

idp

idn

# MESTRADO PROFISSIONAL EM ECONOMIA

---

**FATORES DINÂMICOS APLICADO AO MERCADO DE  
FUNDOS IMOBILIÁRIOS**

**FABIANO NOGUEIRA ALVES**

Brasília-DF, 2021

**FABIANO NOGUEIRA ALVES**

## **FATORES DINÂMICOS APLICADO AO MERCADO DE FUNDOS IMOBILIÁRIOS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Economia (área de concentração: Finanças), como parte dos requisitos necessários para a obtenção do Título de Mestre em Economia.

### **Orientador**

Professor Doutor Adonias Evaristo Da Costa Filho

Brasília-DF 2021

**FABIANO NOGUEIRA ALVES**

## **FATORES DINÂMICOS APLICADO AO MERCADO DE FUNDOS IMOBILIÁRIOS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Economia (área de concentração: Finanças), como parte dos requisitos necessários para a obtenção do Título de Mestre em Economia.

Aprovado em 21 / 10 / 2021

### **Banca Examinadora**

---

Prof. Dr. Adonias Evaristo Da Costa Filho - Orientador

---

Prof. Dr. José Luis Rossi Junior

---

Prof. Dr. Diego Martins

---

A474f Alves, Fabiano Nogueira  
Fatores dinâmicos aplicado ao mercado de fundos imobiliários / Fabiano  
Nogueira Alves. – Brasília: IDP, 2021.

64 p. : il. color.  
Inclui bibliografia.

Trabalho de Conclusão de Curso (Dissertação) – Instituto Brasileiro de  
Ensino, Desenvolvimento e Pesquisa – IDP, Curso de Mestrado profissional  
em Economia, Brasília, 2021.

Orientador: Prof. Dr. Adonias Evaristo Da Costa Filho.

1. Fundos imobiliários. 2. Previsão. 3. Fatores dinâmicos. 4. Modelagem. I.  
Título.

CDD 332

---

Ficha catalográfica elaborada pela Biblioteca Ministro Moreira Alves  
Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa

## DEDICATÓRIA

*Ao nosso Deus.*

## AGRADECIMENTOS

Agradeço ao meu orientador, Adonias Evaristo da Costa Filho, por todos os conselhos, pela paciência e ajuda nesse período.

Aos meus amigos Alexandre, Allan e Mathias, que percorremos juntos o período de estudo, esforço e empenho para a conclusão deste curso.

Aos professores Gustavo Guimarães, Guilherme Resende e Felipe Salto, pela prazerosa disseminação do conhecimento, que transformaram horas aula em eventos qualitativos de aprendizado e crescimento profissional.

À FUNCEF, pelo apoio financeiro para realização deste trabalho de pesquisa.

À minha Mãe e ao meu Pai, um agradecimento especial por todos os ensinamentos e incentivos para a continuidade das minhas conquistas acadêmicas. Pela dedicação de suas vidas aos seus quatro filhos.

À minha amada esposa, Anna Carolina, por todo o apoio nos quase 700 dias de vigência deste projeto.

À minha princesa, Mariana, por fornecer o maior combustível que a humanidade desfruta, o amor incondicional. Mesmo sem entender, és fonte abundante de motivação para as superações que possam me tornar um pai melhor, admirado e que seja exemplo.

## RESUMO

Na última década, as pesquisas sobre análise e previsão de investimentos cresceram exponencialmente. Neste contexto, os estudos expandiram a forma de considerar o comportamento dos dados, decompondo seus efeitos aleatórios ao longo do tempo, e, um dos modelos que tratou desta decomposição foi o modelo de fatores dinâmicos. O objetivo da presente dissertação foi de aplicar o Modelo de Fatores Dinâmicos para extrair fatores comuns de fundos de investimentos imobiliários (FIIs) no período de 2013 a 2019. Os valores utilizados foram de fechamentos mensais das quotas dos fundos e também subconjunto divididos entre fundos de tijolo e de papel. Para a análise, foram elaborados modelos de fatores dinâmicos utilizando como variável explicativa indicadores econômicos e de mercado, as variáveis dependentes foram os principais fatores extraídos a partir da análise de componentes principais para 78 fundos selecionados, os modelos foram estimados por OLS (Ordinary Least Squares). Os resultados mostraram que a presente pesquisa foi inédita a partir do escopo e da determinação dos modelos de análise, além da variedade de variáveis utilizadas. O principal indicador do mercado do FIIs é o IFIX, e nos três modelos estimados, o IFIX foi significativo, porém, seu efeito marginal foi negativo, um resultado pouco intuitivo. O Índice de Preços medido pelo IPCA foi significativo nos três modelos, porém, seu efeito é negativo para os FIIs, ou seja, um aumento marginal diminui os fatores comuns que determinam os retornos dos FIIs. Para o câmbio medido pela relação real/dólar o resultado teve efeito significativo nos fatores comuns para os três modelos estimados, e seu efeito marginal foi negativo, que é intuitivo ao pensar que o dólar é também um investimento concorrente. Os índices NTN, IMAB, IVG e Fipe apresentaram resultados significantes estatisticamente, para o NTN o efeito marginal foi sempre positivo nos três modelos estimados, o IMAB somente para o modelo 1, o IVG para os modelos 2 e 3 e o Fipe teve efeito negativo marginalmente. O estudo trouxe como principal achado que a maior parte dos retornos é dado por componentes idiossincráticos, que o modelo de fatores dinâmicos é um método que pode ser aplicado como forma de previsão, e, indicadores de mercado são mais importantes para prever FIIs que índices econômicos.



Palavras-chaves: Previsão. Modelagem. Fundos Imobiliários. Fatores Dinâmicos.





## ABSTRACT

In the last decade, research on investment analysis and forecasting has grown exponentially. In this context, the studies expanded the way to consider the behavior of data, decomposing its random effects over time, one of the models that dealt with this decomposition was the dynamic factors model. The objective of this dissertation was to apply the Dynamic Factors Model to extract common factors of real estate investment funds (FII) in the period from 2013 to 2019. The values used were from monthly closing of fund quotas and also subsets divided between funds brick and paper. For the analysis, dynamic factor models were developed using economic and market indicators as the explanatory variable, the dependent variable were the main factors extracted from the principal component analysis for 78 selected funds, the models were estimated by OLS (Ordinary Least Squares). The results showed that this research was unprecedented based on the scope and determination of the analysis models, in addition to the variety of variables used. The main indicator of the FII market is the IFIX, and in the three estimated models, the IFIX was significant, however, its marginal effect was negative, a result not very intuitive. The Price Index measured by the IPCA was significant in the three models, however, its effect is negative for the FII, that is, a marginal increase reduces the common factors that determine the returns of the FII. For the exchange rate measured by the real/dollar ratio, the result had a significant effect on the common factors for the three estimated models, and its marginal effect was negative, which is intuitive when thinking that the dollar is also a competing investment. The NTN, IMAB, IVG and Fipe indices showed statistically significant results, for NTN the marginal effect was always positive in the three estimated models, IMAB only for model 1, IVG for models 2 and 3 and Fipe had a negative effect marginally. The study brought as its main finding that most of the returns are given by idiosyncratic components, that the dynamic factors model is a method that can be applied as a form of forecasting, and market indicators are more important to predict FII than economic indices.

**Keywords: Prediction. Modeling. Real Estate Funds. Dynamic Factors.**



## **LISTA DE ABREVIATURAS E SIGLAS**

ABNT	Associação Brasileira de Normas Técnicas
AbnTeX	Normas para Tex



## LISTA DE ABREVIATURAS E SIGLAS

Γ	Letra grega Gama
Λ	Lambda
ζ	Letra grega minúscula zeta
€	Pertence

## LISTA DE ILUSTRAÇÕES

<b>Figura 1</b> Trajetória dos Fatores	<b>34</b>
<b>Figura 2</b> Percentual de Variância	<b>35</b>
<b>Figura 3</b> Índice de Fatores Estimados	<b>36</b>
<b>Figura 4</b> ICR1	<b>55</b>
<b>Figura 5</b> ICR2	<b>56</b>
<b>Figura 6</b> ICR3	<b>56</b>
<b>Figura 7</b> nowcasting PIB	<b>60</b>
<b>Figura 8</b> nowcasting IFIX	<b>60</b>
<b>Figura 9</b> nowcasting IBOV	<b>61</b>
<b>Figura 10</b> nowcasting IPCA	<b>61</b>
<b>Figura 11</b> nowcasting IGPM	<b>62</b>
<b>Figura 12</b> nowcasting Câmbio	<b>62</b>
<b>Figura 13</b> nowcasting NTN-B	<b>63</b>
<b>Figura 14</b> nowcasting IMA-B	<b>63</b>

## LISTA DE TABELAS

### **Tabela 1**

Dados

27

### **Tabela 2**

Resultados do PCA

35

### **Tabela 3**

Resultados do Modelo 1

37

### **Tabela 4**

Resultados do PCA - FIIs de Tijolo

39

### **Tabela 5**

Resultados do PCA - FIIs de Papel

39

### **Tabela 6**

Resultados do Modelo 2 - FII Tijolo

40

### **Tabela 7**

Resultados do Modelo 3 - FII Papel

42

### **Tabela 8**

Resultados IC

55

### **Tabela 9**

Dados FII

57

### **Tabela 10**

Dados FII – continuação

58

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
<b>2</b>	<b>REVISÃO DA LITERATURA</b>	<b>20</b>
2.1	Fundos de Investimento Imobiliário	21
2.2	MFD com séries de preço e de retorno de ativos	22
<b>3</b>	<b>METODOLOGIA</b>	<b>26</b>
3.1	Dados	26
3.2	Modelo de Fatores Dinâmicos	28
3.3	Análise de Componentes Principais - PCA	29
3.3.1	Determinação dos Fatores	31
3.3.2	Métrica de comparação para os modelos de previsão	32
<b>4</b>	<b>RESULTADOS</b>	<b>34</b>
4.1	Fatores Comuns	34
4.2	Estimação dos Modelos	36
4.2.1	Resultados Empíricos do Modelo 1	37
4.2.2	Resultados Empíricos do Modelo 2	38
4.2.3	Resultados Empíricos do Modelo 3	41
4.2.4	Discussão dos resultados	43
<b>5</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>46</b>
	Referências	47
	Anexo A – ANEXO	55
	Anexo A.1 Índice de Fatores (IC) e IC shocks	55
	Anexo A.2 Dados	57
	Anexo A.3 Script RStudio	59
	Anexo A.4 Resultados dos Nowcasting	60



## 1

## INTRODUÇÃO

Após a crise financeira mundial em 2009 as pesquisas sobre processos estocásticos e modelos de fatores dinâmicos cresceram exponencialmente, principalmente nos estudos relacionados à macroeconometria, que tentam modelar a dinâmica das variáveis para entender e prever crises ou movimentos extremos antes que eles aconteçam.

Esse crescimento se deve pelo menos a dois pontos importantes: i) aos estudos que investigam a dinâmica de fatores não observáveis e muitas vezes responsáveis pelo comportamento da dinâmica de séries temporais; e ii) pela flexibilidade que esses modelos de fatores dinâmicos possuem para analisar grandes dimensões de dados. Essas duas características podem auxiliar na determinação de comovimentos que são precedentes a eventos aleatórios e extremos.

Os modelos conhecidos como MFD, ou seja, modelos de fatores dinâmicos, permitem capturar a dinâmica da série de interesse a partir da fonte comum de variação da própria série ou de variáveis de interesse. O MFD vem sendo utilizado para análise da atividade econômica e modelagem de previsão, além disso, se o número de variáveis for superior ao número de observações, não é possível estimar coeficientes em modelos paramétricos tradicionais.

Por outro lado, mesmo que seja possível estimar os coeficientes, não é apropriado introduzir um número muito elevado de variáveis nos modelos, pois, isto pode gerar *overfitting*, o que tende a produzir previsões bastante imprecisas. Uma solução comumente adotada é utilizar um modelo com fatores, que busca reduzir o conjunto de informações (variáveis) a uma fonte de variação comum entre elas. Em geral, essa fonte de variação comum é não-observável.

