


ARTIGOS

DETERMINANTES MACROECONÔMICOS DOS PREÇOS DO MERCADO HABITACIONAL BRASILEIRO: UMA ABORDAGEM COM DADOS EM PAINEL

Jadson Pessoa

Professor no Departamento de Economia da Universidade Federal do Maranhão (UFMA).


E-mail: jadson.pessoa@ufma.br

 <https://orcid.org/0000-0002-0152-7141>

Sérgio Rivero

Professor no Departamento de Economia e da Pós-Graduação em Economia da Universidade Federal do Pará (UFPA).


E-mail: rivero@ufpa.br

 <https://orcid.org/0000-0002-7723-2497>

João Cerejeira

Professor no Departamento de Economia da Escola de Economia e Gestão (EEG) e do Núcleo de Investigação em Políticas Econômicas e Empresariais (Nipe) da Universidade do Minho (UMinho).

E-mail: joao.cerejeira@eeg.uminho.pt

 <https://orcid.org/0000-0001-6544-6116>



Este artigo está licenciado com uma Licença Creative Commons - Atribuição-NãoComercial 4.0 Internacional

Como citar este artigo: Pessoa, J., Rivero, S., & Cerejeira, J. (2021). Determinantes macroeconômicas dos preços do mercado habitacional brasileiro: uma abordagem com dados em painel. *Revista de Economia Mackenzie*, 18(esp.), 12-38. doi:10.5935/1808-2785/rem.v18nespp.12-38

Aprovado em: 31/5/2021

Recebido em: 20/10/2020

Resumo

O presente artigo investigou os determinantes macroeconômicos dos preços dos imóveis residenciais das 13 regiões metropolitanas brasileiras entre 2004 a 2016. Utilizamos como método de pesquisa estimações de modelos com dados em painel. Realizamos testes de especificidade e de robustez para encontrar o melhor modelo. O principal resultado estimado foi para o produto interno bruto (PIB), por causa da elasticidade positiva maior que 1 e de uma relação inversa com a taxa de juros do Sistema Especial de Liquidação e de Custódia (Selic). Nesse sentido, nossas conclusões apontam para a necessidade de uma forte recuperação da economia brasileira no curto prazo, especialmente do PIB, e de uma redução significativa da Selic, o que já vem ocorrendo, para que o setor imobiliário residencial retome sua trajetória de crescimento.

Palavras-chave: Ciclo de preço; dados em painel; preços dos imóveis; região metropolitana; determinantes macroeconômicos.

Classificação *JEL*: D40; R20; C23; R29; E30.

INTRODUÇÃO

O mercado imobiliário brasileiro apresentou, a partir de 2003, uma forte elevação dos preços médios dos imóveis residenciais em diferentes cidades, o que levou a preocupações com a hipótese de o mercado brasileiro estar sofrendo um efeito de “bolha” especulativa e se teríamos um “estouro” como consequência (Oliveira & Almeida, 2014). Essa elevação coincide com o período em que também houve crescimento do Produto Interno Bruto (PIB), do volume de contratações, redução das taxas de juros e forte expansão do crédito para o setor – algo sem precedentes na história do país. No entanto, a partir de 2014, verificamos não só uma redução desse crescimento geral dos preços,

como também uma retração de vários desses indicadores macroeconômicos. Desse movimento mais geral, podemos verificar a formação típica de um ciclo dos preços de imóveis para o mercado brasileiro: *boom*, consolidação e crise (Wheaton, 1999).

Assim, em uma perspectiva macroeconômica, o mercado imobiliário brasileiro atuou de forma pró-cíclica no movimento de crescimento da economia brasileira, observado entre 2000 e 2008, assim como anticíclico, por causa de um maior direcionamento de recursos do governo federal para o setor decorrente da criação de programas e subsídios para enfrentar a crise financeira mundial de 2008, tendo como consequência uma expansão consistente em diversos indicadores do setor imobiliário.

Nesse sentido, podemos salientar o volume de empregos gerado entre 2006 e 2013, período de maior expansão. Surgiram 700 mil postos de trabalho de empregos formais, o que representou 5,2% do total de empregos formais gerado no Brasil nesse período. E, como se trata de um setor essencialmente pró-cíclico, no período em que se inicia a crise econômica brasileira de 2014 até 2017, houve uma redução de 450 mil trabalhadores formais, ou seja, 21% de redução de vagas no Brasil (Instituto Brasileiro de Geografia e Estatística [IBGE], 2018a). O volume de crédito para o setor, que em 2007, por exemplo, era de 1,8% em relação ao PIB, passou para cerca de 9,7% em 2017. Todavia, apesar do grande crescimento para o período analisado, o volume de crédito imobiliário em proporção do PIB ainda se mostra muito abaixo da média de diversos outros países da América Latina (Cerutti, Dagher, & Dell’Ariccia, 2017; Otto, 2015). Já a participação no valor adicionado bruto do Brasil, no que se refere à indústria da construção civil e aos serviços ligados às atividades imobiliárias, entre os anos de 2000 e 2015, apresentou uma taxa média de 7,5%, o que equivale a cerca de R\$ 196 bilhões por ano, a preços constantes (IBGE, 2018b).

Portanto, podemos perceber que o mercado de imóveis representa uma grande porcentagem da produção macroeconômica, revelando um papel importante na dinâmica global do país. Lucena (1981) acrescenta que a produção de moradias fornece uma vantagem endógena adicional ao desenvolvimento do país, pois, ao utilizar, na maior parte do processo produtivo, fatores de produção do próprio país, gera um desenvolvimento mais harmônico.

Desse modo, por se comportar de forma pró-cíclica, quando induzido pelo mercado (2000-2008), ou anticíclica, quando orientado pelo governo (2008-2017), o setor imobiliário desempenha um papel fundamental no circuito econômico de um país, sobretudo em países onde as estruturas social e eco-

nômica se encontram deprimidas, como é o caso do Brasil, pois, além de absorver uma grande quantidade de mão de obra – não qualificada, inclusive –, gera um forte encadeamento de valor em diversos outros setores.

Dessa forma, investigar como as variáveis macroeconômicas influenciam os preços dos imóveis residenciais em diferentes localidades pode trazer importantes contribuições ao entendimento de como o mercado imobiliário brasileiro se comporta na formação dos seus preços a partir da perspectiva dos principais *drives* macroeconômicos. Assim, tendo como interesse contribuir com a literatura empírica sobre os ciclos de preços do mercado imobiliário da economia brasileira, buscaremos responder à seguinte questão: quais foram os principais *drives* macroeconômicos para a formação de um ciclo de preços para o mercado imobiliário brasileiro verificado no período recente (2004-2016)?

Para responder à questão apresentada, buscamos investigar como as principais variáveis macroeconômicas – tais como: renda disponível, taxa de juros, crédito para o setor e mercado de trabalho –, são determinantes na formação dos preços dos imóveis residenciais e, conseqüentemente, para a formação de um ciclo de negócios para 13 regiões metropolitanas (RM) do Brasil. Como método de investigação utilizaremos uma abordagem de dados em painel para verificar os determinantes da variação dos preços dos imóveis residenciais nas RM analisadas. Nossos modelos de dados em painel serão do tipo estático com um *lag* nas variáveis independentes, no qual aplicaremos testes de robustez para verificar a melhor especificação do modelo a ser estimado em nosso trabalho empírico.

