

# Modelagem Preditiva do IFIX com Deep Learning

Edison Tito \*

Fernando Aiube †

Marlon M. López-Flores ‡

24 de janeiro de 2025

## Resumo

A participação de investidores no mercado de fundos imobiliários no Brasil tem crescido de forma significativa. Como consequência, observou-se um aumento do interesse dos agentes econômicos na previsão dos preços nesse mercado. Este artigo analisa a previsão do Índice de Fundos Imobiliários (IFIX) utilizando dois métodos: o modelo clássico de séries temporais ARMA-GARCH e redes neurais com a arquitetura *Long Short-Term Memory* (LSTM). Os resultados demonstram que a capacidade preditiva do modelo baseado em redes LSTM supera, de maneira significativa, o desempenho do método clássico.

**Palavras-chave:** Fundos de Investimento Imobiliário; IFIX; LSTM; Deep Learning; Machine Learning

**Código JEL:** C22; C45

## 1 Introdução

O mercado imobiliário brasileiro desempenha um papel crucial na economia nacional, contribuindo significativamente para o Produto Interno Bruto (PIB) e sendo um dos principais geradores de emprego no país. Nesse contexto, os Fundos de Investimento Imobiliários (FIIs) surgem como instrumentos financeiros que permitem aos investidores participarem do mercado imobiliário de forma indireta. Esses fundos oferecem vantagens como diversificação de portfólio, maior liquidez em relação à posse direta de imóveis e benefícios fiscais, incluindo isenção de imposto de renda sobre os rendimentos distribuídos a pessoas físicas, desde que atendidas determinadas condições.

O Índice de Fundos de Investimento Imobiliário (IFIX), calculado pela B3 (Brasil, Bolsa, Balcão), serve como referência para o desempenho dos FIIs no Brasil, refletindo a variação média dos preços das cotas dos principais fundos negociados no mercado. A previsão precisa do IFIX é essencial para investidores e gestores de portfólio, auxiliando na tomada de

---

\*Instituto de Matemática e Estatística, UERJ - email: edison.tito@gmail.com

†Faculdade de Ciências Econômicas, UERJ - email: faiube@gmail.com

‡Departamento de Economia, PUC-Rio - email: mmlf@econ.puc-rio.br

decisões estratégicas de investimento, antecipando movimentos de mercado e otimizando retornos.

Nos últimos anos, observou-se um crescimento expressivo na participação de investidores pessoa física no mercado de FIIs. Dados da B3 indicam que, até 2023, o número de investidores pessoa física em fundos imobiliários ultrapassou os 2 milhões, representando mais de 99% do total de cotistas. Esse aumento reflete fatores como a busca por alternativas de investimento mais rentáveis em um cenário de juros baixos e a acessibilidade proporcionada pelas plataformas digitais de investimento.

A previsão de preços de ativos financeiros tem sido historicamente um desafio acadêmico. As séries temporais financeiras são frequentemente modeladas por métodos econométricos clássicos, como ARMA-GARCH, que consideram o comportamento heterocedástico da volatilidade. No entanto, características como não-linearidade, não estacionariedade, dependência temporal de curto e longo prazos, assimetria, caudas pesadas, autocorrelação, efeito alavanca e não-Gaussianidade dos retornos tornam a previsão dessas séries uma tarefa extremamente complexa.

Mais recentemente, métodos de aprendizado de máquina (*Machine Learning* - ML) têm sido aplicados com sucesso à previsão de variáveis econômicas. Entre esses, o *Deep Learning* (DL) tem demonstrado capacidade superior na precisão de previsões, superando as limitações dos métodos econométricos tradicionais. Dell (2024) [3] apresenta uma revisão sistemática sobre diversas aplicações de DL em economia. Redes Neurais Recorrentes (RNNs), especialmente as arquiteturas *Long Short-Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU), destacam-se pela habilidade de modelar séries temporais financeiras, capturando dependências de longo prazo e padrões complexos nos dados (Hochreiter e Schmidhuber, 1997 [7]; Cho et al., 2014 [2]). Além disso, esses modelos possuem *lags* dinâmicos e flexíveis.