A ideia, portanto, é utilizar um conjunto de variáveis relacionadas a essa fonte e, ao extrair o componente de variação comum entre elas, obter uma aproximação desta fonte não-observável. A literatura empírica utiliza o modelo de fatores dinâmicos em geral para



acompanhar a evolução da atividade econômica em tempo real, há poucos trabalhos que experimentaram analisar variáveis de mercado financeiro e entender se, ao extrair o componente de variação comum, esse componente pode ser uma medida indireta da atividade econômica ou de outras dinâmicas econômicas. Com estas informações disponíveis no instante  $t$ , pode ser possível acompanhar a atividade econômica também em  $t-1$ , o que é chamado na literatura por um *Nowcast*. O *Nowcasting* é definido como a previsão do presente, do futuro muito próximo e do próprio passado recente. O termo é uma contração para agora (*now*) e previsão (*forecasting*) e tem sido usado por um longo tempo em meteorologia e recentemente também em economia [Giannone, Reichlin e Small \(2008a\)](#).

Neste contexto, a presente dissertação tem por objetivo aplicar o Modelo de Fatores Dinâmicos em séries de retornos de fundos imobiliários (FIIs), de forma a estimar a influencia de variáveis macroeconômicas e índices de mercado nos fatores comuns. Como objetivos específicos foram criados subamostras dos FIIs que se caracterizam como Tijolo e Papel, esses fundos de tijolo são representados por imóveis físicos: lojas e supermercados; agências bancárias; shoppings; galpões e outros. Por outro lado, os fundos de recebíveis ou de papel são formados por títulos ou valores mobiliários ligados ao setor imobiliário.

O campo empírico de estudo é constituído por um conjunto de 99 Fundos Imobiliários pertencentes à B3. Em dezembro de 2020, a classe de FIIs na B3 contava com 537 Fundos registrados pela CVM, sendo que 301 estavam listados, disponíveis para comercialização na bolsa, que somavam R\$ 124 bilhões de Patrimônio Líquido. O período de abordagem da análise foi de 2013 a 2019, utilizando os valores de fechamento mensal das quotas dos fundos. Para a análise, o desafio foi obter os principais fatores dinâmicos dos FIIs e estimar modelos a partir de variáveis macroeconômicas e índices de mercado.

A pesquisa foi elaborada seguindo os passos do trabalho desenvolvido por [Valk, Mattos e Ferreira \(2019\)](#), que são os autores do pacote *Nowcasting* e desenvolveram os algoritmos na linguagem de programação *R* para estimar e prever variáveis econômicas usando Modelos de Fatores Dinâmicos. Os pesquisadores utilizaram como base o estudo de [Giannone, Reichlin e Small \(2008a\)](#) e [Stock e Watson \(2016\)](#).

Para desenvolver a análise foram estimados os fatores a partir de Componentes Principais (PCA) e pelo IC - Indicador de fatores do pacote *Nowcasting*. Em seguida, foram ajustados os modelos de regressão linear múltipla com os dois principais fatores das séries dos retornos dos fundos imobiliários como variável dependente e as variáveis econômicas como IBOV, IPCA, IGPM, Câmbio, IFIX, NTN-B, IMA-B, IVG-R, MVG-R e Fipe como variáveis explicativas.

Para complementar a análise, o conjunto de dados dos retornos dos FIs, foram separados entre FIs de Tijolo e FIs de Papel, e estimados com os indicadores do mercado imobiliário. As análises foram realizadas pelo software *R*, e seus códigos estão no anexo da dissertação.

Para o alcance do objetivo, a presente pesquisa está dividida nesta introdução, na revisão da literatura, na seção de metodologia e na análise dos resultados.



?

## 2

## REVISÃO DA LITERATURA

A partir da década de 1980 inúmeras pesquisas analisaram a dependência e o padrão do co-movimento entre as bolsas de valores no mundo. Começaram a testar vários métodos estatísticos e da econofísica, porém, a primeira corrente da literatura influenciada por [Geweke \(1977\)](#) procurou analisar a dinâmica desse co-movimento verificando a correlação entre os diversos mercados, conforme [Furstenberg et al. \(1989\)](#), [Bertero e Mayer \(1990\)](#), [Hamao, Masulis e Ng \(1990\)](#), [Ng, Engle e Rothschild \(1992\)](#) e [Cheung e Ng \(1993\)](#).

A literatura foi evoluindo para a ideia de encontrar uma solução baseada em um modelo com fatores. Mais especificamente, um fator ou fatores que buscam reduzir o conjunto de informações a uma fonte de variação comum entre elas. Em geral, essa fonte de variação comum é não-observável, e chamada de fatores latentes não observados. Neste contexto, o objetivo é utilizar um conjunto de variáveis relacionadas a essa fonte e, ao extrair o componente de variação comum entre elas, obter uma aproximação desta fonte não-observável. Essa corrente de análise e da literatura apareceu em pesquisas sobre busca de tendências estocásticas comuns e verificação à transmissão de choques entre os mercados, [Johansen \(1988\)](#), [Blackman, Holden e Thomas \(1994\)](#), [Masih e Masih \(1997\)](#) e [Eun e Shim \(1989\)](#), que apresentaram evidências de uma tendência estocástica comum entre bolsas de valores de países desenvolvidos e em desenvolvimento.

O MFD é utilizado para análise e comparação da atividade econômica [Nowcasting... \(2007\)](#), [Giannone, Reichlin e Small \(2008b\)](#), e modelagem de previsão, desde [Sargent, Sims et al. \(1977\)](#) as análises de fatores dinâmicos são capazes de explicar variáveis como PIB, desemprego, preços, dentre outras.

Com o MFD é possível acompanhar a evolução da atividade econômica, com a premissa de que sabemos que uma série de variáveis é afetada ou afeta a atividade econômica, embora em direções e magnitudes possivelmente distintas. O princípio da análise é de extrair o componente de variação comum entre estas variáveis, no presente estudo, essas variáveis são os Fundos Imobiliários disponíveis no

mercado e assim identificar a influência das variáveis econômicas na dinâmica dos comovimentos. Estimulada por essa ideia, a presente pesquisa busca realizar uma análise de previsão para Fundos Imobiliários. Com esse objetivo e auxílio da literatura para esse problema, pode ser possível, então, reunir essas informações, extrair fatores e obter previsões. De início, serão utilizados os próprios fundos para fazer a análise e no seguinte momento inserir variáveis macroeconômicas, como por exemplo medidas de inflação, atividade econômica e confiança dos agentes, utilizando o método de Componentes Principais (PCA).

## 2.1 FUNDOS DE INVESTIMENTO IMOBILIÁRIO

O Fundo de Investimento Imobiliário obteve seu processo normativo publicado a partir da Lei 8.668 de junho de 1993 (Lei nº 8.668/93), que instituiu Fundos de Investimento Imobiliário (FII), sem personalidade jurídica, se caracterizando pela comunhão de recursos captados por meio do Sistema de Distribuição de Valores Mobiliários, na forma da Lei nº 6.385/76, destinados à aplicação em empreendimentos imobiliários.

De acordo com [Carvalho \(2019\)](#) embora os fundos imobiliários tenham sido criados em 1993, foi em 2008 que os fundos imobiliários ganharam popularidade no mercado nacional. Até 2010 os fundos desta classe de ativos financeiros tinham pouco mais de 10 mil investidores. No primeiro triênio do período analisado observamos o forte crescimento deste número. Em 2012 o total de investidores saltou de 40 mil no início do ano para 100 mil, aproximadamente.

Conforme o relatório denominado Boletim Mensal Fundos Imobiliários, emitido pela Brasil Bolsa Balcão (B3), data base dezembro/2020, total de Fundos registrados na CVM era 537, sendo 301 listados, com PL de R\$ 124 bilhões. O número de investidores no mercado brasileiro aumentou de 645 mil investidores para 1,172 milhão de investidores.

De acordo com informações e pesquisa da B3, foi identificado que mais de 1,16 milhão de investidores são Pessoas Físicas, e em 2020, o volume total negociado em bolsa foi de R\$ 53,9 bi, sendo que diariamente a movimentação média foi de R\$ 216 milhões. Passando a oferecer volumes atrativos de liquidez diária para grandes investidores

e investidores institucionais, como os fundos de pensão, que passaram a adotar a classe de Fundos Imobiliários em seus portfólios de investimentos, com a finalidade de aumentar as possibilidades de alocação em ativos que superem suas metas atuariais, diante de um cenário de baixas taxas de juros, o que inviabilizou os tradicionais investimentos em renda fixa. Por fim, observa-se que os FII's estão começando a ser utilizados para calibrar risco e retorno de carteiras de investimentos.

## 2.2 MFD COM SÉRIES DE PREÇO E DE RETORNO DE ATIVOS

A análise de séries de preço e de retorno de ativos é realizada também com o Modelo de Fatores Dinâmicos - MFD. Alguns autores vêm incorporando evidências dessas pesquisas, como [Ng, Engle e Rothschild \(1992\)](#), [Cheung e Ng \(1993\)](#), [Forni et al. \(2000\)](#), [Pagan e Soydemir \(2000\)](#), [Rocha e Sekkel \(2006\)](#), [Tabak e Lima \(2013\)](#), [Focardi, Fabozzi e Mitov \(2016\)](#) e [Conceição \(2017\)](#). Além de avaliar economias e suas atividades econômicas o MFD é utilizado em vários modelos de integração e dependência entre séries de retorno de ativos.

Os principais trabalhos desenvolveram novas abordagens a partir do arcabouço do MFD, por exemplo [Ng, Engle e Rothschild \(1992\)](#) que definem fatores dinâmicos e estáticos dos retornos em excesso de ativos financeiros. Além disso, examinam o portfólio de mercado ponderado pelo valor como um fator dinâmico e propõem um procedimento para a busca de fatores mais dinâmicos.

Na mesma linha de análise [Cheung e Ng \(1993\)](#) avaliam a importância das notícias de um país na geração da volatilidade do mercado de ações de outro país. Na análise das interações entre os índices S&P 500 e Nikkei 225 nos períodos pré e pós-crash. As evidências apresentaram contribuição das notícias dos EUA na geração da volatilidade das ações do mercado de Tóquio, mostrando que há fatores dinâmicos e eles se espalham na economia mundial.

No trabalho de [Forni et al. \(2000\)](#) os autores propõem um modelo de fator com dinâmica infinita e componentes idiossincráticos não ortogonais. O modelo foi novidade na literatura e generaliza o modelo de fator estático aproximado de [Chamberlain e Rothschild \(1983\)](#), bem como o modelo de fator exato à la [Sargent, Sims et al. \(1977\)](#). O inédito

estudo propõe, ainda, um estimador dos componentes comuns e apresenta resultados de simulações.

Outro trabalho importante é o dos autores [Pagan e Soydemir \(2000\)](#) que utilizam um modelo VAR (Vetores Auto-Regressivos) para analisar a extensão da interdependência dos mercados de ações na América Latina. Os resultados da estimativa das funções de resposta ao impulso sugerem que há fortes vínculos entre os mercados de ações do México e dos EUA, e vínculos mais fracos, porém significativos, entre os mercados de ações da Argentina, Brasil e Chile. Na mesma linha de análise, [Rocha e Sekkel \(2006\)](#) aplicaram o modelo de [Forni et al. \(2000\)](#) para 24 diferentes mercados de ações. Complementando os estudos com várias economias, mas, utilizando mercados de ativos, [Tabak e Lima \(2013\)](#) analisaram as relações de causalidade e cointegração entre os mercados de ações da América Latina e dos Estados Unidos. Em uma estrutura simples, a causalidade e a cointegração são testadas para Argentina, Brasil, Chile, Colômbia, México, Peru, Venezuela e Estados Unidos. Os autores não encontraram evidências de cointegração entre esses mercados de ações, mas a causalidade de curto prazo não pôde ser rejeitada. Para o Brasil, [Felício e Júnior \(2014\)](#) examinaram a utilidade de modelos fatoriais na análise da dinâmica da taxa de câmbio Real / Dólar.

