No entanto, por se tratarem de modelos mais simples e, geralmente, com menos parâmetros, permitem uma fácil interpretação de como as variáveis de entrada estão associadas à saída do modelo. Por outro lado, as técnicas complexas geralmente modelam melhor a relação entre variáveis de entrada e saída, levando a um bom desempenho. O preço que se paga é que tais modelos são de difícil interpretação, uma vez que possuem um mecanismo mais complexo (às vezes com muitas variáveis) para estabelecer a relação $f(\mathbf{x}_i) = \hat{y}_i$.

Dentre as técnicas consideradas robustas em Aprendizado de Máquina, podemos citar as Florestas Aleatórias (BREIMAN, 2001). Para compreender o funcionamento de tal modelo, precisamos entender no que consiste um modelo de árvore de decisão (LEE; CHEANG; MOSLEHPOUR, 2022). A árvore de decisão também é uma técnica de aprendizado de máquina que pode ser usada como regressor. A ideia de tal abordagem é particionar o espaço das variáveis de entrada $\mathbf{x}_i$, $i = 1, 2, \dots, n$ em diferentes ramificações, de forma que o valor estimado para a variável dependente $\hat{y}_i$ represente as amostras enquadradas em cada ramificação. A Figura 3 ilustra esse procedimento. Claramente, quanto maior o número de ramificações, mais valores $\hat{y}_i$ a árvore de decisão pode atingir. No entanto, um número excessivo de ramificações pode fazer com que o modelo fique especializado nos dados de treinamento, porém pouco generalista para os dados de teste. Isso é conhecido como *overfitting*.

Figura 3 - Exemplo de Árvore de Decisão



Fonte: Elaboração própria

A fim de mitigar (ou pelo menos reduzir) o efeito do *overfitting* em árvores de decisão, é interessante usar um conjunto de árvores de decisão para compor o modelo de aprendizado de máquina. Essa ideia está contida no modelo de Floresta Aleatória. Cada árvore de decisão é treinada em um subconjunto aleatório dos dados, usando uma estratégia de *bagging*. O resultado

médio das saídas de cada árvore individual tende a levar a um modelo mais robusto e menos sensível ao *overfitting*. Em resumo, as etapas de uma floresta aleatória são as seguintes:

- **Reamostragem (*Bagging*):** Com o intuito de criar árvores diferentes, no treinamento de cada árvore, seleciona-se (aleatoriamente) um subconjunto dos dados de treinamento. Essa seleção aleatória tende a construir árvores treinadas com dados diferentes e, portanto, aumenta a diversidade da floresta aleatória.
- **Seleção dos atributos:** Como um outro componente da floresta aleatória para gerar árvores diversas, seleciona-se aleatoriamente um subconjunto dos atributos para serem considerados como candidatos na próxima ramificação da árvore. Isso também contribui para aumentar a diversidade da floresta aleatória treinada.
- **Combinação das árvores na regressão:** Com o conjunto de árvores de decisão treinadas, o valor previsto $\hat{y}_i$ para a amostra $\mathbf{x}_i$ é calculado com base na média das previsões das árvores individuais (procedimento de *ensemble*). Essa estratégia tende encontrar previsões menos enviesadas, contribuindo para a robustez do modelo.

Por ser um modelo que traz resultados interessantes, a floresta aleatória vem sendo aplicada em análise de mercado de ações (SADORSKY, 2021; ZHENG *et al.*, 2024). No entanto, é uma técnica cuja interpretação não é tão clara, principalmente na relação do efeito dos parâmetros do modelo (e, conseqüentemente, das variáveis de entrada) no valor predito. Sendo assim, com o objetivo de se adotar um modelo de Aprendizado de Máquina que leve a um bom desempenho na tarefa de predição e, ao mesmo tempo, consiga trazer uma interpretabilidade acerca da importância das variáveis de entrada no valor predito, foram propostos na literatura mecanismos agnósticos para lidar com tais situações (MOLNAR, 2024).

Na biblioteca *scikit-learn* da linguagem Python, há uma função, chamada *permutation_importance*, que pode ser usada para extrair essa interpretabilidade da importância dos atributos na predição (o qual será utilizado em nossas análises). Esta função extrai a importância do atributo j (de uma forma agnóstica, ou seja, pode ser usada em qualquer modelo) a partir dos seguintes passos:

- **Cálculo do desempenho de referência:** Primeiramente, o modelo de floresta aleatória é treinado e o desempenho é calculado. No nosso caso, utilizaremos o R^2 .