O presente artigo é desenvolvido da seguinte forma: além desta seção introdutória, na seção 2, será apresentada uma breve revisão da literatura sobre determinantes dos preços dos imóveis, em especial, para o caso brasileiro. A seção 3 apresenta uma discussão sobre a metodologia de dados em painel que iremos desenvolver. A seção 4 apresenta as estimações e os testes para verificar qual é o melhor modelo, além da base de dados utilizada. Na seção 5, realizamos uma análise e discussão dos resultados. Por fim, a última seção, apresenta nossas conclusões.

1

REVISÃO DE LITERATURA

1.1 Modelo teórico e literatura empírica

Em termos macroeconômicos, a dinâmica dos preços dos imóveis, segundo Égert & Mihaljek (2007), é modelada a partir da variação entre a oferta e a demanda por habitação. Pelo lado da demanda (D^h), os fatores centrais são caracterizados pela expectativa do preço dos imóveis (P^d), renda da família (Y), taxa real de juros dos empréstimos para habitação (r), riqueza financeira (Rf), fatores demográficos e mercado de trabalho (L) e expectativa de retorno sobre o bem habitação (e). Outros fatores ainda podem ser incluídos, como localização, idade e estado do imóvel, além de fatores institucionais que podem facilitar ou dificultar o acesso das famílias ao bem habitação, como inovações financeiras que possam incluir a população no mercado de moradia (Z). Formalmente, teríamos uma equação do tipo:

$$D^h = f(P^h, Y, r, Rf, L, e, Z) \quad (1.1)$$

Pelo lado da oferta, seguindo a teoria econômica tradicional, temos dois fatores centrais que influenciam numa maior ou menor oferta de imóveis: o preço do bem (P^h), que exerce uma influência positiva sobre a oferta; e os custos de produção (C), como preço da terra (P^t), salários dos trabalhadores (L) e o custo do material de construção (M), tendo uma influência negativa sobre a oferta. Formalmente, temos:

$$O^h = f(P^h, C(P^t, I, M)) \quad (1.2)$$

Para um modelo mais geral, em que oferta e demanda estejam em equilíbrio a longo prazo, o preço dos imóveis pode ser representado em termos macroeconômicos em uma forma reduzida:

$$P^h = f(P^h, Y, r, Rf, L, e, P^h, C(P^t, I, M)) \quad (1.3)$$

Todavia, como indicam Égert e Mihaljek (2007), o fato de o modelo RM apresentar uma interação dinâmica dos fatores macroeconômicos de oferta e demanda para determinação dos preços dos imóveis não significa que os preços irão se manter estáveis no curto prazo. O que se observa é uma relativa volatilidade dos preços muito maior do que os fatores que os determinam via parâmetros da oferta ou demanda do modelo. Nesse sentido, a partir da relação do mercado imobiliário e da economia urbana, há uma vasta literatura sobre a interação, volatilidade e determinantes dos preços dos imóveis, que vai desde o texto seminal do Lancaster (1966) até a retomada do interesse no assunto pela academia, decorrente da Crise Financeira Imobiliária de 2008, em um nível global, e do *boom* imobiliário na economia brasileira no início dos anos 2000, em particular.

Assim, diversos estudos, tomando diferentes recortes espaciais, investigaram os determinantes dos preços habitacionais para cidades específicas, em geral, adotando modelos de preços hedônicos. Por esse ângulo, a literatura brasileira é relativamente bem desenvolvida, ainda que seja bastante concentrada no Sudeste. Quanto aos municípios do estado de São Paulo, podemos citar Hermann e Haddad (2005), que investigaram a presença de áreas verdes ou criminalidade como elementos de externalidades sobre os preços; Fávero, Belfiore e Lima (2008) e Campos (2017), que investigaram quais atributos mais interferem nas condições de oferta e demanda e como os perfis socioeconômicos podem determinar as preferências. Para a cidade de Belo Horizonte, temos Paixão (2015), que buscou mensurar a valorização dos preços, e também Furtado (2007), que verificou o papel da localização na determinação dos preços. Com a mesma abordagem, John e Porsse (2016) analisaram os efeitos da localização e amenidades sobre os preços imobiliários para cidade de Curitiba, no sul do país. Para a região Nordeste, utilizando preços hedônicos para a cidade de Fortaleza, temos os estudos de Arraes e Sousa (2008) e, para Recife, Dantas, Magalhães e Vergolino (2007), que adotaram dependência espacial no modelo.

Todos os estudos apresentados têm em comum a análise das decisões e dos fatores que afetam a forma como as escolhas são feitas pelos agentes econômicos. Tais referências se restringem ao recorte espacial de municípios devido à qualidade dos dados requeridos para tal análise. Contudo, estudos empíricos que busquem essencialmente captar os determinantes dos preços dos imóveis

em termos macroeconômicos, para um recorte espacial amplo, ainda são poucos. Isso se deve, em parte, pela falta de indicadores sobre preços imobiliários para uma ampla variedade de municípios. Espera-se que esse cenário mude nos próximos anos em decorrência das iniciativas da Fundação Instituto de Pesquisa Econômica (Fipe), com os indicadores Fipezap, para uma ampla variedade de cidades (Fipe, 2018) e da Fundação Getúlio Vargas (FGV), com o Índice Geral do Mercado Imobiliário Comercial (IGMI-C), que buscam avançar para o residencial (FGV, 2018).

Desse modo, entre os estudos que adotam uma abordagem essencialmente macroeconômica de determinação do mercado imobiliário está o de Melo (2013), que apresenta os fatores macroeconômicos para o mercado de moradia no Ceará, como o crédito habitacional, a taxa básica de juros (Sistema Especial de Liquidação e de Custódia [Selic]), o Índice de Confiança do Consumidor, a taxa de câmbio pela paridade do poder de compra, a quantidade de unidades imobiliárias lançadas e a quantidade de unidades imobiliárias vendidas. O artigo ressaltou a importância do crédito imobiliário como importante variável macroeconômica para o mercado cearense. Há também Nakazawa (2013), que, tomando como recorte empírico os imóveis residências da cidade de São Paulo entre 2001 e 2012, pesquisou os efeitos de variáveis macroeconômicas como PIB, taxa de juros e bolsa de valores. Seus principais resultados apontam para o forte efeito do PIB sobre os preços dos imóveis e não foram encontradas evidências estatísticas sobre o efeito da bolsa de valores. Esses estudos avançam do ponto de vista de inclusão explícita de variáveis macroeconômicas, mas o recorte empírico é bastante limitado.