[Focardi, Fabozzi e Mitov \(2016\)](#) apresentaram uma nova estratégia de arbitragem estatística baseada em modelos de fator dinâmico de preços. Os autores exploraram as propriedades de reversão à média dos preços relatadas na literatura. Para testar empiricamente o desempenho relativo dos modelos baseados no retorno e no preço, construíram carteiras (long-short, long-only e igualmente ponderadas) com base nas previsões geradas por dois modelos de fatores dinâmicos.

Usando as ações das empresas incluídas no índice S&P 500 para a construção de carteiras, os principais resultados mostraram que os preços permitem previsões significativamente mais precisas do que os retornos e passam no teste de arbitragem estatística. Utilizando dados do IBOVESPA, [Conceição \(2017\)](#) usou modelos de fatores dinâmicos para o mercado financeiro a partir de preços de ações, com base em [Stock e Watson \(2016\)](#) e [Focardi, Fabozzi e Mitov \(2016\)](#). Para o autor, ao se utilizar as previsões feitas pelos modelos, é possível criar estratégias de trading cuja performance pode ser aferida, de posse dos

preços de fechamento de ativos pertencentes ao IBX100 no período de 2010 até 2016.

A maioria dos trabalhos até aqui pesquisados utilizaram a análise de componentes principais - PCA para estimar o fator comum. [Chamberlain e Rothschild \(1983\)](#) sugeriram o uso do PCA para estimar o modelo de fator estático aproximado, e [Stock e Watson \(1988\)](#); [Stock e Watson \(2002\)](#) e [Bai e Ng \(2002\)](#) popularizaram essa abordagem em macroeconometria. Duas das principais tarefas que os pesquisadores enfrentam ao lidar com MFD é estimar o número de fatores comuns, bem como, a estimativa dos fatores latentes. Algumas referências conhecidas sobre a consistência do estimador de Componente Principal são [Connor e Korajczyk \(1986\)](#), [Forni e Reichlin \(1998\)](#), [Forni et al. \(2000\)](#), [Bai \(2003\)](#), [Bai e Ng \(2006\)](#) e [Stock e Watson \(2011\)](#).

[Soto \(2016\)](#) e [Conceição \(2017\)](#) utilizaram a modelagem de fatores dinâmicos e PCA para definir fatores comuns no mercado de ações brasileiro, [Carvalho \(2019\)](#) modelou e analisou fatores para o índice IFIX. A presente pesquisa pretende fazer uma análise mais desagregada, com vários fundos imobiliários, e essa modelagem, ainda não foi explorada, sendo, assim, a contribuição deste trabalho.





3



# 3

## METODOLOGIA

Esta seção apresenta o campo empírico de estudo, o banco de dados e os procedimentos metodológicos para estimar as análises pretendidas. A estimação do Modelo de Fatores Dinâmicos, bem como o estimador via Análise de Componentes Principais e os critérios de informações conhecidos na literatura como AIC e BIC.

### 3.1 DADOS

O campo empírico de estudo foi constituído, inicialmente, por um conjunto de 93 Fundos Imobiliários pertencentes à B3. O período de coleta para a análise foi de 2013 a 2019, utilizando os valores de fechamento mensal das quotas dos fundos. Para organização da base de dados, 15 Fundos de Investimentos Imobiliários - FII foram retirados da análise por não ter negociações de cotas em um total de dias inferior a 70% dos dias analisados. Assim, foram retirados os Fundos (ANCR / AQLL / ATSA / CXTL / DRIT / FIVN / FMOF / FVPQ / HMOC / LATR / PABY / RBED / REIT / RMAI / SAIC). Outra observação importante foi que os dados são da posição de fechamento diário de cada FII listado - Ajustado, assim, em dia sem comercialização foi replicado o valor do fechamento da cota do dia anterior.

Para a estimação dos fatores foram utilizados os 78 FIIs selecionados, que estão apresentados na [Tabela 2](#) e [Tabela 3](#) no Anexo. Para analisar a relação entre os Principais Fatores (PCA) e variáveis econômicas/mercado financeiro, foram utilizados os seguintes indicadores: IFIX que é o Índice de Fundos Imobiliários, IPCA - Índice de Preços para o Consumidor Amplo, IGPM - Índice Geral de Preços, Câmbio (Dólar), NTN-B - Notas do Tesouro Nacional - tipo B, IMA-B - Indicador da Anbima, é um índice que representa o desempenho de uma carteira de títulos públicos federais, IBOV - o índice da Bovespa, IVG-R - Índice de Valores de Garantia de Imóveis Residenciais Financiados, MVG-R - Mediana dos Valores de Garantia de Imóveis Residenciais Financiados e Fipe (Fipezap) que são os preços imobiliários.

Os resultados foram estimados utilizando o software *R* e o pacote nowcasting, além disso foram comparados os resultados das previsões com os indicadores de acurácia mais conhecidos na literatura.<sup>1</sup>

As variáveis são transformadas em log-retorno, pois, a normalização dos dados melhora as estimativas utilizadas. O pacote nowcasting faz a transformação dos dados no processo e no passo a passo para estimar o modelo de fatores dinâmicos. A equação de log-retorno ( $r$ ) utilizada é  $r = \ln(1 + R)$ , onde  $R$  é o retorno linear e  $\ln$  o logaritmo natural. Na [Tabela 1](#) relaciona as variáveis utilizadas e o formato dos dados.

Tabela 1 - Dados			
Variável	Formato	Transformação	Período
FII5	Valor de Fechamento	Log-retorno	2013-2019
PIB	Em milhões R\$	Log-retorno	2013-2019
IFIX	Valor de Fechamento	Log-retorno	2013-2019
IBOV	Valor de Fechamento	Log-retorno	2013-2019
IPCA	Taxa Mensal	Variação	2013-2019
IGPM	Taxa Mensal	Variação	2013-2019
Câmbio (Dólar)	Valor de Fechamento	Variação	2013-2019
NTN-B	Valor de Fechamento	Log-retorno	2013-2019
IMA-B	Valor de Fechamento	Log-retorno	2013-2019
IVG-R	Valor de Fechamento	Log-retorno	2013-2019
MVG-R	Valor de Fechamento	Log-retorno	2013-2019
FipeZap	Índice de Preços Imóveis	Log-retorno	2013-2019
FII5	Valor de Fechamento	Log-retorno	2013-2019

O pacote criado por [Valk, Mattos e Ferreira \(2019\)](#) de previsão a curto prazo contém ferramentas úteis para o uso de modelos de fator dinâmico. É possível estimar os métodos baseados nos artigos de [Giannone, Reichlin e Small \(2008a\)](#) e [Bańbura et al. \(2013\)](#), e suas

<sup>1</sup> <https://cran.r-project.org/web/packages/nowcasting/nowcasting.pdf>

funções auxiliares foram desenvolvidas para tratar variáveis, construir séries e visualizar resultados.<sup>2</sup>

### 3.2 MODELO DE FATORES DINÂMICOS

A ideia principal do MFD é que os co-movimentos de um vetor  $N$ -dimensional da série temporal  $y_t$  pode ser explicado pela soma de dois componentes mutuamente ortogonais não observados: o componente comum que tem um efeito penetrante sobre todas as variáveis em  $y_t$ , e o componente idiossincrático ou ruído, que é específico para cada variável de série temporal.

Os modelos sobre MFD distinguem duas representações em termos do comportamento dinâmico dos fatores comuns latentes. O modelo de Fatores Dinâmicos foi originalmente proposto por [Geweke \(1977\)](#) e [Sargent, Sims et al. \(1977\)](#) e a representação padrão, que é conhecida como representação estática ou empilhada, introduz os fatores latentes  $f_t$ , que está representada na Equação 3.1 contemporaneamente, e a representação dinâmica que leva em consideração o efeito atual, bem como as defasagens dos fatores comuns [Stock e Watson \(2016\)](#).

Conforme [Stock e Watson \(2016\)](#), os co-movimentos de um vetor  $N$ -dimensional de variáveis de série temporal,  $y_t$ , são explicados pela soma de dois componentes latentes:  $\Delta f_t$  e  $e_t$ , onde  $\Delta f_t$  é o componente comum,  $f_t$  é um vetor  $r \times 1$  de fatores comuns,  $\Lambda$  é uma matriz  $N \times r$  de cargas fatoriais, e  $e_t$ , é o componente idiossincrático, um vetor  $N \times 1$  de distúrbios ou erros idiossincráticos.

Além disso, os fatores seguem processos em séries temporais, que geralmente tem sido assumido como sendo uma autorregressão vetorial, VAR( $p$ ), onde  $p$  é o grau da matriz polinomial  $\Phi(L) = (I - \varphi_1 L - \dots - \varphi_p L^p)$  [Forni et al. \(2000\)](#). Onde,  $\eta_t$  é um vetor  $r \times 1$  ruído branco gaussiano com matriz  $\Sigma_\eta$  de covariância positiva e finita, que é independente da idiossincrática de erros  $e_t$ , ou seja,  $E e_t \eta_{t-k} = 0$  para todo  $k$ .

---

<sup>2</sup> Para usar a função nowcast, precisamos de variáveis estacionárias. Isso pode ser feito usando uma função do próprio pacote. Esta função cria um painel balanceado usando um painel não balanceado como entrada. A opção padrão é substituir observações ausentes e outliers usando a metodologia decorreção de outlier de [Giannone, Reichlin e Small \(2008a\)](#)

$$\mathbf{y}_t = \Lambda \mathbf{f}_t + \mathbf{e}_t \quad (3.1)$$

$$\Phi(L)\mathbf{f}_t = \eta_t \quad (3.2)$$

Na Equação 3.1, deve ser estimada com a informação contida no vetor  $N$ -dimensional  $y_t$ . É importante considerar as seguintes suposições gerais sobre os fatores  $\mathbf{f}_t$ , o fator de carregamento na matriz  $\Lambda$ , e os erros idiossincráticos  $\mathbf{e}_t$ , seguindo Stock e Watson (2002). Para evitar o problema de identificação, dado que para qualquer matriz não singular  $A$ ,  $\Lambda \mathbf{f}_t = \Lambda A A^{-1} \mathbf{f}_t$ , assume-se que:

$E(\mathbf{f}_t \mathbf{f}_t^j) = \Sigma_{ff}$ , onde  $\Sigma_{ff}$  é uma matriz diagonal com elementos  $\sigma_{ii} > \sigma_{ij} > 0$  para  $i < j$ , o que significa que os fatores podem apresentar autocorrelação.

Os fatores serão identificados até uma mudança de sinal dado que a matriz  $A$  é restrita a ser diagonal com elementos de  $\pm 1$ . Este formato é mais recomendado para a utilização da análise de componentes principais. É assumido que as séries  $\mathbf{e}_t$  e  $\eta_t$  não são correlacionadas em qualquer lag (defasagem utilizada para a previsão), ou seja,  $E[e_{tn_{t-k}}] = 0$  para todo  $K$  e  $E[e_t e_{t-k}^j] = 0$  para todo  $K$ . Para o caso de séries não estacionárias, Navarro e Rivera (2018) mostram que o modelo descrito pelas equações 3.1 e 3.2 pode ser utilizado com séries de log-retornos e log-preços, que é fracamente estacionária.

Neste contexto, na próxima seção é apresentado o estimador PCA, que em Bai e Ng (2008) são encontradas suas aplicações quando se consideram processos estocásticos multidimensionais com um grande número de observações, dentre elas, a obtenção de tendências comuns, que seriam uma releitura dos dados de maneira a identificar padrões gerais Conceição (2017).

### 3.3 ANÁLISE DE COMPONENTES PRINCIPAIS - PCA

Nesta seção o desafio é estimar o número de fatores comuns  $r$ , bem como, a estimativa do espaço de carregamento fatorial  $M$  ( $\Lambda$ ) e os fatores latentes comuns  $f_t$ . Na presente análise, o interesse está na estimativa do componente comum e assume-se que o número de fatores comuns  $r$  é conhecido. Especificamente,

prestamos atenção em uma das metodologias mais aplicadas em problemas de redução de dimensão, Análise de Componente Principal (PCA). Algumas referências bem conhecidas sobre a consistência dos estimadores de Componente Principal são [Forni e Reichlin \(1998\)](#), [Forni et al. \(2000\)](#) e [Bai \(2003\)](#); [Bai e Ng \(2006\)](#).