- **Permutação dos valores do atributo j :** A fim de medir a importância do atributo j no regressor, permutam-se os valores do atributo j de maneira a quebrar a relação deste atributo com a variável de saída.
- **Cálculo do novo desempenho:** Feita a permutação do atributo j e mantendo as demais colunas inalteradas, realizam-se novamente as previsões e calcula-se o novo desempenho R_j^2 .
- **Cálculo da importância do atributo j :** Com base no desempenho de referência e no novo desempenho, a ideia é avaliar qual a piora no modelo ao quebrar a relação da variável j com os valores previstos. Para isso, calcula-se a diferença $R^2 - R_j^2$ e, a fim de extrair uma importância relativa, podemos realizar a seguinte normalização:

$$I_j^{FA} = \frac{|R^2 - R_j^2|}{\sum_{j=1}^m |R^2 - R_j^2|}.$$

3. METODOLOGIA

O interesse neste artigo é avaliar a importância de cada indicador (ou atributos externos) na capacidade de prever o P/VP de um FIIs, dado o modelo de floresta aleatória treinado. Iniciamos, então, selecionando um conjunto de FIIs do setor sob análise (shoppings ou imóveis logísticos). Nesta seleção, consideramos apenas os FIIs com no mínimo 1 bilhão de patrimônio no fechamento do ano de 2024. Uma vez selecionados esses FIIs, coletamos as informações mensais (indicadores internos e externos) ao longo dos anos de 2018 a 2024 para compor nossa base de dados. Os indicadores selecionados para prever o P/VP foram os seguintes: PL, número de cotistas, número de cotas/cotista, volume, receita/cota, despesas/cota, resultado/cota, VP/cota, DY patrimonial anualizado, vacância física e juros real NTN 2035.

De posse dos dados, treinamos o regressor baseado na floresta aleatória. Na etapa de construção do modelo, avaliamos diferentes configurações de florestas aleatórias (variando o número de árvores de decisão e profundidade das árvores), a fim de selecionar o modelo com melhor desempenho (em termos do R^2). Do total dos dados, consideramos 80% para treinamento e 20% para teste. Uma vez selecionado o melhor modelo, avaliamos o impacto de cada indicador por meio do modelo agnóstico discutido na Seção 2.2.


4. RESULTADO E DISCUSSÃO

Esta seção descreve os resultados obtidos para os setores de shoppings e de imóveis logísticos.

5.1 Interpretabilidade no setor de Shoppings


A base de dados analisada continha 369 amostras, contemplando as informações dos fundos XPML, MALL, VISC, HSML, HGBS. O modelo de floresta aleatória, ao ser treinado, apresentou um $R^2 = 0,86$, indicando um ajuste satisfatório do modelo aos dados observados, conforme ilustrado no gráfico de dispersão da Figura 4. O gráfico de dispersão mostra a distribuição das previsões de P/VP em relação aos valores reais, com os pontos se concentrando em torno de uma linha reta, o que reflete uma boa capacidade de predição por parte do modelo.

Figura 4 – Gráfico de dispersão: Shoppings



Fonte: Elaboração própria

Figura 5 – Representatividade dos indicadores - Shoppings




Fonte: Elaboração própria

Ao analisar as importâncias das variáveis no modelo, ilustradas na Figura 5, a taxa de juros real (NTNB 2035) se destacou como o fator mais relevante para a previsão do P/VP, confirmando a elevada sensibilidade dos FIIs de shopping ao ambiente macroeconômico. Em seguida, destacaram-se os indicadores internos DY patrimonial anualizado, número de cotistas e vacância física, os quais refletem diretamente a capacidade de geração de renda, a atratividade do fundo no mercado e a ocupação dos ativos, respectivamente. Esses resultados indicam que, embora fatores macroeconômicos exerçam forte influência sobre o *valuation* dos fundos, há espaço para atuação dos gestores sobre variáveis internas que impactam diretamente a precificação no mercado secundário.

5.2 Interpretabilidade no setor Logístico


Para o setor logístico, a análise incluiu FIIs BRCO, BTLG, GARE, HSLG, HGLG, LVBI, VILG, XPLG, com um total de 509 amostras. O modelo de floresta aleatória obteve um $R^2 = 0,94$, refletindo um excelente ajuste entre as variáveis analisadas e os valores preditos de P/VP, conforme demonstrado no gráfico de dispersão da Figura 6.