Já o estudo realizado por Nunes (2018) apresentou uma compilação de um amplo recorte espacial, ainda que as regiões tenham sido analisadas individualmente, sobre o impacto dos fatores macroeconômicos na formação dos preços em cinco capitais brasileiras (Belo Horizonte, Porto Alegre, Rio de Janeiro, Salvador e São Paulo) e também em nível do agregado nacional. Os resultados apontam para o importante papel do crédito na variação dos preços, tanto em nível nacional quanto para cada capital analisada. Assim, embora apresente um avanço ao realizar um estudo mais amplo no espaço, as análises foram desenvolvidas isoladamente.

Como podemos observar, a documentação acerca dos determinantes macroeconômicos dos preços dos imóveis avançou nos últimos anos. No entanto, nenhum dos estudos analisados buscou investigar uma quantidade maior de localidades de tal forma que pudessem ser verificadas e controladas as heterogeneidades individuais, ou seja, os estudos levantados ou controlavam o

tempo para uma localidade específica, chamados de modelos de séries temporais, ou controlavam as diferentes localidades para um dado ponto no tempo, modelos do tipo seccionais (*cross section*).

Nesse sentido, estudos que pudessem investigar os diferentes mercados por intermédio de uma abordagem do tipo dados em painel poderiam contribuir com a literatura empírica em busca de um aprofundamento sobre os determinantes macroeconômicos dos preços habitacionais a partir da heterogeneidade existente em diferentes localidades.

Conforme salientam Gujarati e Porter (2011), modelos que utilizam dados em painel apresentam vantagens em relação aos modelos de séries temporais ou de corte transversal, tais como: proporcionar dados com uma maior variabilidade e menor colinearidade e apresentar mais graus de liberdade e maior eficiência. Para Marques (2000), ao trabalharmos com dados em painel, temos a vantagem de medir de forma separada tanto os efeitos gerados por causa de diferenças existentes entre cada elemento do *cross section* quanto a evolução dos efeitos das variáveis ao longo do tempo em cada indivíduo, algo fundamental para nossa pesquisa, dado o objetivo proposto.

2

MODELO ECONOMÉTRICO

Os modelos de dados em painel, também chamados de dados combinados, utilizam no modelo dados originados de uma variável em relação ao tempo, isto é, uma série temporal, além de haver uma seleção de elementos de diferentes indivíduos para um período específico do tempo, ou seja, elementos em corte transversal (*cross section*). Desse modo, teremos muito mais observações, o que irá nos possibilitar maiores graus de liberdade para o trabalho empírico (Wooldrige, 2011).

O modelo teórico geral de dados em painel é dado pela seguinte equação:

$$Y_{it} = \beta_{0it} + \beta_{1it}X_{1it} + \dots + \beta_{kit}X_{kit} + \epsilon_{it} \quad (1.4)$$

O subscrito i da equação 1.4 indica os diferentes indivíduos, e o subscrito t indica o período que estamos analisando. O β_0 refere-se ao intercepto do

modelo, que, na maioria das vezes, não tem explicação econômica adequada. Do β_1 ao β_k são os coeficientes angulares relacionados à k-ésima variável explicativa do modelo.

$$y_1 = \begin{bmatrix} y_{i1} \\ y_{i2} \\ \vdots \\ y_{iT} \end{bmatrix} X_i = \begin{bmatrix} x_{1i1} & x_{2i1} & \dots & x_{ki1} \\ x_{1i2} & x_{2i2} & \dots & x_{ki2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1iT} & x_{2iT} & \dots & x_{kiT} \end{bmatrix} \beta_i = \begin{bmatrix} \beta_{0i1} & \beta_{1i1} & \beta_{2i1} & \dots & \beta_{ki1} \\ \beta_{0i2} & \beta_{1i2} & \beta_{2i2} & \dots & \beta_{ki2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \beta_{0iT} & \beta_{1iT} & \beta_{2iT} & \dots & \beta_{kiT} \end{bmatrix} e_i = \begin{bmatrix} e_{i1} \\ e_{i2} \\ \vdots \\ e_{iT} \end{bmatrix}$$

Em que y_i são as variáveis dependentes do modelo com vetores de dimensão (T x 1). Os β_i são os parâmetros a serem estimados. Os X_i de matriz de dimensão (K x T) são as variáveis explicativas do modelo. Assim, uma variável do tipo x_{kiT} refere-se à k-ésima variável explicativa para o elemento i no instante t . Por fim, e_i são os erros aleatórios da estimação, também com vetores de dimensão (T x 1).

Nesse modelo matricial mais geral, podemos verificar que o intercepto e os parâmetros são diferentes para cada elemento e para cada período. Nesse sentido, teríamos mais parâmetros desconhecidos do que observações, o que tornaria impossível sua estimativa. Para superar essa dificuldade, é necessário especificar esse modelo geral, a fim de torná-lo funcional, o que será feito por meio das suposições dadas nos modelos de efeitos fixos (MEF) e modelo de efeito aleatório (MEA).

■ 2.1 Modelo de efeitos fixos

Por meio dos MEF, segundo Gujarati e Porter (2011), é possível controlar a heterogeneidade entre os indivíduos, pois cada elemento tem o próprio intercepto permanecendo *constante* ao longo do tempo. Esse tipo de modelo sugere que cada indivíduo apresenta características internas que divergem das outras variáveis do modelo, mas os coeficientes angulares não variam entre os indivíduos ou no tempo.

O MEF é formalmente apresentado da seguinte forma:

$$Y_{it} = \alpha_i + \beta_1 X_{1it} + \dots + \beta_k X_{kit} + \varepsilon_{it} \quad (1.5)$$

A forma matricial para o i -ésimo indivíduo é apresentado em Greene (1998) como:

$$\begin{bmatrix} y_{i1} \\ y_{i2} \\ \vdots \\ y_{iT} \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \alpha_i + \begin{bmatrix} x_{1i1} & x_{2i1} & \dots & x_{Ki1} \\ x_{1i2} & x_{2i2} & \dots & x_{Ki2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1iT} & x_{2iT} & \dots & x_{KiT} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix} \begin{bmatrix} e_{i1} \\ e_{i2} \\ \vdots \\ e_{iT} \end{bmatrix}$$

Para esse modelo, os α_i são os parâmetros do intercepto que será estimado para cada indivíduo, desse modo, como já mencionado, esses parâmetros não variam entre os indivíduos, bem como não variam em relação ao tempo. Todas as variações de comportamento entre os indivíduos deverão ser captadas pelos interceptos. Os α_i , portanto, são analisados como os efeitos das variáveis omitidas.

Por fim, espera-se que os α_i sejam correlacionados com as variáveis explicativas do modelo, assim, o melhor modelo seria, conforme afirma Gujarati e Porter (2011), o MEF. Por isso, para além dos testes de robustez, o bom conhecimento sobre os dados por parte do pesquisador é imprescindível para uma melhor escolha do modelo.

■ 2.2 Modelos de efeitos aleatórios

A diferença principal entre os MEF e MEA é em relação ao tratamento dado ao comportamento do intercepto das equações estimadas, pois, para ambos modelos, o intercepto apresenta variação de um indivíduo para outro. Todavia, não varia em relação ao tempo. Os parâmetros explicativos, para ambos os modelos, não variam entre todos os indivíduos e em qualquer tempo analisado.