[Stock e Watson \(2011\)](#) resumem as diferentes metodologias dentro da estimativa no domínio do tempo de MFD em três gerações. A primeira geração aplicou a Máxima Verossimilhança Gaussiana (Gaussian Maximum Likelihood - MLE) e o filtro de Kalman para estimar modelos paramétricos de baixa dimensão. A segunda geração considerou métodos transversais de média para estimar modelos não paramétricos de alta dimensão. A terceira geração combina ambos modelos, usando as estimativas não paramétricas consistentes de fatores (segunda geração) na estimativa do modelo de espaço de estados (primeira geração), obtendo as estimativas de parâmetro.

Neste trabalho seguimos os métodos de média de seção transversal, o vetor  $\mathbf{f}_t$  é considerado um parâmetro  $r$ -dimensional a ser estimado usando a média da seção transversal de  $\mathbf{y}_t$ . Portanto, o estimador de  $\mathbf{f}_t$ ,  $\hat{\mathbf{f}}_t$ , é obtido como a média ponderada de  $\mathbf{y}_t$  usando uma matriz não aleatória de pesos  $W$ , que é normalizado de modo que  $WW' / N = I_r$ . O estimador de componente principal define  $W = \hat{\Lambda}$ , onde  $\hat{\Lambda}$  é a matriz de autovetores em escala associados aos  $r$  maiores autovalores da matriz de covariância de amostra  $M$  descrito abaixo, e os fatores são calculados como  $\hat{\mathbf{f}}_t = \hat{\Lambda}' \mathbf{y}_t$ , os primeiros  $r$  componentes principais escalados de  $\mathbf{y}_t$  e este estimador é consistente sob a estrutura de erro geral, conforme mostrado em [Stock e Watson \(2011\)](#).

Seguindo [Bai e Ng \(2002\)](#) e [Conceição \(2017\)](#) optou-se pela escolha do critério ICP2, pois, de acordo com os autores é adequado para o formato dos dados utilizados nesta pesquisa. A proposta de [Pena e Box \(1987\)](#), fornece a estimativa mais precisa de  $\hat{\Lambda}$ , em termos de tamanho de amostra  $T$ , dimensão de série temporal  $N$ , bem como, o número de defasagens  $k_0$  considerando a função  $V(k, F^k$ , especificada na equação 3.3

$$V(k, F^k) = \min_{\Lambda} \frac{1}{NT} \sum_{i=1}^N \sum_{t=1}^T (X_{it} - \lambda_i^k F_i^k)^2 \quad (3.3)$$

Onde,  $K$  é o número de fatores. Para um determinado  $K$  existem múltiplas soluções para esse problema, e independente da normalização escolhida, o valor de  $V(k, F^k)$  permanece o mesmo. Com esse valor calculado o critério ICP2 é determinado por,

$$ICP2(k) = \log(V(k, F^k)) + k \left( \frac{N+T}{NT} \right) \log(C_{NT}^2) \quad (3.4)$$

com  $C_{NT}^2 = \log(\min(N, T))$ . O número de fatores escolhidos pelo critério ICP2 é um  $k$  tal que a função  $V(k, F^k)$  tem o menor valor. De acordo com [Conceição \(2017\)](#) a partir da análise de [Connor e Korajczyk \(1986\)](#), a dinâmica dos fatores, descrita na equação 3.2, é um processo VAR( $p$ ), cujo número de lags  $p$  pode ser estimado utilizando os critérios de informação de Akaike (AIC) e Bayesiano (BIC), a partir das seguintes equações:

$$AIC = 2k - \log \hat{L} \quad (3.5)$$

e

$$BIC = k \log N - 2 \log \hat{L} \quad (3.6)$$

Onde  $\hat{L}$  é a função de máxima verossimilhança escolhida. No caso de [Conceição \(2017\)](#) o valor do lag estimado foi de  $p = 1$ .

### 3.3.1 DETERMINAÇÃO DOS FATORES

Para desenvolver a análise de componentes principais e estimar o fator comum, foi utilizado o PCA e também a análise do Índice de Fatores - IC.

$$IC_r = \ln(V(r, F^r)) + r \left( \frac{N+T}{NT} \right) \ln \left( \frac{NT}{N+T} \right)$$

Seja  $V(r, F^r)$  a soma dos resíduos quadrados quando  $r$  fatores são estimados usando componentes principais, seguindo Bai e Ng (2007).

### 3.3.2 MÉTRICA DE COMPARAÇÃO PARA OS MODELOS DE PREVISÃO

Utilizando como base de comparação o Erro Absoluto Médio (MAE), que considera a expressão análoga do erro de simulação médio com os valores absolutos como na equação:

$$MAE = \frac{1}{T} \sum_{t=1}^T |Y_t^s - Y_t^o|$$

onde, os valores baixos das medidas, informa o erro menor e o melhor modelo, quando comparado o  $Y^s$  simulado, em relação ao valor observado de  $Y_t$ , que é  $Y_t^o$ .






## 4

## RESULTADOS

Nesta seção são apresentados os resultados empíricos da análise e estimação dos modelos. Para o desenho da análise o estudo acompanhou o passo a passo realizado por [Valk, Mattos e Ferreira \(2019\)](#), que são os autores do pacote *Nowcasting* e desenvolveram algoritmos na linguagem de programação *R* para estimar e prever variáveis econômicas usando Modelos de Fatores Dinâmicos. Os pesquisadores utilizaram como base o estudo de [Giannone, Reichlin e Small \(2008a\)](#) e [Stock e Watson \(2016\)](#).

#### 4.1 FATORES COMUNS

Os fatores comuns são extraídos de um painel de 78 fundos imobiliários. Foram utilizados o PCA e o IC que apresentaram resultados idênticos independentemente do método utilizado para a identificação dos fatores, e apresentou o seguinte resultado da Figura 1.



A trajetória dos fatores mostra a volatilidade dos Fundos de Investimentos Imobiliários - FIIs, destacando alta queda em 2014


com a crise econômica, depois em 2016 com o processo de impeachment e 2017 com resultados abaixo do esperado para a economia. Em 2018 tem alta e um comportamento menos volátil no final de 2019.

A Tabela 2 apresenta os resultados da estimação dos fatores pela Análise de Componentes Principais - PCA.

Tabela 2 – Resultados do PCA					
	PC1	PC2	PC3	PC4	PC5
Standard deviation	0.04808	0.04302	0.04086	0.03944	0.09899
Proportion of Variance	0.07756	0.06211	0.05603	0.05218	0.05100
Cumulative Proportion	0.07756	0.13966	0.19569	0.24787	0.29887

Para a Análise de Componentes Principais - PCA os quatro primeiros fatores em conjunto explicam aproximadamente 24.78% da variabilidade nos dados, com os quatro fatores explicando, respectivamente, 7.75%, 13.96%, 19.56% e 24.78% da variabilidade nos dados.

A análise do número de fatores com o Índice de Fatores - IC, dado pelo algoritmo do pacote Nowcasting, apontou o primeiro componente conforme a Figura 2.

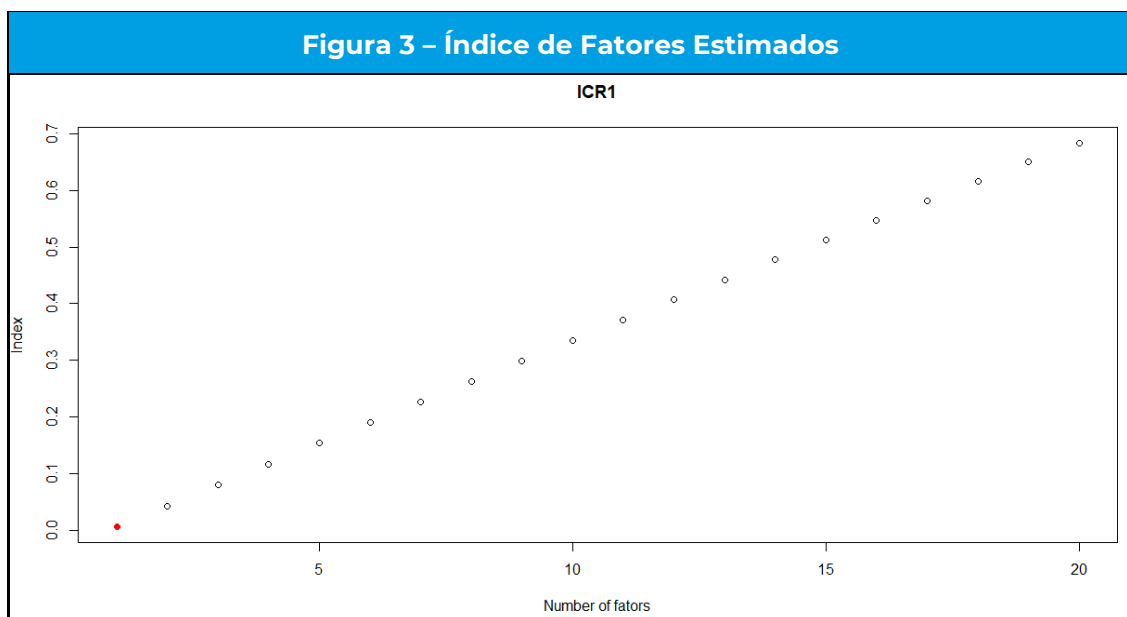


Com os fatores estimados o modelo nowcasting seleciona os parâmetros de acordo com o número  $r$  de fatores dinâmicos, a ordem de defasagem dos fatores  $p$  e o número  $q$  de choques nos fatores. Esses parâmetros foram definidos pelo algoritmo de acordo com [Giannone, Reichlin e Small \(2008a\)](#) e [Mariano e Murasawa](#)

(2003), que definiram  $r=2$ ,  $p=2$  e  $q=2$ .<sup>3</sup> O pacote permite visualizar os componentes na Figura 3.

Como as duas metodologias (PCA e IC) são semelhantes na construção da análise para identificar os co-movimentos entre retornos de séries financeiras, os resultados corroboram para novos estudos e novas comparações.

A literatura empírica identifica diferentes variáveis correlacionadas com fatores comuns que têm impacto em variáveis econômicas, porém, há poucos estudos relacionando



fundos de Investimento, e principalmente Fundos Imobiliários. Por razão dessa lacuna na literatura, realizamos a estimação de modelos distintos, com variáveis macroeconômicas e variáveis do mercado financeiro, com objetivo de explorar novos resultados e novas fronteiras de pesquisa.

## 4.2 ESTIMAÇÃO DOS MODELOS

Para estimação do nowcasting foi utilizado o pacote [Valk, Mattos e Ferreira \(2019\)](#) que permite estimar o modelo após a definição dos parâmetros e também extrai o componente preditivo.

<sup>3</sup> Foi utilizado o procedimento de [Giannone, Reichlin e Small \(2008a\)](#) que segue [Bai e Ng \(2007\)](#) e empacotado por [Valk, Mattos e Ferreira \(2019\)](#) na linguagem R. O Script do passo a passo está no anexo desta dissertação.

## 4.2.1 RESULTADOS EMPÍRICO DOS MODELOS 1

O modelo 1 foi estimado por OLS e sua equação foi caracterizada por

$$y_t = \mu + \Lambda x_t + e_t$$

onde, a variável dependente  $y_t$  é o Fator 1 na primeira estimação e o Fator 2 na segunda estimação, o  $\mu$  é o intercepto,  $x_t$  as variáveis explicativas, e  $e_t$  o erro idiossincrático. As variáveis explicativas são o IFIX, IBOV, IPCA, IGPM, Câmbio, NTN e IMAB, que são exaustivamente utilizadas na literatura específica.