Estudos recentes mostram que modelos baseados em LSTM e GRU superam técnicas tradicionais na previsão de séries temporais financeiras, proporcionando maior acurácia e robustez nas previsões (Goodfellow et al., 2016 [6]; Nelson et al., 2018 [9]). A aplicação dessas metodologias à previsão do IFIX pode oferecer subsídios valiosos para a tomada de decisão dos investidores, identificando tendências e antecipando movimentos no mercado imobiliário brasileiro.

Este artigo compara a previsão do IFIX utilizando redes neurais com arquitetura LSTM e o modelo econométrico clássico ARMA-EGARCH. Dessa forma, busca-se avaliar a eficácia de métodos baseados em DL em comparação com técnicas tradicionalmente aplicadas a séries temporais financeiras.

A estrutura do artigo está organizada da seguinte forma: a Seção 2 apresenta uma revisão da literatura; a Seção 3 detalha as metodologias utilizadas; a Seção 4 descreve os dados; a Seção 5 apresenta os resultados obtidos; e, finalmente, a Seção 6 apresenta as conclusões e sugestões para trabalhos futuros.

## 2 Revisão da Literatura

A previsão de índices financeiros, como o IFIX no Brasil e os Real Estate Investment Trusts (REITs) nos Estados Unidos, tem sido objeto de diversos estudos acadêmicos. Essas pesquisas utilizam tanto métodos econométricos tradicionais quanto técnicas mais recentes de DL, como redes neurais LSTM e GRU.

A literatura específica sobre a previsão do IFIX é relativamente limitada. No entanto, alguns estudos utilizam metodologias clássicas aplicadas ao setor imobiliário brasileiro. Bernardo et al. (2023) [1] analisam a viabilidade de diversificação de portfólios com fundos imobiliários brasileiros por meio de modelos da família GARCH. Pereira e Perlin (2023) [10] investigam os resgates em FIIs utilizando simulações baseadas em modelos GARCH.

Nos Estados Unidos, a previsão de REITs tem sido amplamente estudada. Fletcher et al. (2004) [5], Rapach e Strauss (2009) [11] e Stevenson (2004) [12] exploram o setor imobiliário americano com métodos econométricos clássicos. Liow e Webb (2009) [8] empregam modelos VAR para analisar as inter-relações entre REITs e outras classes de ativos, destacando a importância da dinâmica multivariada na previsão desses investimentos. Yilmaz e Kestel (2018) [13] utilizam abordagens baseadas em processos estocásticos para modelar os preços.

Com o avanço do DL, modelos como LSTM e GRU têm sido aplicados à previsão de séries financeiras, graças à sua capacidade de capturar dependências temporais de longo prazo. Hochreiter e Schmidhuber (1997) [7] introduziram as redes LSTM, projetadas para superar as limitações das redes neurais recorrentes tradicionais. Inicialmente desenvolvidas para o Processamento de Linguagem Natural (NLP), as LSTMs foram posteriormente adaptadas para séries temporais. Cho et al. (2014) [2] propuseram as GRUs como uma alternativa mais simples às LSTMs, mantendo desempenho comparável. Estudos recentes, como o de Fischer e Krauss (2018) [4], mostram que modelos LSTM podem superar métodos tradicionais na previsão de retornos financeiros.

## 3 Os Modelos

A abordagem econométrica clássica aplicada a séries financeiras é amplamente discutida em diversos artigos e livros-textos. No contexto do setor imobiliário, Rapach e Strauss (2009) [11] exploram a previsibilidade dos retornos de ativos, considerando as séries temporais de retornos de imóveis.

A metodologia tradicionalmente utilizada para o estudo de séries financeiras univariadas é baseada nos modelos da família GARCH. Neste estudo, seguimos essa abordagem ao adotar um modelo GARCH como base para comparação com a metodologia de *Deep Learning* (DL), descrita posteriormente. Essa escolha permite avaliar a eficácia relativa dos modelos econométricos tradicionais em relação às técnicas avançadas de DL.