Assim, para o –MEF, o intercepto de parâmetros é *fixo* e, para o –MEA, o intercepto é entendido como uma variável *aleatória*. Segundo Wooldrige (2011), para MEA, os indivíduos analisados são amostras aleatórias de uma população maior.

O MEA é dado da seguinte forma:

$$Y_{it} = \bar{\beta}_0 + \beta_1 X_{1it} + \dots + \beta_k X_{kit} + vit; \text{ onde: } v_{it} = \epsilon_{it} + \alpha_i \quad (1.6)$$

Em que $\bar{\beta}_0$, é o intercepto populacional; v_{it} , o erro estocástico, representado pelo ε_{it} e pelo α_i , que capta o intercepto do MEF. Matricialmente para o i -ésimo indivíduo, temos:

$$\begin{bmatrix} y_{i1} \\ y_{i2} \\ \vdots \\ y_{iT} \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \bar{\beta}_0 + \begin{bmatrix} x_{1i1} & x_{2i1} & \dots & x_{Ki1} \\ x_{1i2} & x_{2i2} & \dots & x_{Ki2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1iT} & x_{2iT} & \dots & x_{KiT} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix} \begin{bmatrix} e_{i1} \\ e_{i2} \\ \vdots \\ e_{iT} \end{bmatrix}$$

Para a escolha de qual dos modelos, fixo ou aleatório, seria o mais adequado para os dados com que estamos trabalhando, vamos realizar os testes já consolidados pela literatura, a saber: Hausman, Wald e Teste F.

3

MODELO ESTÁTICO DOS DETERMINANTES DO MERCADO HABITACIONAL BRASILEIRO

O modelo econométrico que iremos adotar no presente artigo será o modelo estático de regressão com dados em painel, por meio do qual apresentaremos, para fins de comparação, as estimações por mínimos quadrados ordinários (MQO) para dados em painel (*pooled OLS*), além do efeito aleatório (EA) e do efeito fixo (EF). Para escolha do melhor modelo, utilizaremos testes específicos de robustez.

A metodologia para modelar e estimar os determinantes do mercado habitacional brasileiro, utilizando dados em painel, será desenvolvida a partir do seguinte conjunto de passos:

1. formulação das hipóteses sobre os determinantes do mercado habitacional à luz da teoria econômica;
2. especificação do modelo estático com dados em painel, identificando as principais variáveis;
3. descrição das variáveis e levantamento dos dados;
4. modelagem e estimação dos determinantes;
5. testes de especificação; e
6. análise dos resultados.

■ 3.1 Hipóteses e formulação do modelo

Para investigar os determinantes do mercado habitacional, é necessário especificar quais são os determinantes mais explícitos no mercado que buscamos modelar, assim como a relação funcional que existe entre as variáveis.

Como hipótese subjacente ao nosso modelo de determinação do preço do imóvel, trabalhamos com uma defasagem (um *lag*) no que diz respeito ao impacto das variáveis explicativas sobre nossa variável dependente, pois partimos do pressuposto de que a decisão de comprar ou vender um imóvel exige certo grau de amadurecimento dos parâmetros macroeconômicos (em nosso caso, um ano) e renda formal, como garantia de colateral financeiro. O produto, a renda e os custos pressionam positivamente os preços dos imóveis, enquanto a taxa de juros e o volume de crédito pressionam no sentido contrário.

■ 3.2 Base de dados

Recorte espacial

A pesquisa trabalha com as 13 regiões metropolitanas que o IBGE acompanha, por meio do Sistema Nacional de Índices de Preços ao Consumidor (Snipc), conforme Nota Técnica 03/2013 (IBGE, 2013), sendo, também, as regiões que o Banco Central do Brasil (Bacen) acompanha, por meio do Índice de Valores de Garantia de Imóveis Residenciais Financiados (IVG-R), nossa variável dependente (Bacen, 2018).

Sendo assim, nossas regiões metropolitanas são: 1) RM Belém; 2) RM Belo Horizonte; 3) RM Campina Grande; 4) RM Curitiba; 5) RM Fortaleza; 6) RM Goiânia; 7) RM Porto Alegre; 8) RM Recife; 9) RM Rio de Janeiro; 10) RM Salvador; 11) RM São Paulo; 12) RM Grande Vitória e 13) Região Integrada de Desenvolvimento do Distrito Federal e Entorno (Ride).

Cada região metropolitana é composta por municípios que, em conjunto, formam nosso recorte espacial de interesse. A relação de todos os municípios que fazem parte de cada RM está disponibilizada no site oficial do IBGE¹.

1 Cf. Seção. Organização territorial. Estrutura territorial. Recuperado em 16 fevereiro, 2021, de www.ibge.gov.br.

Recorte temporal

Nosso recorte temporal abrange o período de 2004 a 2016. A data inicial se deve à mudança no perfil da atuação da política monetária e de uma nova configuração dos principais indicadores macroeconômicos (Mendonça, 2013), além de demarcar a nova atuação no cenário político nacional que foi a eleição do primeiro mandato do governo do Partido dos Trabalhadores (PT), desde o primeiro mandato do presidente Luiz Inácio Lula da Silva até a cassação, em 2016, do segundo mandato de Dilma Rousseff, o que totalizou 13 anos de dados para nossas análises.

Outra justificativa para o recorte temporal decorre do fato de se buscar manter um painel de dados balanceado, pois, ainda que alguns indicadores tenham disponibilidade para o mês anterior à pesquisa, outros indicadores de interesse apresentam uma relativa demora para serem disponibilizados de forma desagregada por município, como é o caso do PIB municipal, por exemplo. Outro ajuste metodológico para manter o painel balanceado é a utilização de dados anualizados.

Variável dependente

Tendo como objetivo investigar os determinantes macroeconômicos dos preços dos imóveis das RM, nossa variável dependente é, portanto, algum indicador de acompanhamento dos preços dos imóveis desse recorte espacial. No entanto, para as pesquisas empíricas desse tipo, a seleção de uma amostra com uma série de dados, longa no tempo e ampla no espaço, é o ponto de maior dificuldade, pois o Brasil ainda não tem uma grande tradição na coleta, no controle e acesso público a essas informações.

No que tange a esse ponto, a variável mais comum tem recaído sobre os indicadores da Fipezap, que trabalha com os dados de oferta *on-line* dos imóveis em diversas cidades do país. Há ainda estudos que trabalham com o IVG-R ou outros indicadores mais locais (Brando & Barbedo, 2016).

O indicador Fipezap ainda se encontra com séries históricas curtas para uma quantidade grande de cidades. Por outro lado, o IVG-R apresenta uma série mais longa, tendo início em 2001, de forma agregada, para um conjunto de regiões metropolitanas. Há ainda o esforço da Fundação Getulio Vargas (FGV), ao desenvolver Índice Geral do Mercado Imobiliário Residencial da Associação Brasileira das Entidades de Crédito Imobiliário e Poupança (IGMI-R/Abecip), que acompanha os preços de ativos imobiliários no país desde 2014.