O objetivo desse modelo foi analisar se os dois principais fatores comuns, ou seja, os co-movimentos extraídos dos 78 FIIIs são influenciados pela dinâmica de log-retorno das variáveis explicativas. A presente pesquisa inova em inserir variáveis econômicas e financeiras na análise, com intuito de explorar esses novos resultados e principalmente testar o modelo de fatores dinâmicos.

Os resultados da estimação estão na Tabela 3, que apresenta o modelo com Fator 1 e o modelo com Fator 2.

Tabela 3 – Resultados do Modelo 1				
Variáveis	Fator 1	p-valor	Fator 2	p-valor
(Intercept)	0.3862	0.0834.	-0.07133	0.7214
IFIX	-28.5485	0.0014**	6.21787	0.4276
IBOV	0.6641	0.8963	-1.12551	0.8074
IPCA	-0.5319	0.0090**	-0.16685	0.3560
IGPM	0.3120	0.1046	-0.15451	0.3719
Câmbio	-15.3125	0.0142*	2.90535	0.6006
NTN-B	15.1333	0.0024**	1.62930	0.7098
IMA-B	3.7982	0.0419*	-4.11188	0.0156*
R-squared	0.3544		0.1054	
P-valor	0.0000		0.2808	
-valor	0 ****	0.001 ***	0.01 **	0.05 *

Os efeitos no primeiro fator (Fator 1) apresentaram resultados promissores, alguns intuitivos e outros contra-intuitivos. Os resultados apontam que há efeito significativo estatisticamente para o IFIX, IPCA, Câmbio, NTN-B e IMA-B, porém, para o IFIX o sinal do coeficiente foi negativo, o que representa que o aumento marginal no IFIX implicaria diminuição linear do Fator Dinâmico Comum 1.

Os Índices IPCA e Câmbio também mostraram a mesma dinâmica negativa do IFIX, o que pode determinar que aumentos de preços e dólar influenciam negativamente nos retornos dos FII's.

Para os índices do mercado financeiro como o NTN-B e o IMA-B, os coeficientes foram positivos e significativos, sendo responsáveis por aumentos marginais dos FII's em decorrência de resultados positivos nesses índices. O modelo com Fator 1 como variável dependente apresentou p-valor significativo a 0.000 e R<sup>2</sup> (R-squared) com ajuste de 0.3544, os resultados estão na Tabela 3.

Para o Fator 2, o único índice que teve efeito significativo, foi o IMA-B, resultando em efeitos secundários e marginais do IMA-B na dinâmica dos FII's, porém, o coeficiente foi negativo, mostrando empiricamente que o IMA-B tem variação negativa ao longo do tempo. As demais variáveis foram todas com p-valor maior que 0.5%

A estimação do modelo com Fator 2 como variável dependente apresentou p-valor de 0.2808 e R<sup>2</sup> com ajuste de 0.1054, respectivamente um resultado sem

#### **4.2.2 RESULTADOS EMPÍRICOS DO MODELO 2**

Para análise específica do Mercado de Fundos Imobiliários a base de dados inicial de 78 FII's, foi dividida em FII's de Tijolos e Papéis, os fundos de tijolo são representados por imóveis físicos: lojas e supermercados; agências bancárias; shoppings; galpões. Por outro lado, os fundos de recebíveis ou de papel são formados por títulos ou valores mobiliários ligados ao setor imobiliário.

Dos 78 FII's selecionados que ficaram na amostra, 62 FII's tem especificação de Tijolo e 16 com especificação Papel. Com essas duas

novas amostras, foram realizadas as estimações via OLS para avaliar o impacto das variáveis econômicas, financeiras e ainda foram incluídos os índices de preço do mercado imobiliário.

A análise de componentes principais foi estimada separadamente para FII de Tijolo e Papel, os resultados estão apresentados nas Tabelas 4 e 5

Tabela 4 – Resultados do PCA – FII de Tijolo					
	PC1	PC2	PC3	PC4	PC5
Standard deviation	0.04686	0.04124	0.03898	0.03780	0.03672
Proportion of Variance	0.08726	0.06761	0.06040	0.05678	0.05360
Cumulative Proportion	0.08726	0.15487	0.21527	0.27205	0.32565

Para os fatores estimados dos FII de Tijolo, a variação cumulativa dos fatores PC1 a PC4 foram 27.20% dos fatores da base de dados, sendo: 8.72%, 15.48%, 21.52% e 27.20%.

Tabela 5 – Resultados do PCA – FII de Papel					
	PC1	PC2	PC3	PC4	PC5
Standard deviation	0.0301	0.02723	0.0248	0.02266	0.02012
Proportion of Variance	0.1951	0.15974	0.1324	0.11058	0.08719
Cumulative Proportion	0.1951	0.35488	0.4873	0.59788	0.68508

No caso dos dados de FII caracterizados como papel, a variação proporcional cumulativa dos fatores comuns teve PC1 com 19.51%, PC2 com 35.48%, 48.73% e 59.78% para o PC3 e PC4 respectivamente dos fatores da amostra. A divisão entre FII de Tijolo e Papel mostraram resultados interessantes e complementares dos fatores totais, o que representa diferenças reais na dinâmica dos FII de características mercadológicas diferenciadas.

De acordo com as pesquisas de [Oliveira e Milani \(2020\)](#) o Índice Ibovespa foi a única variável que explica o retorno dos Fundos Imobiliários, neste estudo os autores utilizaram diversos índices macroeconômicos e de mercado. O artigo de [Haas et al. \(2021\)](#) também corrobora com a presente pesquisa, e conclui que não é trivial a

compreensão dos fatores que fizeram com que a carteira de valor dos FII. Neste contexto [Moraes e Serra \(2017\)](#) concluíram que os fundos maiores são mais diversificados. A quantidade de imóveis e a concentração dos imóveis não foram significantes na explicação da diversificação dos FII.

Os trabalhos mencionados levaram em conta índices de mercado para medir efeitos dos FIIs, para entender esses efeitos foi incorporados os índices: IVG-R - Índice de Valores de Garantia de Imóveis Residenciais Financiados, MVG-R - Mediana dos Valores de Garantia de Imóveis Residenciais Financiados e o Índice Fipezap de preços, para entender como as variáveis econômicas, financeiras e o índices de mercado influenciam os fatores comuns dinâmicos dos FIIs de Tijolo e Papel.

Os resultados da estimação do modelo com Fatores Comuns para FIIs de Tijolo, são apresentados na Tabela 6.

Tabela 6 – Resultados do Modelo 2 – FII Tijolo				
Variáveis	Fator 1	p-valor	Fator 2	p-valor
(Intercept)	-0.3829	0.17643	0.1196	0.673
IFIX	-23.2572	0.00477**	6.2091	0.442
IBOV	-1.3604	0.77389	-0.6817	0.886
IPCA	-0.4603	0.01320*	-0.1838	0.317
IGPM	0.3130	0.08076.	-0.1744	0.330
Câmbio	-14.5436	0.01125*	3.3373	0.555
NTN	11.1141	0.01947*	2.4889	0.596
IMAB	2.2782	0.20040	-3.8558	0.033*
IVG	162.0199	0.00616**	11.0655	0.849
MVG	10.4174	0.23018	-4.1484	0.633
Fipe	-135.6645	0.01735*	61.4695	0.276
R-squared	0.4879		0.1612	
P-valor	0.0000		0.2053	
P-valor	0 ****	0.001 ***	0.01 **	0.05 !'

As evidências empíricas do modelo com FIIs de tijolo e incorporado os Índices de Mercado Imobiliário, apresentaram novos



resultados, onde o IFIX no Fator 1 foi significativo com coeficiente negativo, e para o Fator 2 o IFIX não foi significativo. Outros índices significativos estatisticamente para o Fator 1 foram o IPCA, o Câmbio e o NTN, porém com efeito marginal negativo.

O Índice IMAB foi significativo no Fator 2 e coeficiente negativo. Para os novos índices incorporados, IVG, MVG e Fipe, os resultados mostraram que essas variáveis foram significantes para o IVG e Fipe, e o MVG não teve efeito significativo. O IVG foi positivo, que mostra sua influência sobre os fatores comuns dos FIs de Tijolo, e o Índice Fipe foi negativo nesse segmento do FI.

O modelo teve ajuste melhor que o modelo anterior com R2 de 0.4879 no Fator 1 e 0.1612 no Fator 2. Os fatores continuam ainda, com forte efeito dado por componentes idiossincráticos.

### 4.2.3 RESULTADOS EMPÍRICOS DO MODELO 3

Os fundos de papel são formados por títulos ou valores mobiliários ligados ao setor imobiliário, a amostra analisada contém 16 fundos imobiliários - FIs no período de 2013 a 2019. Essa separação entre fundos de tijolo e papel é uma inovação desta pesquisa, para os fundos caracterizados como papel foram estimados seus fatores comuns e definida equação linear:

$$y_t = \mu + \Lambda x_t + e_t$$

onde  $y_t$  = são os fatores comuns extraídos dos FIs de papel,  $\mu$  o intercepto da equação  $\Lambda x_t$  caracteriza as variáveis dependentes que são formadas pelo IFIX, IBOV, IPCA, IGPM, Câmbio, NTN, IMAB, IVG, MVG e Fipe (Fipezap), e o erro  $e_t$ .

A Tabela 7 apresenta o resultado da estimação por OLS dos Fatores comuns 1 e 2. Para o IFIX o resultado continua semelhante ao resultado modelo 1 e 2, com coeficiente negativo e estatisticamente significante, que se mostra pouco intuitivo, pois, um aumento marginal do Índice IFIX diminuiria os fatores comuns, ou seja, o comportamento dos fundos FIs de papel seria cair.

Nessa amostra, aumentos marginais do IPCA, câmbio e da Fipe também contribuí-riam para reduzir os retornos dos FIs de

papel. As variáveis que impactam positivamente e são significantes estatisticamente são o NTN e a IVG, índices do mercado financeiro que podem ser preditores para os FIs.

O modelo estimado com o Fator 2 não apresentou relevância estatística em nenhuma variável, e, o modelo para o Fator 1 apresentou um ajuste com R<sup>2</sup> (R-squared) de 0.4759, ou seja, as variáveis utilizadas na análise explicam 47.59% do comportamento dos co- movimentos dos FIs de papel. Há muitos outros elementos que explicam a dinâmica dos FIs de papel ao longo do tempo.

Tabela 7 – Resultados do Modelo 3 – FI Papel				
Variáveis	Fator 1	p-valor	Fator 2	p-valor
(Intercept)	-0.2567	0.31779	-0.03911	0.812
IFIX	-21.0862	0.00491**	-6.51296	0.167
IBOV	-1.7698	0.68136	-3.88580	0.163
IPCA	-0.4165	0.01370*	-0.10549	0.322
IGPM	0.2404	0.13917	0.08566	0.409
Câmbio	-13.7536	0.00854**	-4.75914	0.149
NTN	11.5773	0.00783**	-0.41436	0.879
IMAB	2.2807	0.15944	0.18789	0.856
IVG	123.8897	0.02039*	21.21125	0.529
MVG	7.3611	0.35049	5.97448	0.239
Fipe	-110.5114	0.03251*	-32.95702	0.315
R-squared	0.4879		0.1612	
P-valor	0.0000		0.2053	
P-valor	0 <sup>***</sup>	0.001 <sup>***</sup>	0.01 <sup>*</sup>	0.05 <sup>!</sup>

Observa-se que a pesquisa ainda teve como objetivo a análise separada da amostra para fundos de fundos, porém, não há observações suficientes para estimar o modelo.

#### 4.2.4 DISCUSSÃO DOS RESULTADOS

A atividade econômica envolve uma série de variáveis que se unem para explicar a dinâmica da economia, os resultados encontrados na pesquisa mostram que os comovimentos dos FII's não são facilmente representados pelas variáveis econômicas ou índices de mercado, a literatura já indica que essa dinâmica é complexa e existem outros determinantes.