### 3.1 Abordagem Clássica

Considere  $r_t$  como o vetor dos log-retornos do IFIX. A equação da média é definida como:

$$\Phi(L)r_t = \mu + \Theta(L)\varepsilon_t, \quad t = 1, \dots, T, \quad (1a)$$

$$\varepsilon_t = z_t \sigma_t^{\frac{1}{2}}, \quad (1b)$$

onde  $L$  é o operador de defasagem (*lag operator*) aplicado aos polinômios autorregressivo (AR) e de médias móveis (MA), definidos por  $\Phi(L) = 1 - \phi_1 L - \dots - \phi_r L^r$  e  $\Theta(L) = 1 + \theta_1 L + \dots + \theta_s L^s$ , respectivamente. Aqui,  $z_t$  representa um processo *iid* com média zero e variância unitária.

A variância condicional,  $E(\varepsilon_t^2 | \mathcal{F}_t) = \sigma_t$ , onde  $\mathcal{F}_t$  é o conjunto de informações disponíveis até o tempo  $t$ , segue um processo EGARCH(1,1), definido como:


$$\ln \sigma_t = \omega + \alpha_1 z_{t-1} + \gamma_1 (|z_{t-1}| - E(|z_{t-1}|)) + \beta_1 \ln \sigma_{t-1}, \quad (2)$$

onde os parâmetros  $\alpha_1$ ,  $\gamma_1$  e  $\beta_1$  não precisam satisfazer restrições para garantir a positividade de  $\sigma_t$ .

### 3.2 Abordagem por Redes Neurais

No contexto de redes neurais, as Redes Neurais Recorrentes (RNNs) foram propostas para capturar aprendizados baseados em sequências, onde a ordem dos dados é relevante. Essa estrutura é particularmente adequada para séries temporais, pois as camadas ocultas atuam como memória dos estados anteriores, permitindo modelar como os valores passados influenciam os mais recentes. A Figura 1 ilustra a arquitetura de uma RNN clássica, onde  $x_i$ ,  $i = 1, \dots, t$ , representa a sequência de dados de entrada, enquanto os valores de  $y_i$  representam a saída correspondente. A unidade  $H$  da rede é iterada ao longo do tempo, armazenando informações de estados anteriores.

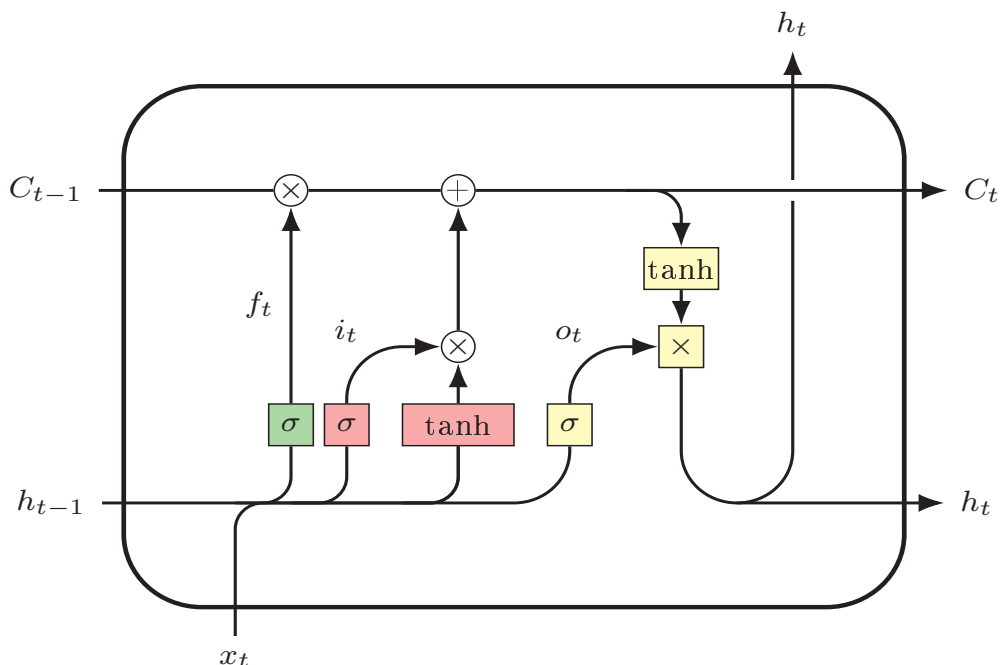
Figura 1: Representação esquemática de uma RNN clássica