Sendo assim, a variável dependente que optamos no presente estudo será o Índice de Valores de Garantia de Imóveis Residenciais Financiados (IVG-R), que faz o acompanhamento dos valores das avaliações dos imóveis dados em garantia aos financiamentos imobiliários das pessoas físicas (Bacen, 2018), disponibilizado pelo Bacen para cada RM, em número índice de 2004. Utilizaremos a letra Y , na função dos determinantes dos preços dos imóveis (Equação 1.4).

Variáveis independentes

As variáveis explicativas compreendem um conjunto de dados dividido em quatro grandes categorias:

1. *Crescimento econômico*: tem como variável o PIB (Y) de todas as cidades que compõem a RM do nosso recorte espacial, que é disponibilizado IBGE;
2. *Crédito*: tem como variável o volume de crédito habitacional efetivamente disponibilizado pelo mercado (F) e taxa de juros representada pela Selic (R), ambas as variáveis são disponibilizadas na plataforma de séries temporais do Bacen;
3. *Trabalho e renda*: renda média mensal municipal (I) e volume de contratações formais (L), sendo disponibilizados pelo Ministério do Trabalho e Emprego (MTE) via Cadastro Geral de Empregados e Desempregados (Caged);
4. *Custo*: custo para contratação da mão de obra e aquisição de materiais. Utilizaremos o Índice de Custo da Construção Civil, disponibilizado pelo Sistema Nacional de Pesquisa de Custos e Índices da Construção Civil (Sinapi), que é uma produção conjunta do IBGE com a Caixa Econômica Federal (Caixa), simbolizada pela letra C .

Para uma melhor visualização e apresentação das variáveis independentes, as categorias, símbolos, unidades de medida e fonte dos dados são sumarizados conforme apresentado na Tabela 1:

Tabela 1

Caracterização das variáveis independentes

| Categoria | Variável | Descrição / Unidade | Fonte |
|-----------------------|----------|--|------------|
| Crescimento econômico | Y | PIB/R\$ | IBGE |
| Crédito | F | Volume de Crédito habitacional/R\$ | Bacen |
| Crédito | R | Taxa de juros – Selic/porcentagem | Bacen |
| Trabalho e renda | I | Renda média mensal municipal/R\$ | MTE/Caged |
| Trabalho e renda | L | Volume de contratações formais/milhares de contratações | MTE/Caged |
| Custo | C | Índice de Custo da Construção Civil/número índice (Base100 = jun/94) | IBGE/Caixa |

Fonte: Elaborada pelos autores.

3.3 Função macroeconômica de determinação do preço do imóvel e forma funcional

No presente trabalho, os fatores macroeconômicos determinantes dos preços dos imóveis residenciais nas 13 RM brasileiras serão desenvolvidos por meio de um modelo econométrico a ser estimado, com dados em painel, representado pela seguinte equação geral:

$$P_{it}^h = \alpha_i + \beta_1 Y_{it} + \beta_2 F_{it} + \beta_3 R_{it} + \beta_4 I_{it} + \beta_5 L_{it} + \beta_6 C_{it} + \epsilon_{it} \quad (1.7)$$

Em que P_{it}^h se refere à variável dependente do modelo, e cada RM é representada pelo subscrito i e cada período, por t . O β_1 ao β_6 são os parâmetros a serem estimados no modelo. O α_i , diz respeito ao intercepto. Os elementos Y_{it} , F_{it} , R_{it} , I_{it} , L_{it} e C_{it} são nossas variáveis explicativas, conforme apresentado anteriormente, e ϵ_{it} é o erro aleatório.

Para uma melhor explicação dos resultados, adotamos a forma funcional logarítmica, por meio da qual poderemos verificar os efeitos da elasticidade das variáveis explicativas sobre a variável dependente, exceto tendência. No entanto, a variável L não foi logaritimizada, pois se trata de uma variável de fluxo, ou seja, apresenta valores positivos e negativos. Assim, trabalhamos com essa variável como log-nível.

Nesse sentido, a função dos determinantes macroeconômicos dos preços dos imóveis apresenta a seguinte forma funcional:

$$\ln P_{it}^h = \alpha_i + \beta_1 \ln Y_{it} + \beta_2 \ln F_{it} + \beta_3 \ln R_{it} + \beta_4 \ln I_{it} + \beta_5 \ln L_{it} + \beta_6 \ln C_{it} + \epsilon_{it} \quad (1.8)$$

Como consequência da forma funcional logarítmica e log-nível da equação 1.8, os coeficientes estimados do modelo podem ser considerados elasticidades, ou seja, a partir das estimações realizadas pelos nossos modelos, apresentaram-se os efeitos da variação de 1% em alguma das variáveis independentes sobre os preços (variável dependente).

4


ANÁLISE E DISCUSSÃO DOS RESULTADOS

■ 4.1 Estatística descritiva

Para uma primeira aproximação com os dados da pesquisa, apresentamos a evolução dos preços em número-índice, tendo como base o ano de 2004 das 13 RM, conforme Figura 1.

Figura 1

IVG-R por região metropolitana selecionada



Fonte: Bacen (2018).

Como podemos observar na Figura 1, todas as regiões analisadas apresentaram uma forte expansão no comportamento dos preços, tendo um amortecimento nesse crescimento em meados de 2014. Nesse sentido, nosso objetivo é investigar quais variáveis se apresentaram como determinantes para o período analisado por meio de um painel de dados estático.

Seguindo nossa análise descritiva dos dados, a Tabela 2 apresenta os principais resultados estatísticos dos indicadores macroeconômicos analisados.

Tabela 2

Estatística descritiva dos dados

| | P | Y | I | F | R | L | C |
|---------------|--------|-----------|----------|------------|-------|-------|--------|
| Média | 280,14 | 5.866,67 | 834,46 | 12.429,90 | 12,38 | 10,08 | 373,72 |
| Mediana | 265,70 | 3.936,85 | 776,47 | 3.528,52 | 11,88 | 7,90 | 379,18 |
| Máximo | 628,90 | 28.406,86 | 1.601,92 | 213.762,80 | 19,05 | 54,37 | 551,10 |
| Mínimo | 96,80 | 151,46 | 323,15 | 36,48 | 8,22 | -6,68 | 225,01 |
| Desvio padrão | 133,92 | 5.723,64 | 293,94 | 29.962,83 | 3,03 | 10,12 | 84,53 |
| Assimetria | 0,40 | 2,01 | 0,43 | 4,89 | 0,59 | 1,91 | 0,10 |
| Curtosa | 2,20 | 6,91 | 2,33 | 28,80 | 2,67 | 7,52 | 1,91 |
| Observações | 169 | 169 | 169 | 169 | 169 | 169 | 169 |

Fonte: Elaborada pelos autores.

A Tabela 2 tem como objetivo central fornecer uma visão das estatísticas descritivas das 169 observações de forma agregada e, assim, apontar possíveis erros de contagem ou distorções provocadas pela presença de *outliers*.

Em decorrência de as variáveis econômicas terem uma tendência a colinearidade, realizamos uma análise de correlação das variáveis utilizadas para verificar possíveis situações de multicolinearidade. Conforme pode ser observado na Tabela 3, apresentamos a matriz de correlação das variáveis independentes do período analisado, 2004 a 2016.