O principal indicador do mercado do FII's é o IFIX, e nos três modelos estimados, o IFIX foi significativo, porém, seu efeito marginal foi negativo, um resultado pouco intuitivo. No trabalho de [Oliveira e Milani \(2020\)](#) a variável IFIX foi utilizada como dependente, e mesmo neste contexto os resultados também observam contradições. Para o IFIX, o estudo de [Carvalho \(2019\)](#) modelou a previsão em três equações diferentes, conseguindo bons resultados para previsão. Outros trabalhos que utilizaram o IFIX e outros índices de mercado imobiliário foram de [Oliveira e Milani \(2020\)](#), [Haas et al. \(2021\)](#) e [Moraes e Serra \(2017\)](#) que corroboram com a complexidade dos resultados da presente pesquisa, pois, mostram que nem todos os fatores influenciam os FII's.

Para a taxa de inflação [Giannone, Reichlin e Small \(2008a\)](#) também apresentam uma série de variáveis para estimar os fatores e testar sua influência sobre o comportamento dos preços. Para os FII's, seja o conjunto completo dos dados, ou separados em Tijolo e Papel, o Índice de Preços medido pelo IPCA foi significativo nos três modelos, porém, seu efeito é negativo para os FII's, ou seja, um aumento marginal diminui os fatores comuns que determinam os retornos dos FII's.

Para o caso do dólar [Felício e Júnior \(2014\)](#) utilizaram os fatores comuns das taxas de câmbio de um conjunto de países com variáveis macroeconômicas, esses fatores das taxas de outros países são determinantes da taxa nacional. No caso dos FII's, o câmbio medido pela relação real/dólar teve efeito significativo nos fatores comuns para os três modelos estimados de FII's, e seu efeito marginal foi negativo, que é intuitivo ao pensar que o dólar é também um investimento concorrente ao FII.

Os índices NTN, IMAB, IVG e Fipe apresentaram resultados significantes estatisticamente, para o NTN o efeito marginal foi

sempre positivo nos três modelos estimados, o IMAB somente para o modelo 1, o IVG para os modelos 2 e 3 e o Fipe teve efeito negativo marginalmente. Esses índices do mercado foram utilizados por [Oliveira e Milani \(2020\)](#) e [Haas et al. \(2021\)](#) e seus resultados significativos e positivos corroboram com os apresentados nesta pesquisa. O estudo de [Conceição \(2017\)](#) para o mercado de ações usando IBOVESPA e os fatores estimados do IBX-100 foram positivos e significativos, na presente análise o IBOVESPA não apresentou efeito estatístico em nenhum dos modelos. Para os indicadores IMA e NTN os resultados mostraram indícios de multicolinearidade pela análise visual (Figura 13 e 14).

A presente pesquisa foi a que mais explorou modelos para identificar se as variáveis econômicas e de mercado tivessem efeito marginal sobre os fatores ou co-movimentos dos FIIs. O processo metodológico de explorar novos resultados empíricos apresentaram considerações promissoras, seja pela utilização de um novo pacote desenvolvido por brasileiros para estimar nowcast de variáveis macroeconômicas em qualquer formato temporal, seja pelo desfecho de entender que os fatores dinâmicos comuns relacionados com Fundos de Investimentos Imobiliários são complexos e há uma variedade de dinâmicas não observáveis que influenciam seu comportamento.

Por outro lado, a presente pesquisa ainda traz como novidade uma análise mais específica sobre os fatores dinâmicos comuns dos FIIS de Tijolo e Papel, ainda pouco explorado na literatura e com resultados promissores para preditores como o Índice NTN- B, o IMAB, o IVG e o Fipezap. Os resultados apresentam maior poder explicativo dos componentes principais quando aplicados para os fundos de papéis, vis-à-vis os de tijolo (tabelas 4 e 5), e quando aplicados aos fundos de papel, o poder explicativo praticamente dobra.



5

## 5

**CONSIDERAÇÕES FINAIS**

A presente dissertação apresentou análise de fatores dinâmicos para dados de Fundos de Investimentos Imobiliários listados, e, correlacionou variáveis econômicas e índices do mercado imobiliário com os fatores dinâmicos comuns dos FII's. O estudo, trouxe como principal achado, que a maior parte dos retornos é dado por componentes idiossincráticos, e que os fatores estimados dos FII's são complexos e há uma variedade de indicadores que refletem esse mercado.

Os indicadores de mercado como IFIX, IVG-R, NTN-B, IMAB e Fipe apresentam efeitos sobre os fatores comuns dos FII's, e as variáveis IPCA e Câmbio também impactam na dinâmica dos fundos, seja no conjunto analisado, seja nas amostra de tijolo ou de papel.

De maneira geral os resultados concluem que a metodologia de fatores dinâmicos para medir os co-movimentos de Fundos Imobiliários apresentou resultados promissores. Há diferenças entre as amostras analisadas, sendo pelo conjunto dos 78 fundos, ou, em tijolo e papel, que podem influenciar a dinâmica preditiva.

Esse resultado corrobora com a literatura empírica, pois, confirma a existência de fatores não observáveis extraídos dos FII's, e que os co-movimentos dos FII's são complexos e há uma variedade de dinâmicas não observáveis que influenciam a seu comportamento.



# REFERÊNCIAS

# REFERÊNCIAS

## REFERÊNCIAS

BAI, J. Inferential theory for factor models of large dimensions. *Econometrica*, WileyOnline Library, v. 71, n. 1, p. 135–171, 2003. Citado 2 vezes nas páginas 7 e 11.

BAI, J.; NG, S. Determining the number of factors in approximate factor models. *Econometrica*, Wiley Online Library, v. 70, n. 1, p. 191–221, 2002. Citado 2 vezes nas páginas 7 e 11.

BAI, J.; NG, S. Confidence intervals for diffusion index forecasts and inference for factor-augmented regressions. *Econometrica*, Wiley Online Library, v. 74, n. 4, p. 1133–1150, 2006. Citado 2 vezes nas páginas 7 e 11.

BAI, J.; NG, S. Determining the number of primitive shocks in factor models. *Journal of Business and Economic Statistics*, Taylor and Francis, v. 25, n. 1, p. 52–60, 2007. Disponível em: <<https://doi.org/10.1198/073500106000000413>>. Citado 2 vezes nas páginas 12 e 14.

BAI, J.; NG, S. *Large dimensional factor analysis*. [S.l.]: Now Publishers Inc, 2008. Citado na página 10.

BAÑBURA, M. et al. Chapter 4 - now-casting and the real-time data flow. In: ELLIOTT, G.; TIMMERMANN, A. (Ed.). *Handbook of Economic Forecasting*. Elsevier, 2013, (Handbook of Economic Forecasting, v. 2). p. 195–237. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780444536839000049>>. Citado na página 9.

BERTERO, E.; MAYER, C. Structure and performance: Global interdependence of stockmarkets around the crash of october 1987. *European Economic Review*, Elsevier, v. 34, n. 6, p. 1155–1180, 1990. Citado na página 4.

BLACKMAN, S. C.; HOLDEN, K.; THOMAS, W. A. Long-term relationships between international share prices. *Applied Financial Economics*, Taylor & Francis, v. 4, n. 4, p. 297–304, 1994. Citado na página 4.



CARVALHO, A. L. d. P. *Modelagem econométrica para forecasting do IFIX*. Tese (Doutorado) — FUNDAÇÃO GETÚLIO VARGAS, 2019. Citado 3 vezes nas páginas 5, 7 e 20.

CHAMBERLAIN, G.; ROTHSCCHILD, M. Arbitrage, factor structure, and mean-variance analysis on large asset markets. *Econometrica*, v. 51, n. 5, p. 1281–304, 1983. Disponível em: <<https://EconPapers.repec.org/RePEc:ecm:emetrp:v:51:y:1983:i:5:p:1281-304>>. Citado 2 vezes nas páginas 6 e 7.

CHEUNG, Y.-W.; NG, L. K. Interactions between the us and japan stock market indices. *Journal of International Financial Markets, Institutions & Money*, Taylor & Francis, v. 2, n. 2, p. 51–70, 1993. Citado 3 vezes nas páginas 4, 5 e 6.

CONCEIÇÃO, A. M. *Modelo de fatores dinâmicos aplicado ao mercado brasileiro de ações*. Tese (Doutorado) — FUNDAÇÃO GETÚLIO VARGAS, 2017. Citado 6 vezes nas páginas 5, 7, 10, 11, 12 e 21.

CONNOR, G.; KORAJCZYK, R. A. Performance measurement with the arbitrage pricing theory: A new framework for analysis. *Journal of financial economics*, Elsevier, v. 15, n. 3, p. 373–394, 1986. Citado 2 vezes nas páginas 7 e 12.

EUN, C. S.; SHIM, S. International transmission of stock market movements. *Journal of financial and quantitative Analysis*, JSTOR, p. 241–256, 1989. Citado na página 4.

FELÍCIO, W. R. d. O.; JÚNIOR, J. L. R. Common factors and the exchange rate: results from the brazilian case. *Revista Brasileira de Economia*, SciELO Brasil, v. 68, p. 49–71, 2014. Citado 2 vezes nas páginas 6 e 21.

FOCARDI, S. M.; FABOZZI, F. J.; MITOV, I. K. A new approach to statistical arbitrage: Strategies based on dynamic factor models of prices and their performance. *Journal of Banking & Finance*, Elsevier, v. 65, p. 134–155, 2016. Citado 3 vezes nas páginas 5, 6 e 7.

FORNI, M. et al. The generalized dynamic-factor model: Identification and estimation. *Review of Economics and statistics*, MIT Press, v. 82, n. 4, p. 540–554, 2000. Citado 5 vezes nas páginas 5, 6, 7, 10 e 11.

FORNI, M.; REICHLIN, L. Let's get real: a factor analytical approach to disaggregated business cycle dynamics. *The Review of Economic Studies*, Wiley-Blackwell, v. 65, n. 3, p. 453–473, 1998. Citado 2 vezes nas páginas 7 e 11.

FURSTENBERG, G. M. V. et al. International stock price movements: links and messages. *Brookings papers on economic activity*, JSTOR, v. 1989, n. 1, p. 125–179, 1989. Citado na página 4.

GEWEKE, J. The dynamic factor analysis of economic time series. *Latent variables in socio-economic models*, North-Holland, 1977. Citado 2 vezes nas páginas 4 e 9.

GIANNONE, D.; REICHLIN, L.; SMALL, D. Nowcasting: The real-time informational content of macroeconomic data. *Journal of Monetary Economics*, v. 55, n. 4, p. 665–676, 2008. ISSN 0304-3932. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0304393208000652>>. Citado 6 vezes nas páginas 2, 3, 9, 13, 14 e 20.

GIANNONE, D.; REICHLIN, L.; SMALL, D. Nowcasting: The real-time informational content of macroeconomic data. *Journal of Monetary Economics*, v. 55, n. 4, p. 665–676, 2008. Disponível em: <<https://EconPapers.repec.org/RePEc:eee:moneco:v:55:y:2008:i:4:p:665-676>>. Citado na página 4.

HAAS, G. P. et al. Existe value premium para os fundos imobiliários brasileiros? uma análise para o período 2013 a 2018. *Revista Brasileira de Economia de Empresas/Brazilian Journal of Business Economics*, v. 21, n. 1, 2021. Citado 3 vezes nas páginas 18, 20 e 21.

HAMAO, Y.; MASULIS, R. W.; NG, V. Correlations in price changes and volatility across international stock markets. *The review of financial studies*, Oxford University Press, v. 3, n. 2, p. 281–307, 1990. Citado na página 4.

JOHANSEN, S. Statistical analysis of cointegration vectors. *Journal of economic dynamics and control*, Elsevier, v. 12, n. 2-3, p. 231–254, 1988. Citado na página 4.

MARIANO, R. S.; MURASAWA, Y. A new coincident index of business cycles based on monthly and quarterly series. *Journal of applied Econometrics*, Wiley Online Library, v. 18, n. 4, p. 427–443, 2003. Citado na página 14.

MASIH, A. M.; MASIH, R. A comparative analysis of the propagation of stock market fluctuations in alternative models of dynamic causal linkages. *Applied Financial Economics*, Taylor & Francis, v. 7, n. 1, p. 59–74, 1997. Citado na página 4.