Apesar de seu potencial, a estrutura da RNN apresenta desvantagens significativas, como a rápida deterioração do gradiente, que pode levar ao problema do gradiente desaparecer (*vanishing gradient*) ou explodir (*exploding gradient*). Esses problemas tornam as RNNs inadequadas para capturar dependências de longo prazo em séries temporais.

Para superar essas limitações, a arquitetura *Long Short-Term Memory* (LSTM) foi desenvolvida. A LSTM é uma variante da RNN que incorpora uma célula de memória na unidade  $H$ , projetada especificamente para lidar com dependências temporais de longa duração. A Figura 2 ilustra a estrutura de uma célula LSTM, que contém três portas principais: a porta de esquecimento (destacada em verde), a porta de entrada (vermelha) e a porta de saída (amarela). Essas portas permitem controlar de forma eficaz o fluxo de informações, regulando a memória de curto e longo prazo. A seguir, resumimos os componentes principais da célula:

Figura 2: Célula LSTM no instante  $t$



$C_{t-1}$  representa a memória de longo prazo proveniente do instante  $t - 1$  (ou da célula anterior);  $h_{t-1}$  representa a saída da célula no instante  $t - 1$  (ou da célula anterior) e é o estado oculto (*hidden state*) e carrega a memória de curto prazo;  $x_t$  é a variável de entrada no instante  $t$ ;  $C_t$  é a memória de saída referente ao instante  $t$ ;  $h_t$  representa o valor estimado referente ao instante oculto  $t$ ;  $\sigma$  em cor verde corresponde à função sigmoide, associada à porta de esquecimento (*forget gate*);  $\sigma$  e  $\tanh(\cdot)$  em cor vermelha representam as funções sigmoide e tangente hiperbólica, respectivamente, associadas à porta de entrada (*input gate*); enquanto  $\sigma$  e  $\tanh(\cdot)$  em cor amarela referem-se às funções sigmoide e tangente hiperbólica da porta de saída (*output gate*).

Note que o estado  $C_t$  atravessa todas as portas da célula, e em cada porta, o nível de informação (memória) é armazenado ou descartado. Cada porta combina a função sigmoide com uma operação de multiplicação, podendo ou não incluir a função  $\tanh$ . A saída da função sigmoide está no intervalo  $[0, 1]$ , onde 0 indica ausência de passagem de informação, e 1 indica passagem total da informação.

Em cada porção da célula, os valores são calculados de acordo com o conjunto de equações:

$$f_t = \sigma(W_f \cdot \langle h_{t-1}, x_t \rangle + b_f) , \quad (3a)$$

$$i_t = \sigma(W_i \cdot \langle h_{t-1}, x_t \rangle + b_i) , \quad (3b)$$

$$\tilde{C}_t = \tanh(W_C \cdot \langle h_{t-1}, x_t \rangle + b_C) , \quad (3c)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ \tilde{C}_t , \quad (3d)$$


$$o_t = \sigma(W_o \cdot \langle h_{t-1}, x_t \rangle + b_o) , \quad (3e)$$

$$h_t = o_t \circ \tanh(C_t) , \quad (3f)$$

onde  $W$  e  $b$  representam os pesos e *bias* treinados;  $f_t$ ,  $i_t$  e  $o_t$  correspondem aos valores calculados nas portas de esquecimento, entrada e saída, respectivamente;  $\tilde{C}_t$  é a saída da função  $\tanh$  na porta de entrada e representa nova informação potencial para a célula  $C_t$  (veja equação (3d)). Para obter a memória  $C_t$  na equação (3d) usa-se o produto Hadamard simbolizado aqui por  $\circ$  (*element-wise operator*).