Figura 6 – Gráfico de dispersão - Logístico



Fonte: Elaboração própria

Figura 7 – Representatividade dos indicadores - Logístico



Fonte: Elaboração própria

Quanto à interpretabilidade, ilustrada na Figura 7, a taxa de juros real (NTNB 2035) novamente se destacou como a variável mais relevante para a previsão do P/VP, o que sugere que mesmo fundos com contratos atípicos e maior previsibilidade de receita ainda são fortemente influenciados pelas condições macroeconômicas. Em termos de indicadores internos, os fatores mais relevantes foram VP por cota e DY patrimonial anualizado, sugerindo que o mercado valoriza fundos com crescimento patrimonial sustentável, ampla base de investidores e capacidade consistente de geração de lucro.

5. CONCLUSÃO

Neste artigo, investigamos os principais indicadores internos e externos que influenciam na previsão do P/VP dos FIIs dos setores de shoppings e imóveis logísticos. Nessa análise, utilizamos o modelo de floresta aleatória e extraímos a interpretabilidade das variáveis de entrada a partir de método agnóstico disponível na linguagem Python.

Do ponto de vista do ajuste do regressor, obtivemos coeficientes de determinação satisfatórios, corroborando que o modelo empregado pôde encontrar uma boa relação entre os dados de entrada e o P/VP. Ao se analisar a importância relativa das variáveis no modelo preditivo, a taxa de juros real destacou-se como o fator mais relevante para a previsão da razão P/VP, exercendo impacto considerável sobre a relação entre o valor de mercado e o valor patrimonial dos fundos analisados. Tal resultado encontra justificativa nos efeitos provocados pela elevação desse indicador, conforme discutido previamente na Seção 2.1. Por se tratar de um indicador macroeconômico externo, o controle sobre essa variável escapa à alçada da gestão dos fundos, uma vez que sua formação está diretamente vinculada a políticas governamentais

e fatores de ordem internacional. Apesar disso, o modelo também apontou como relevantes, embora em menor magnitude, indicadores internos como o DY patrimonial anualizado, o número de cotistas e a vacância física. Tais variáveis, por serem passíveis de atuação direta por parte da gestão, configuram oportunidades para a otimização da atratividade e do desempenho dos fundos no mercado secundário. Um DY patrimonial elevado sinaliza que o fundo está gerando retornos consistentes em relação ao valor de seus ativos, o que tende a aumentar sua atratividade para investidores. Esse desempenho geralmente está associado a alocações eficientes de capital e boa gestão operacional. Por sua vez, uma vacância física elevada reflete menor ocupação dos ativos do portfólio, o que compromete a receita operacional, reduz os proventos distribuídos e eleva a percepção de risco por parte dos investidores. O número de cotistas, por fim, serve como uma proxy de liquidez e aceitação de mercado. Fundos com uma base ampla de investidores tendem a apresentar menor volatilidade, maior liquidez e menor risco de negociações com desconto, fatores que contribuem para a sustentação do P/VP. Além disso, oscilações significativas nesse indicador podem sinalizar movimentações expressivas de entrada ou saída de capital, afetando o equilíbrio entre oferta e demanda e, consequentemente, a precificação das cotas. Portanto, ações voltadas à transparência, recorrência e qualidade das divulgações institucionais do fundo podem ser estratégias eficazes para atrair e fidelizar investidores, contribuindo para o fortalecimento de sua posição no mercado. Como perspectivas futuras, a metodologia proposta pode ser aplicada em outros setores de FIIs, inclusive nos de papel, para compreender melhor os elementos que influenciam na cotação dos fundos. Outros indicadores também poderão ser incorporados, como aspectos qualitativos associados à governança do fundo e credibilidade por parte dos cotistas. Além disso, pretendemos explorar outros modelos de interpretabilidade, como os baseados no valor de Shapley (LUNDBERG; LEE, 2017), a fim de extrair possíveis interações entre os indicadores.

6. REFERÊNCIAS

ALMEIDA, Helberte João França; FELTRIN, Rafael Jasper; HAAS, Gabriel Pereira; NUNES, Mauricio Simiano. Existe value premium para os fundos imobiliários brasileiros? Uma análise para o período 2013 a 2018. **Revista brasileira de economia de empresas**, v. 21, n. 1, p. 117-130, 2021.

ALMEIDA, Marília. **A história do primeiro fundo imobiliário para pessoas físicas**. B3 Bora Investir, 2024. Disponível em: <https://borainvestir.b3.com.br/tipos-de-investimentos/renda->

variavel/fundos-investimento/a-historia-do-primeiro-fundo-imobiliario-para-pessoas-fisicas/.