Tabela 3

Matriz de correlação entre as variáveis independentes do modelo

| | Y | I | F | R | L | C |
|---|------|------|------|------|------|------|
| Y | 1,00 | | | | | |
| I | 0,56 | 1,00 | | | | |
| F | 0,79 | 0,51 | 1,00 | | | |
| R | 0,18 | 0,38 | 0,11 | 1,00 | | |
| L | 0,52 | 0,01 | 0,31 | 0,26 | 1,00 | |
| C | 0,32 | 0,87 | 0,32 | 0,49 | 0,12 | 1,00 |

Fonte: Elaborada pelos autores.

O que podemos verificar na Tabela 3, de modo geral, é que as variáveis independentes não apresentam alta correlação, ou seja, acima de 0,70, com exceção do custo (C) e da renda formal (I), com 0,87 – provavelmente por causa da variável C que já seja capaz de capturar as variações do custo da mão de obra. Vale notar também a relação entre PIB (Y) e financiamento imobiliário (F), com 0,79, o que se justifica pelo debate já consagrado sobre o papel do crédito em influenciar variáveis do lado real da economia.

4.2 Análise dos dados em painel

Para o nosso modelo com dados em painel estático, a partir do modelo econométrico geral adotado na Equação 1.8, estimamos inicialmente os seguintes modelos para dados agrupados por *cross section* e empilhados no tempo: MQO ou *pooling*, em seguida o MEF e, por fim, o MEA. Os resultados das estimações encontram-se na Tabela 4.

Tabela 4

Resultados das estimações – modelo estático de dados em painel

| P | MQO | MEF | MEA |
|----------------|-------------|-------------|-------------|
| Y | -0,0860 *** | 1,2281 *** | 0,0631 |
| | (-3,63) | (7,66) | (0,98) |
| I | 0,4135 *** | -0,1183 | 0,4034 ** |
| | (3,27) | (-0,73) | (2,47) |
| F | -0,0369 * | -0,1571 *** | -0,0908 *** |
| | (-1,94) | (-4,67) | (-2,68) |
| R | -0,3812 *** | -0,2756 *** | -0,3453 *** |
| | (-5,04) | (-5,55) | (-6,07) |
| L | 0,0047 *** | 0,0039 *** | 0,0045 *** |
| | (2,63) | (2,63) | (2,65) |
| C | 1,4660 *** | 0,7002 *** | 1,5592 *** |
| | (10,06) | (3,08) | (7,53) |
| Constante | -3,8710 *** | -5,9267 *** | -5,2327 *** |
| | (-5,233) | (-7,20) | (-6,03) |
| R ² | 0,8955 | 0,9684 | 0,82 |

Notas: 1) níveis de significância: ***: significativo a 1%; **: significativo a 5%; *: significativo a 10%. 2) As estatísticas t e z (MEA) estão entre parênteses.

Fonte: Elaborada pelos autores.

Para que possamos escolher qual é o melhor modelo, dentre os três apresentados na Tabela 4, realizamos testes de especificidade para dados em painel buscando verificar a robustez de cada um.

Testes de especificidade para dados em painel

Os testes de especificidades de um modelo com dados em painel são utilizados para verificar quais são os efeitos presentes nos dados em painel, se são aleatórios no tempo ou fixos, ou ainda, se o modelo mais apropriado seria considerar um modelo com dados *pooled* (MQO). Dessa forma, nosso primeiro teste é o Teste F, conforme Equação 1.8, para analisar se devemos utilizar os MQO ou o MEF.

O resultado do Teste F foi:

$$F_{(6,149)} = 212,8854 \text{ com } p\text{-value } (F) = (0,0) \quad (1.9)$$

Como podemos verificar, o Teste $F_{\text{calculado}}$ de 212,8854 é maior que o Teste F_{critico} com um *p-value* de 0,0, ou seja, a hipótese nula de que os coeficientes do modelo sejam homogêneos é rejeitada. Assim, o modelo de dados do tipo MQO poderá ser rejeitado.

Essa rejeição, tomando como base o resultado do Teste F (Equação 1.9), já era esperada pelas próprias características heterogêneas de cada RM, como atividade econômica ou crescimento populacional.

Para confirmar nossa rejeição dos MQO, podemos realizar ainda o Teste de Wald, que também tem como objetivo verificar se o MEF é preferível em relação ao modelo empilhado (*pooling*). Assim, segundo o Teste de Wald, o resultado precisaria ser de um *p-value* menor que o valor de 0,05, o que é confirmado com o resultado de 0,0000 do Teste F apresentado. Desse modo, rejeitamos a hipótese nula de que o melhor modelo é o dos MQO.

Tabela 5

Teste de Wald

| Estatística de teste | Valor | Graus de liberdade (GL) | Probabilidade |
|----------------------|----------|-------------------------|---------------|
| F-statistic | 85717.82 | (7,137) | 0.0000 |
| Chi-square | 600024.8 | 7 | 0.0000 |

Fonte: Elaborada pelos autores.

Agora devemos verificar se o melhor modelo seria com EF ou com EA. Para isso, realizaremos o Teste de Hausman, que busca verificar a presença de EA em dados em painel cujos coeficientes não sejam homogêneos.

Assim, o Teste de Hausman compara as estimativas do MEA com as estimativas do MEF. Caso existam diferenças significativas entre os modelos, isso indicaria que há inconsistência entre os estimadores com EA. Em outras palavras, na hipótese nula, o Teste Hausman assume que os estimadores com EA são consistentes.

Para realizarmos o Teste de Hausman, é necessário estimar o MEA – o que já foi feito, conforme apresentado na Tabela 4. O resultado do teste encontra-se na Tabela 6.

Tabela 6

Teste de Hausman

| Resumo do teste | Chi-square statistic | Chi-square GL | Probabilidade |
|-----------------------------|----------------------|---------------|---------------|
| <i>Cross-section random</i> | 60,521 | 6 | 0.0000 |

Fonte: Elaborada pelos autores.

Como o valor do $\chi^2_{\text{calculado}}$ é igual a 60,521 com seis graus de liberdade (Tabela 6), sendo esse valor maior que o $\chi^2_{\text{critico}} = 12,592$, a 5% (12,592), rejeitamos a hipótese de que o melhor modelo seja o MEA. A probabilidade 0,00 confirma o resultado da estatística do teste. Assim, nossa hipótese nula será

rejeitada, indicando que o modelo mais adequado para estimar nossos dados em painel é o MEF.

Modelagem e estimação

Por fim, tomando como referência os resultados de especificidade realizados, e em busca de um melhor ajuste da estimação com dados em painel, consideraremos a estimação do MEF, conforme Equação 1.8.

Na primeira estimação, como apresentado na Tabela 4, a especificação do modelo foi de 96,84% (R^2), já muito boa. No entanto, a renda (I) não apresentou nível de significância nem mesmo a 10% (*p-value*), ou seja, mesmo trabalhando com uma defasagem (*lag*) de um ano, os dados não se demonstraram significativos.