A junção da célula LSTM básica com as células anterior e posterior está ilustrada na Figura 3.

Figura 3: Células LSTM nos instantes  $t - 1$ ,  $t$  e  $t + 1$



A aplicação da rede LSTM pode ser implementada utilizando pacotes como TensorFlow/-Keras e PyTorch.

Trabalhos como o de Fischer e Krauss (2018) [4] demonstraram o uso de LSTMs na previsão de movimentos do mercado de ações, destacando que as redes LSTM apresentam desempenho superior em relação a métodos de *Machine Learning* (ML) que não incorporam memórias. Outro exemplo é o estudo de Nelson et al. (2017) [9], que aplicou LSTMs para prever preços de ações, evidenciando melhorias significativas em comparação com métodos tradicionais.


A função de perda utilizada neste estudo é o erro quadrático médio (*Mean Squared Error* - MSE), definido como:

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 , \quad (4)$$

onde  $n$  é o tamanho da amostra, e  $y_t$  e  $\hat{y}_t$  representam os valores reais e previstos, respectivamente.

## 4 Dados

Figura 4: Evolução do IFIX de 03/01/2011 a 25/11/2024



A amostra do IFIX compreende o período de 03/01/2011 a 25/11/2024, totalizando 3447 observações. Ela foi dividida em três subamostras: o período de treinamento (03/01/2011 a 29/12/2022); o período de validação (02/01/2023 a 28/12/2023); e o período de teste (02/01/2024 a 25/11/2024).

A Tabela 1 apresenta as estatísticas descritivas dos log-retornos para a amostra completa, calculados como  $r_t = \log IFIX_t - \log IFIX_{t-1}$ , onde  $IFIX_t$  é o índice de fechamento diário ajustado para o pagamento de dividendos. Observa-se um elevado valor de curtose, refletindo as fortes quedas observadas durante o início da pandemia de COVID-19 em 2020. Esse comportamento é também evidenciado pelas estatísticas de Jarque-Bera e ARCH-LM, que rejeitam as hipóteses nulas de normalidade e ausência de heterocedasticidade, respectivamente.

A Figura 4 exibe a série histórica do IFIX para o período completo analisado. Nota-se uma queda abrupta no início de 2020, atribuída aos impactos iniciais da pandemia de COVID-19, seguida por uma recuperação do índice. No segundo semestre de 2024, observa-se uma

Figura 5: Previsão do IFIX de 02/01/2024 a 25/11/2024 modelo ARMA-EGARCH


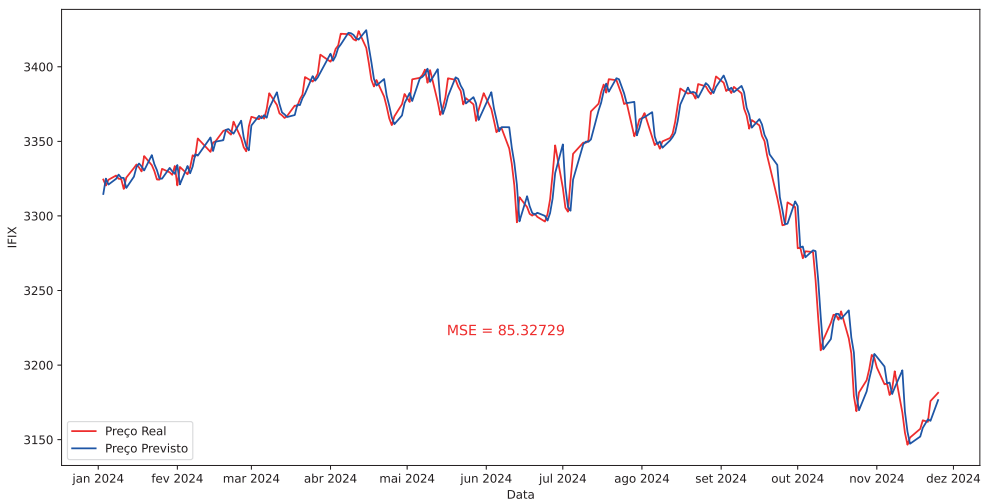


Figura 6: Previsão do IFIX de 02/01/2024 a 25/11/2024 rede LSTM



nova queda, associada às taxas de juros futuros persistentemente elevadas.