MORAES, A. V. D.; SERRA, R. G. Diversificação dos fundos de investimento imobiliário brasileiros. *Revista Base (Administração e Contabilidade) da UNISINOS*, Universidade do Vale do Rio dos Sinos, v. 14, n. 1, p. 63–73, 2017. Citado 2 vezes nas páginas 18 e 20.

NAVARRO, C.; RIVERA, D. Peña Sánchez de. *Estimation of the common component in Dynamic Factor Models*. [S.l.], 2018. Disponível em: <<https://ideas.repec.org/p/cte/wsrepe/27047.html>>. Citado na página 10.

NG, V.; ENGLE, R. F.; ROTHSCCHILD, M. A multi-dynamic-factor model for stock returns. *Journal of Econometrics*, v. 52, n. 1, p. 245–266, 1992. ISSN 0304-4076. Disponível em: <<https://www.sciencedirect.com/science/article/pii/030440769290072Y>>. Citado 3 vezes nas páginas 4, 5 e 6.

NOWCASTING GDP and Inflation: The Real-Time Informational Content of Macroeconomic Data Release. [S.l.], 2007. Disponível em: <<https://EconPapers.repec.org/RePEc:mmf:mmfc06:164>>. Citado na página 4.

OLIVEIRA, J. M. de; MILANI, B. Variáveis que explicam o retorno dos fundos imobiliários brasileiros. *Revista Visão: Gestão Organizacional*, v. 9, n. 1, p. 17–33, 2020. Citado 3 vezes nas páginas 18, 20 e 21.

PAGAN, J. A.; SOYDEMIR, G. On the linkages between equity markets in latin america. *Applied Economics Letters*, Taylor & Francis, v. 7, n. 3, p. 207–210, 2000. Citado 2 vezes nas páginas 5 e 6.

PENA, D.; BOX, G. E. P. Identifying a simplifying structure in time series. *Journal of the American Statistical Association*, [American Statistical Association, Taylor & Francis, Ltd.], v. 82, n. 399, p. 836–843, 1987. ISSN 01621459. Disponível em: <<http://www.jstor.org/stable/2288794>>. Citado na página 11.

ROCHA, B. de P.; SEKKEL, R. M. The dynamic factor model: an application to international stock market integration. *Revista de economía*, Banco Central del Uruguay, v. 13, n. 1, p. 91–116, 2006. Citado 2 vezes nas páginas 5 e 6.

SARGENT, T. J.; SIMS, C. A. et al. Business cycle modeling without pretending to have too much a priori economic theory. *New methods in business cycle research*, v. 1, p.145–168, 1977. Citado 3 vezes nas páginas 4, 6 e 9.

SOTO, P. A. *Arbitragem estatística no mercado brasileiro de ações: uma abordagem por VECM*. Tese (Doutorado) — FUNDAÇÃO GETÚLIO VARGAS, 2016. Citado na página 7.

STOCK, J. H.; WATSON, M. Dynamic factor models. *Oxford Handbooks Online*, Oxford University Press, 2011. Citado 2 vezes nas páginas 7 e 11.

STOCK, J. H.; WATSON, M. W. Testing for common trends. *Journal of the American statistical Association*, Taylor & Francis Group, v. 83, n. 404, p.1097–1107, 1988. Citado na página 7.

STOCK, J. H.; WATSON, M. W. Forecasting using principal components from a large number of predictors. *Journal of the American statistical association*, Taylor & Francis, v. 97, n. 460, p. 1167–1179, 2002. Citado 2 vezes nas páginas 7 e 10.

STOCK, J. H.; WATSON, M. W. Dynamic factor models, factor-augmented vector autoregressions, and structural vector autoregressions in macroeconomics. In: *Handbook of macroeconomics*. [S.l.]: Elsevier, 2016. v. 2, p. 415–525. Citado 4 vezes nas páginas 3, 7, 10 e 13.

TABAK, B. M.; LIMA, E. J. A. Causality and cointegration in stock markets: the case of latin america. *Revista Brasileira de Economia de Empresas*, v. 3, n. 2, 2013. Citado 2 vezes nas páginas 5 e 6.

VALK, S. de; MATTOS, D. de; FERREIRA, P. Nowcasting: An R Package for Predicting Economic Variables Using Dynamic Factor Models. *The R Journal*, v. 11, n. 1, p. 230–244, 2019. Disponível em: <<https://doi.org/10.32614/RJ-2019-020>>. Citado 6 vezes nas páginas 3, 9, 13, 14, 15 e 31.



APÊNDICES

**APÊNDICES**

# ANEXO A – Anexo

## A.1 ÍNDICE DE FATORES (IC) E IC SHOCKS

**Tabela 8 – Resultados do IC**

ICR 1	Lenght	Class	Mode
r-star	1	none	numeric
IC	20	none	numeric
IC Shocks	Lenght	Class	Mode
q-star	1	none	Numeric
p	1	none	numeric

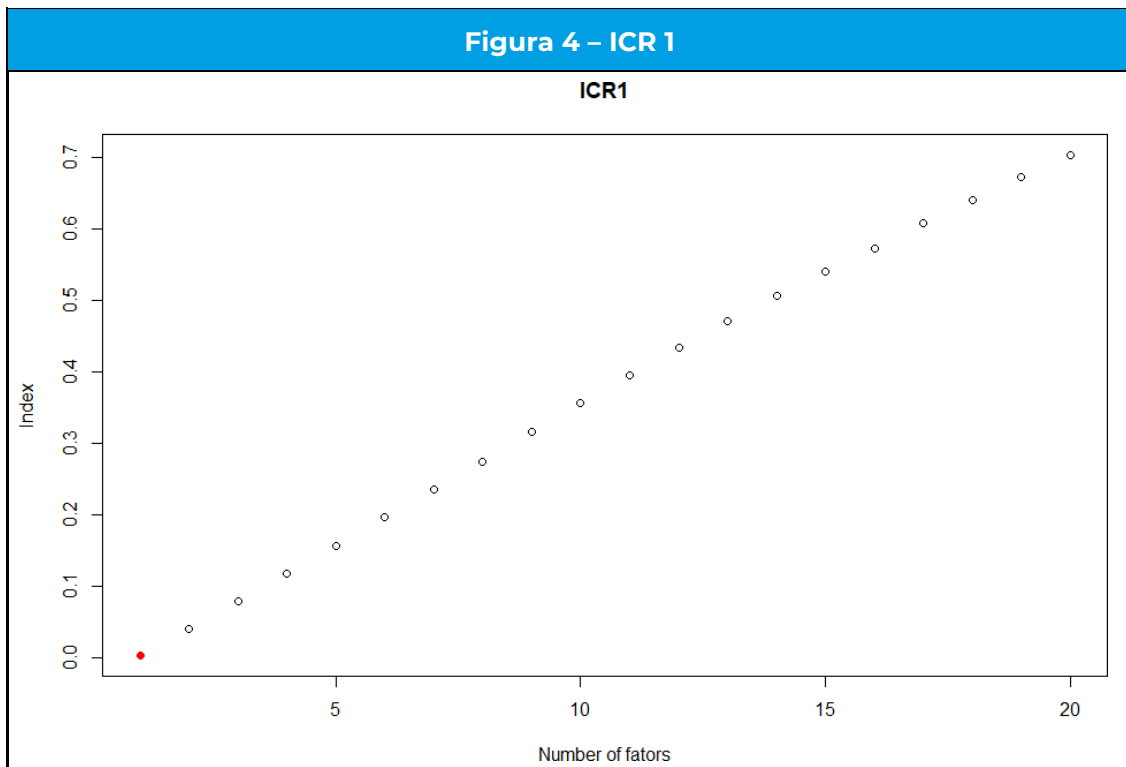


Figura 5 – ICR 2

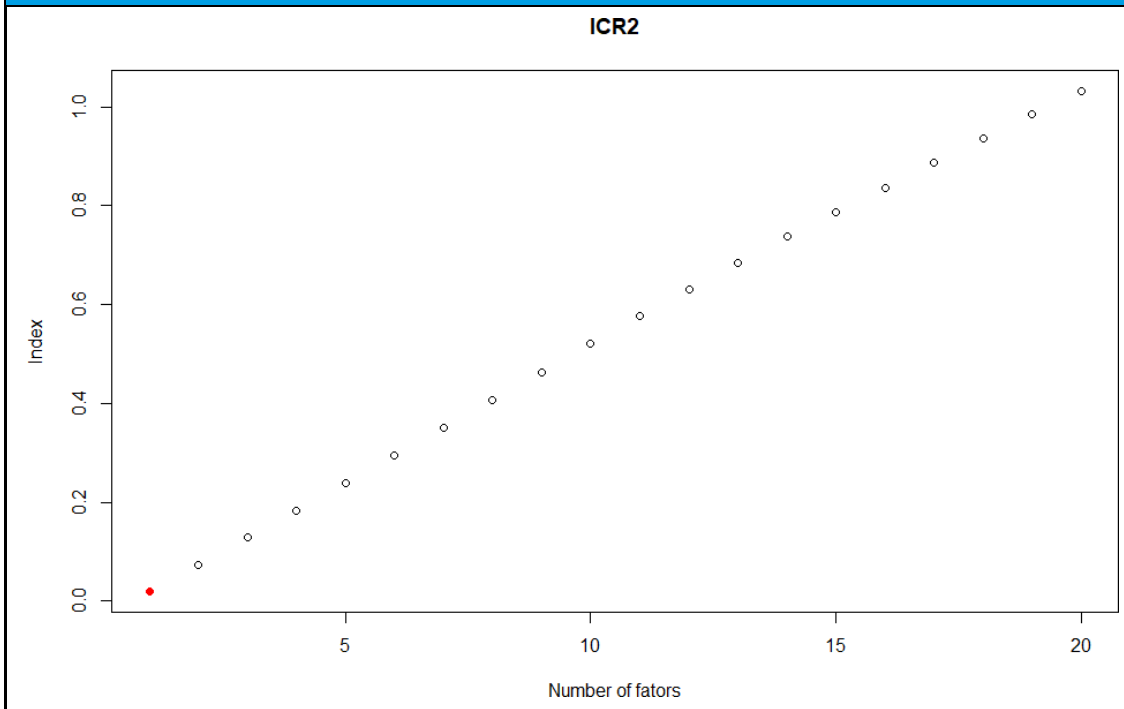
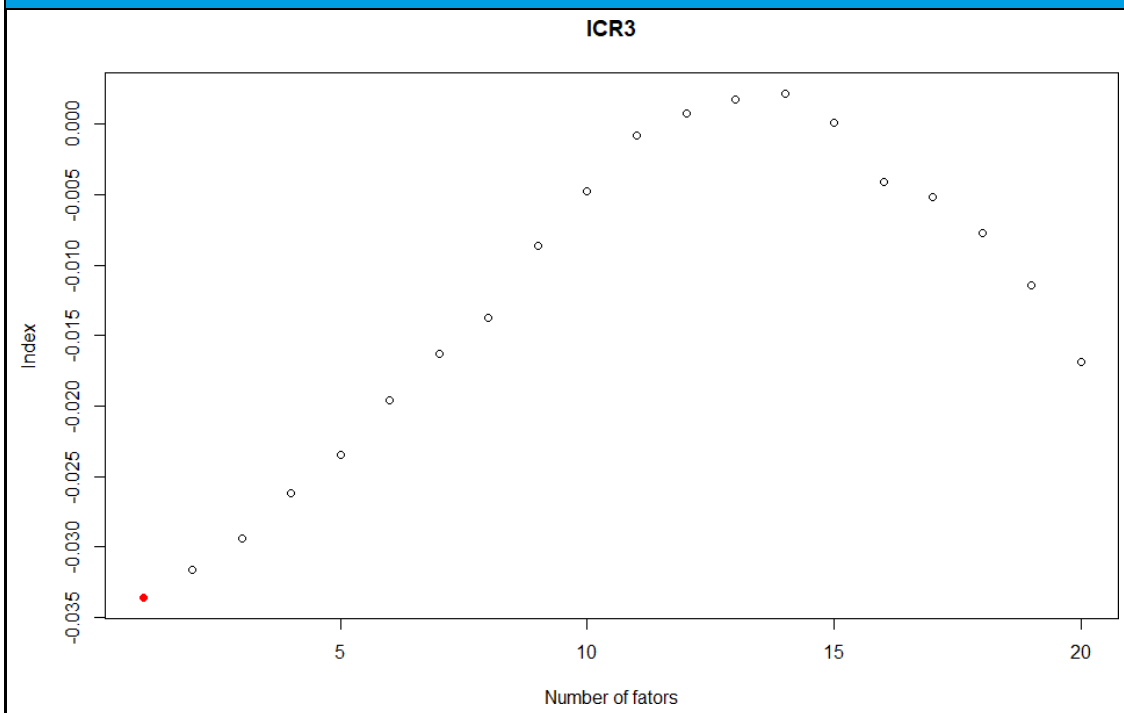