Desse modo, realizamos uma nova estimação sem considerar I, com ou sem *lags*. A primeira e a segunda estimação estão disponíveis na Tabela 7 para fins de comparações.

Tabela 7

Estimações dos modelos com efeitos fixos

| Variável | Primeira estimação | | Segunda estimação | |
|-----------|--------------------|----------------|-------------------|----------------|
| | Coefficiente | <i>p-value</i> | Coefficiente | <i>p-value</i> |
| Y | 1,2281 | 0,0000 | 1,1695 | 0,0000 |
| I | -0,1183 | 0,4622 | | |
| F | -0,1571 | 0,0000 | -0,1613 | 0,0000 |
| R | -0,2756 | 0,0000 | -0,2778 | 0,0000 |
| L | 0,0039 | 0,0094 | 0,0043 | 0,0023 |
| C | 0,7002 | 0,0025 | 0,6514 | 0,0032 |
| Constante | -5,9267 | 0,0000 | -5,9087 | 0,0000 |
| R^2 | 0,9684 | | 0,9683 | |

Fonte: Elaborada pelos autores.

Após nosso ajuste para a segunda estimação, temos a manutenção tanto dos sinais dos coeficientes quanto dos resultados, de forma muito próxima dos valores da primeira estimação, entretanto, todas as variáveis são agora estatisticamente significativas, até mesmo a 1%. Assim, nosso modelo final ainda apresenta uma excelente especificação $R^2 = 0,9683$, sendo apresentada pela Equação 1.10:

$$\begin{aligned} \hat{\ln}P_h = & -5,9087 + 1,1695\ln Y_{(-1)} + 0,6514\ln C_{(-1)} - 0,1613\ln F_{(-1)} \\ & \quad \quad \quad (0,8204) \quad \quad \quad (0,1388) \quad \quad \quad (0,2168) \quad \quad \quad (0,0331) \\ & -0,2778\ln R_{(-1)} + 0,0043L_{(-1)} - \hat{\theta}_I \\ & \quad \quad \quad (0,0494) \quad \quad \quad (0,0013) \end{aligned} \quad (1.10)$$

Desse modo, tomando como base a Equação 1.10, podemos estimar, analisar e discutir os resultados, o que será realizado na próxima seção.

■ 4.3 Discussão dos resultados

Assim, ao estimar o nosso modelo estático de dados em painel para o mercado imobiliário brasileiro, com base nos resultados apresentados na Equação 1.10, podemos concluir que, corroborando a literatura econômica, o PIB (Y) e o preço dos imóveis apresentam uma relação positiva e elasticidade (coeficiente > 1), assim como custo (C), apesar de não elástico.

Já o volume de trabalho (L), apresentou uma elasticidade quase neutra, 0,0043, mesmo sendo estatisticamente significativo. Por fim, tanto a taxa de juros (R) quanto os volumes de financiamento (F) seguiram a literatura especializada, que aponta que há uma relação inversa entre taxa de juros e preço, em que o volume de financiamento é tratado como um estoque de recursos disponibilizados pelo mercado. Os juros apresentaram uma maior sensibilidade às variações no preço, com 0,2778, que o volume de financiamento, com 0,1612. Isso indica uma maior efetividade do manejo da política monetária via juros.

Uma última ponderação diz respeito ao papel da exclusão da renda média formal (I) da segunda estimação, pois, ainda no escopo da teoria econômica tradicional e com base nas hipóteses do nosso modelo, esperávamos que fosse estatisticamente significativa. Uma possível resposta pode estar no fato de termos utilizado apenas um ano (um *lag*), o que poderia não ser suficiente para

gerar efeitos em nosso modelo estático. Sendo assim, uma forma de ampliar o estudo seria realizar testes específicos para escolha de *lags* ou tornar nosso modelo dinâmico, ou seja, incluir a variação passada dos preços como uma variável explicativa do modelo.

5 CONCLUSÕES

O artigo teve como objetivo analisar os determinantes macroeconômicos dos preços dos imóveis no Brasil por meio de um painel estático, no qual empilhamos as 13 RM brasileiras de modo a captar os possíveis efeitos que pudessem existir decorrentes de fatores específicos presentes em cada região no período de 2003 a 2016. Para controlar os fatores espaciais na determinação dos preços, escolhemos como técnica de pesquisa a utilização de um modelo estático com dados em painel, empilhando as RM para controlar as especificidades presentes em cada região.

Desse modo, os resultados apresentados nos dão alguns indícios sobre quais fatores macroeconômicos exerceram uma maior ou menor influência na variação dos preços dos imóveis residenciais no Brasil no período analisado. Os resultados empíricos encontrados neste trabalho corroboram a literatura especializada ao apontarem para a sensibilidade dos preços dos imóveis de 1,1695 em relação ao PIB (Y). Isso demonstra uma forte relação entre o nível de atividade da economia e a consequente pressão sobre os preços no setor imobiliário.

Variáveis monetárias como volume de financiamento (F) e taxa de juros (R) apresentaram uma menor sensibilidade (elasticidade menor do que 1), e a taxa de juros Selic foi a que se apresentou como a mais importante variável dentre as variáveis monetárias, tendo uma sensibilidade de 0,2778 contra 0,1613 do volume de financiamento. Assim, a taxa de juros foi uma importante ferramenta de ajuste dos preços para o mercado de imóveis. A renda média formal do trabalho (I) não apresentou significância estatística. No entanto, tal limitação em nosso modelo poderia ser decorrente da utilização inadequada ou ainda insuficiente de *lags*, pois adotamos como hipótese a existência de um *lag*, ou seja, as variáveis macroeconômicas só passariam a exercer influência no nível geral dos preços dos imóveis após um ano, embora mais *lags* pudessem ser necessários para essa variável.

Acrescentamos à limitação apresentada o fato de utilizarmos como método de estimação de dados em painel a sua forma estática, visto que é importante que futuras pesquisas ponham em relevo a hipótese de haver interação dinâmica entre os preços, tomando como base os valores defasados dos preços do próprio bem para a formação do preço futuro, a fim de verificar as consequências para a formação do preço, incluindo, dessa forma, uma perceptiva inercial e dinâmica ao modelo.

MACROECONOMIC DETERMINANTS OF BRAZILIAN HOUSING MARKET PRICES: A PANEL DATA APPROACH

Abstract

This article investigated the macroeconomic determinants of residential property prices in the 13 Brazilian metropolitan regions between 2004 and 2016. We use it as a method of research estimates of models with panel data. We conducted specificity and robustness tests to find the best model. The main result estimated was for the gross domestic product (GDP), because of the positive elasticity and higher than 1 and an inverse relation with the Special Settlement and Custody System interest rate (Sistema Especial de Liquidação e de Custódia – Selic). Therefore, our conclusions point to the need for a strong recovery of the Brazilian economy in the short term, especially the GDP, and a significant reduction of Selic, which has already occurred, for the residential real estate sector to resume its growth trajectory.

Keywords: Price cycle; panel data; real estate prices; metropolitan region; macroeconomic determinants.

JEL classification: D40; R20; C23; R29; E30.