Acesso em: 12 de maio de 2025.

BARONI, Marcos; BASTOS, Danilo. **Guia Suno Fundos Imobiliários: Introdução sobre investimentos seguros e rentáveis**. 1. ed. Paulínia: CLA, 2019.

BARONI, Marcos; CORREA, Marcos. **Evolução da indústria de fundos imobiliários: onde estávamos e para onde vamos**. Infomoney, 2022. Disponível em: <https://www.infomoney.com.br/colunistas/professor-baroni/evolucao-da-industria-de-fundos-imobiliarios-onde-estavamos-e-para-onde-vamos/>. Acesso em: 12 de maio de 2025.

BREIMAN, Leo. Random forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.

B3. **Uma análise da evolução dos investidores na B3**. Dezembro de 2024. Disponível em: <https://www.b3.com.br/data/files/92/17/8E/B7/E232591029BEEC39AC094EA8/Book%20Peessoa%20Fisica%20-%204TRI%202024.pdf>. Acesso em: 12 de maio de 2025.

CATROCCHIO, Andre Luiz Segurado. **Como foi o surgimento dos Fundos de Investimento Imobiliário no mercado de capitais brasileiro**. EXAME, 2024. Disponível em: <https://exame.com/bussola/como-foi-o-surgimento-dos-fundos-de-investimento-imobiliario-no-mercado-de-capitais-brasileiro/>. Acesso em: 12 de maio de 2025.

CVM. **Guia CVM do investidor: Fundos de Investimento Imobiliário**. Rio de Janeiro: Comissão de Valores Mobiliários, 2015.

DAS CUBERO, Bruno Souza; DA COSTA VIANA, Sandramara Aparecida; DE AGUIAR, Heraldo Márcio; DE AZEVEDO, Viviane Elisabete Ramalho. Um estudo sobre investimentos em fundos imobiliários como complemento para a construção de uma renda passiva na aposentadoria. **South American Development Society Journal**, v. 10, n. 28, 2024.

ECONOMATICA. **Indústria de Fundos Imobiliários no Brasil: Evolução do Valor de Mercado, Dividend Yield e Preço / Valor patrimonial**. 2023. Disponível em: <https://insight.economatica.com/industria-de-fundos-imobiliarios-no-brasil/>. Acesso em: 12 de maio de 2025.

KUMAR, Sunil; BHATNAGAR, Vaibhav. A review of regression models in machine learning. *Journal of Intelligent Systems and Computing*, v. 3, n. 1, p. 40-47, 2022.

LEE, Chee Sun; CHEANG, Peck Yeng Sharon; MOSLEHPOUR, Massoud. Predictive analytics in business analytics: decision tree. **Advances in Decision Sciences**, v. 26, n. 1, p. 1-29, 2022.

LUNDBERG, Scott M.; LEE, Su-In. A unified approach to interpreting model predictions. **Advances in neural information processing systems**, v. 30, 2017.

MOLNAR, Christoph. **Interpretable machine learning – A Guide for Making Black Box Models Explainable**. 2. ed., 2023. Publicação online disponível em: <https://christophm.github.io/interpretable-ml-book/index.html>. Acesso em: 08 de maio de 2025.

REIS, Tiago. **Taxa de vacância: entenda como ela afeta os fundos imobiliários (FII)**. Suno Research, 2023. Disponível em: <https://www.suno.com.br/artigos/taxa-de-vacancia/>. Acesso em 12 de maio de 2025.

SADORSKY, Perry. A random forests approach to predicting clean energy stock prices. **Journal of Risk and Financial Management**, v. 14, n. 2, p. 48, 2021.

SARKER, Iqbal H. Machine learning: Algorithms, real-world applications and research directions. **SN Computer Science**, v. 2, n. 3, p. 160, 2021.

SCOLESE, Daniel; BERGMANN, Daniel Reed; DA SILVA, Fabiana Lopes; SAVOIA, José Roberto Ferreira. Análise de estilo de fundos imobiliários no Brasil. **Revista de Contabilidade e Organizações**, v. 9, n. 23, p. 24-35, 2015.

ZHENG, Jiajian; XIN, Duan; CHENG, Qishuo; TIAN, Miao; YANG, Le. The random forest model for analyzing and forecasting the us stock market in the context of smart finance. **arXiv preprint arXiv:2402.17194**, 2024.