Figura 6 – ICR 3





## A.2 DADOS

Tabela 9 – Dados FII

Qtde	Fundos	Dias Negociados	% total	Negociados >70%
1	ABCP11	1219	93.41%	SIM
2	ALMI11	1224	93.79%	SIM
3	BBFI11	1230	94.25%	SIM
4	BBPO11	1237	94.79%	SIM
5	BBRC11	1235	94.64%	SIM
6	BCFF11	1237	94.79%	SIM
7	BCIA11	1061	81.30%	SIM
8	BCRI11	1217	93.26%	SIM
9	BMLC11	1176	90.11%	SIM
10	BNFS11	1058	81.07%	SIM
11	BPPF11	1237	94.79%	SIM
12	BRCR11	1237	94.79%	SIM
13	BTLG11	1236	94.71%	SIM
14	CARE11	922	70.65%	SIM
15	CBOP11	1211	92.80%	SIM
16	CEOC11	1223	93.72%	SIM
17	CJCT11	1216	93.18%	SIM
18	CPTS11	1215	93.10%	SIM
19	CTXT11	1224	93.79%	SIM
20	CXCE11	1071	82.07%	SIM
21	CXRI11	1147	87.89%	SIM
22	EDFO11	919	70.42%	SIM
23	EDGA11	1237	94.79%	SIM
24	EURO11	1150	88.12%	SIM
25	FAED11	1235	94.64%	SIM
26	FAMB11	1157	88.66%	SIM
27	FCFL11	1232	94.41%	SIM
28	FEXC11	1237	94.79%	SIM
29	FIGS11	1237	94.79%	SIM
30	FIIB11	1191	91.26%	SIM
31	FIIP11	1237	94.79%	SIM
32	FLMA11	1236	94.71%	SIM
33	FLRP11	1040	79.69%	SIM
34	FPAB11	1107	84.83%	SIM
35	HCRI11	1190	91.19%	SIM
36	HGBS11	1237	94.79%	SIM
37	HGCR11	1216	93.18%	SIM
38	HGLG11	1237	94.79%	SIM
39	HGPO11	1235	94.64%	SIM
40	HGRE11	1237	94.79%	SIM

Tabela 10 – Dados FII - Continuação

Qtde	Fundos	Dias Negociados	% total	Negociados >70%
41	HTMX11	1237	94.79%	SIM
42	JRDM11	1235	94.64%	SIM
43	JSRE11	1237	94.79%	SIM
44	KNCR11	1237	94.79%	SIM
45	KNRE11	1122	85.98%	SIM
46	KNRI11	1237	94.79%	SIM
47	MAXR11	1054	80.77%	SIM
48	MBRF11	1207	92.49%	SIM
49	MFII11	1159	88.81%	SIM
50	MXRF11	1237	94.79%	SIM
51	NEWU11	978	74.94%	SIM
52	NSLU11	1237	94.79%	SIM
53	ONEF11	1140	87.36%	SIM
54	PLRI11	1108	84.90%	SIM
55	PORD11	1119	85.75%	SIM
56	PQDP11	1233	94.48%	SIM
57	PRSV11	1150	88.12%	SIM
58	RBBV11	1208	92.57%	SIM
59	RBED11	1237	94.79%	SIM
60	RBFF11	1190	91.19%	SIM
61	RBGS11	1235	94.64%	SIM
62	RBRD11	1235	94.64%	SIM
63	RBVA11	1237	94.79%	SIM
64	RBVO11	1113	85.29%	SIM
65	RCRB11	1237	94.79%	SIM
66	RNDP11	990	75.86%	SIM
67	RNGO11	1237	94.79%	SIM
68	SCPF11	969	74.25%	SIM
69	SDIL11	1237	94.79%	SIM
70	SHPH11	1197	91.72%	SIM
71	SPTW11	1237	94.79%	SIM
72	THRA11	1221	93.56%	SIM
73	TRNT11	955	73.18%	SIM
74	VLOL11	1220	93.49%	SIM
75	VRTA11	1236	94.71%	SIM
76	WPLZ11	1064	81.53%	SIM
77	XPCM11	1237	94.79%	SIM
78	XTED11	1221	93.56%	SIM

### A.3 SCRIPT RSTUDIO

Para estimar no nowcast foi utilizado o seguinte script: <sup>4</sup>

Para transformar as variáveis e balancear o painel de dados  
usa-se: `x <- Bpanel(base = dados, trans = dados$trans)`

Para normalizar e transformar as variáveis em mensais:

`y <- diff(diff(GDPqtr, 4))`  
`y <- qtr2month(y)`

Para estimar os fatores:

`ICR1 <- ICfactors(x = x, type = 1)`

Para estimar os parâmetros

`ICQ1 <- ICshocks(x = x, r = 2, delta=0.1, m=1)`

Para estimar o modelo e previsão:

`data <- cbind(y,x)`

`frequency <- c(4,rep(12,ncol(x)))`

`now <- nowcast(formula = y., data = data, r = 2, q = 2, p = 2, method = "2sogg", frequency = frequency)`  
`summary(now$reg)`

Regressão Linear Múltipla Papel

Fatores obtidos do nowcast

`reg <- cbind(y2, y3, y4, y5, y6, y7, y8, y9, y10, y11, factor1papel, factor2papel)`

`fit <- lm(factor1papel ~ y2 + y3 + y4 + y5 + y6 + y7 + y8 + y9 + y10 + y11, data=reg)`  
`summary(fit)`



Para apresentar os resultados:

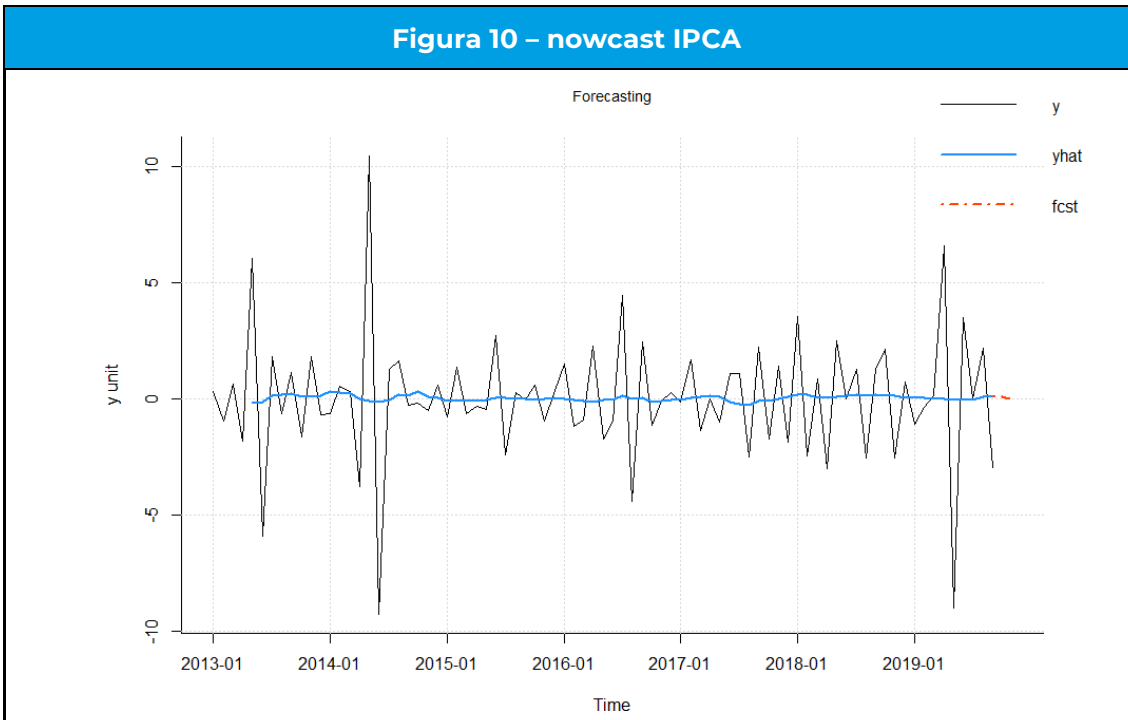

`nowcast.plot(now, type = "fcst")`

<sup>4</sup> Ver mais em [Valk, Mattos e Ferreira \(2019\)](#)

## A.4 RESULTADOS DOS NOWCASTING

Figuras - Nowcasting





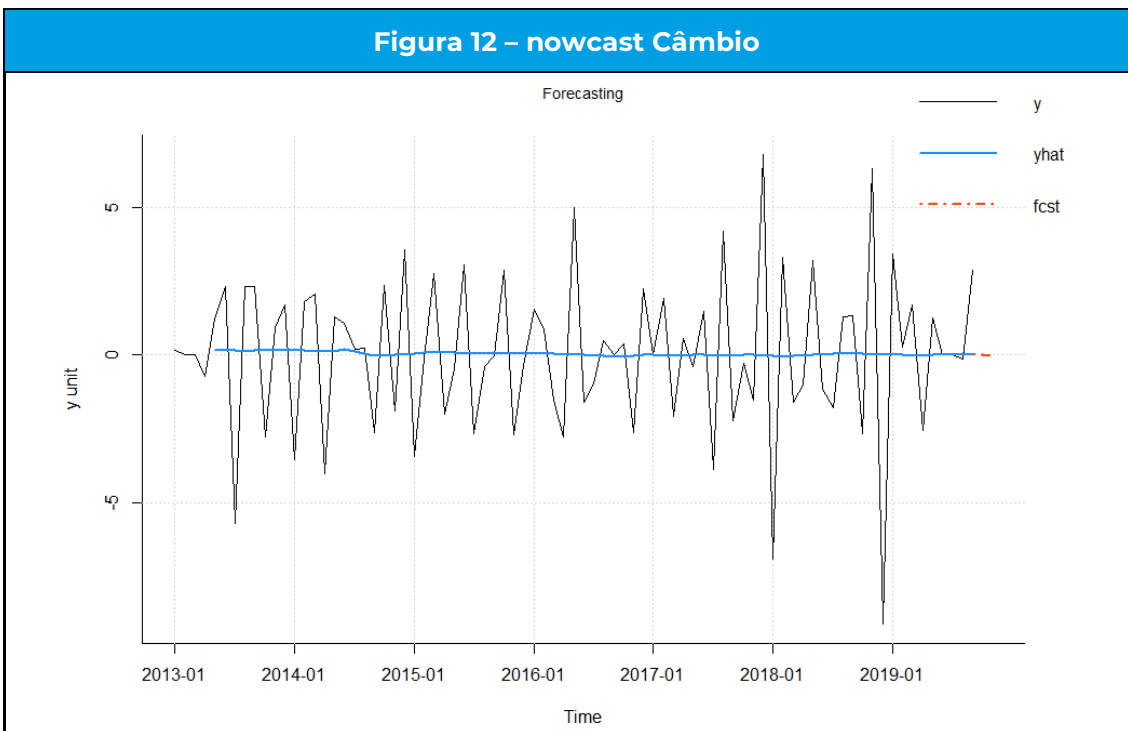



Figura 13 – nowcast NTN-B





Figura 14 – nowcast IMA-B





idn

Bo  
pro  
cit  
ref  
Nos  
são

**idp**

A ESCOLHA QUE  
**TRANSFORMA**  
O SEU CONHECIMENTO