Referências

Arraes, R., & Sousa, E., Filho (2008). Externalidades e formação de preços no mercado imobiliário urbano brasileiro: Um estudo de caso. *Economia Aplicada*, 12(2), 289-319. doi:10.1590/S1413-80502008000200006

- Banco Central do Brasil (Bacen). (2018). Organizações. BCB/Desig. Índice de Valores de Garantia de Imóveis Residenciais Financiados (IVG-R). Recuperado 16 fevereiro, 2021, de <https://dadosabertos.bcb.gov.br/dataset/21340-indice-de-valores-de-garantia-de-imoveis-residenciais-financiados-ivg-r>
- Brando, L., & Barbedo, C. H. (2016). Há fatores não econômicos na formação do preço de imóveis? *Revista de Administração Contemporânea – RAC*, 20(1), 106-130. doi:10.1590/1982-7849rac2016140095
- Campos, R. B. A. (2017). O mercado imobiliário residencial no município de São Paulo: Uma abordagem de preços hedônicos espacial. *Nova Economia*, 27(1), 303-337. doi:10.1590/0103-6351/2441
- Cerutti, E., Dagher, J., & Dell’Ariccia, G. (2017). Housing finance and real-estate booms: A cross-country perspective. *Journal of Housing Economics*, 38, 1-13. doi:10.1016/J.JHE.2017.02.001
- Dantas, R. A., Magalhães, A. M., & Vergolino, J. R. de O. (2007). Avaliação de imóveis: A importância dos vizinhos no caso de Recife. *Economia Aplicada*, 11(2), 231-251. doi:10.1590/S1413-80502007000200004
- Égert, B., & Mihaljek, D. (2007). Determinants of house prices in central and eastern Europe. *Comparative Economic Studies*, 49(3), 367-388. doi:10.1057/palgrave.ces.8100221
- Fávero, L. P. L., Belfiore, P. P., & Lima, G. A. S. F. (2008). Modelos de precificação hedônica de imóveis residenciais na região metropolitana de São Paulo: Uma abordagem sob as perspectivas da demanda e da oferta. *Estudos Econômicos*, 38, 73-96. doi:10.1590/S0101-41612008000100004
- Fundação Instituto de Pesquisas Econômicas (Fipe). (2018). Índice mensal. Recuperado em 6 agosto, 2020, de <http://www.fipe.org.br/pt-br/indices/fipezap/#indice-mensal>
- Furtado, B. (2007). Mercado imobiliário e a importância das características locais: Uma análise quantílico-espacial de preços hedônicos em Belo Horizonte. *Análise Econômica*, 25(48), 71-98. doi:10.22456/2176-5456.10881
- Greene, W. (2012). *Econometric Analysis*. 7th ed. Boston, MA: Prentice Hall.
- Gujarati, D., & Porter, D. (2011). *Econometria* (5a. ed.). Porto Alegre: Amgh Editora.
- Hermann, B. M., & Haddad, E. A. (2005). Mercado imobiliário e amenidades urbanas: A view through the window. *Estudos Econômicos*, 35(2), 237-269. doi:10.1590/S0101-41612005000200001
- Instituto Brasileiro de Geografia e Estatística (IBGE). (2013). *Nota Técnica 03/2013 – IPCA e INPC Ampliação da Abrangência geográfica*. Recuperado em 29 outubro, 2019, de https://ftp.ibge.gov.br/Preços_Indices_de_Precos_ao_Consumidor/Sistema_de_Indices_de_Precos_ao_Consumidor/Notas_Tecnicas/snipc_nota_tecnica_2013_03.pdf
- Instituto Brasileiro de Geografia e Estatística (IBGE). (2018a). Cadastro Geral de Empregados e Desempregados – CAGED. Recuperado em 15 outubro, 2019, de <https://www.ibge.gov.br/estatisticas/downloads-estatisticas.html>
- Instituto Brasileiro de Geografia e Estatística (IBGE). (2018b). Estatísticas. Downloads. Contas Nacionais. Recuperado em 15 outubro, 2019, de https://downloads.ibge.gov.br/downloads_estatisticas.htm

- John, E. M. C., & Porsse, A. A. (2016). Análise de preços hedônicos no mercado imobiliário de apartamentos em Curitiba. *Revista Paranaense de Desenvolvimento*, 37(130), 99-115.
- Lancaster, K. (1966). A new approach to consumer theory. *The Journal of Political Economy*, 74(2), 132-157. doi:10.1086/226550
- Lucena, J. M. P. de. (1981). *O mercado habitacional no Brasil*. (Tese de doutorado, Escola de Pós-Graduação em Economia, Fundação Getulio Vargas, Rio de Janeiro, RJ, Brasil).
- Marques, L. D. (2000). Modelos dinâmicos com dados em painel: revisão de literatura. *Centro de Estudos Macroeconômicos e Previsão*, Faculdade de Economia do Porto. doi:10.1007/BF02850746
- Melo, M. M. (2013). Fatores macroeconômicos determinantes do mercado imobiliário do estado do Ceará. *Revista Nexos Econômicos*, 6(1), 35-59. doi:10.9771/1516-9022rene.v6i1.7951
- Mendonça, M. J. C. (2013). O crédito imobiliário no Brasil e sua relação com a política monetária. *Revista Brasileira de Economia*, 67(4), 457-495. doi:10.1590/S0034-71402013000400005
- Nakazawa, D. K. (2013). *Fatores determinantes do preço de imóveis* (Dissertação de mestrado, Escola de Economia de São Paulo, Fundação Getulio Vargas, São Paulo, SP, Brasil).
- Nunes, G. S. Z. (2018). *Fatores macroeconômicos que determinam o preço dos imóveis e as diferentes elasticidades por região* – (Dissertação de mestrado, Escola de Pós-Graduação em Economia, Fundação Getulio Vargas, Rio de Janeiro, RJ, Brasil).
- Oliveira, M. M. de, & Almeida, A. C. L. (2014). Testing for rational speculative bubbles in the Brazilian residential real-estate market. In A. A. C. L. (Ed.), *Risk management post financial crisis: A period of monetary easing* (Vol. 96, pp. 401-416). Emerald Group Publishing Limited. doi:10.1108/S1569-375920140000096017
- Otto, S. (2015). Real estate policy in Brazil and some comparisons with the United States. (Working Paper No. 549). Stanford, CA: Stanford University. Recuperado em 5 junho, 2019, de <https://globalpoverty.stanford.edu/publications/real-estate-policy-brazil-and-some-comparisons-united-states>
- Paixão, L. A. R. (2015). Índice de preços hedônicos para imóveis: Uma análise para o município de Belo Horizonte. *Economia Aplicada*, 19(1), 5-29. doi:10.1590/1413-8050/ea36708
- Wheaton, W. C. (1999). Real estate “cycles”: Some fundamentals. *Real Estate Economics*, 27(2), 209-230. doi:10.1111/1540-6229.00772
- Wooldrige, J. M. (2011). Econometric analysis of cross section and panel data. *Neurology Secrets*, 7, i-ii. doi:10.1515/humr.2003.021