Tabela 1: Estatísticas da série de retornos do IFIX

Estatística	IFIX
Média	0,0003355
Desvio-padrão	0,00504
Assimetria	-7,7014
Curtose	207,45
Mínimo	-0,14191
Máximo	0,056656
Jarque-Bera	6.220.550 (0,0000)
ARCH-LM	417,15 (0,0000)

Notas: Curtose refere-se ao excesso de curtose. Entre parênteses, o p-valor das respectivas estatísticas de teste.

## 5 Resultados

A previsão realizada no período de validação em ambas metodologias foi feita considerando um passo à frente. Posteriormente, foram realizadas as previsões um passo à frente para o período de teste.

A Figura 5 mostra o IFIX no período de teste usando o modelo ARMA-EGARCH. O MSE obtido foi de 1685. No segundo semestre de 2024 houve um movimento decrescente do IFIX que sofreu o efeito da alta persistente da taxa de juros. Nota-se neste período o descolamento do previsto com os valores reais. O modelo estimado no período de treinamento não foi hábil para capturar o movimento descendente do IFIX.

A Figura 6 mostra a previsão do IFIX calculado pela arquitetura da rede neural LSTM. Nota-se claramente que a previsão acompanha mais precisamente a evolução do IFIX, resultando em um MSE bem inferior e igual a 85.

## 6 Conclusão

Este artigo realiza a previsão do índice dos fundos imobiliários no Brasil. Trata-se de um mercado com um vertiginoso crescimento e tem recebido crescente atenção de investidores, grande parte constituída de pessoas físicas.

A previsão foi realizada um passo à frente em bases diárias por duas diferentes metodologias: o modelo ARMA-EGARCH tradicional em modelagem financeira e através de redes neurais usando a arquitetura LSTM. A previsão por redes neurais apresentou um MSE muito inferior.

O uso de redes neurais tem se tornando muito usual recentemente na literatura de economia quando pretende-se fazer previsão. Trabalhos futuros nesta direção podem ser conduzidos comparando-se os diferentes tipos de arquiteturas como LSTM/GRU, convolution neural networks (CNN), mecanismo de atenção (AM-Attention Mecanism) e modelos híbridos como CNN-LSTM, CNN-LSTM-AM.

No caso específico de fundos imobiliários, há que se investigar o efeito das taxas de juros futuras neste mercado, usando-se também os modelos de redes neurais e comparando-se com a previsão obtida de forma univariada. Abre-se portanto, a perspectiva de vários trabalhos que podem ser conduzidos dentro da perspectiva de redes neurais combinando-se com variáveis relevantes do modelo econômico.

# Referências

- [1] BERNARDO, M. R., CAMPANI, C. H., AND ROQUETE, R. M. Brazilian REITs: Are they an opportunity for diversification and performance? *Journal of Real Estate Portfolio Management* 29, 2 (2023), 127–139.
- [2] CHO, K., VAN MERRIËNBOER, B., AND GULCEHRE, C. E. A. Learning phrase representations using rnn encoder-decoder for statistical machine translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)* (2014), 1724–1734.
- [3] DELL, M. Deep learning for economists. Tech. rep., National Bureau of Economic Research, 2024.
- [4] FISCHER, T., AND KRAUSS, C. Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research* 270, 2 (2018), 654–669.
- [5] FLETCHER, M., MANGAN, J., AND RAEBURN, E. Comparing hedonic models for estimating and forecasting house prices. *Property Management* 22, 3 (2004), 189–200.
- [6] GOODFELLOW, I., BENGIO, Y., AND COURVILLE, A. *Deep Learning*. MIT Press, Cambridge, MA, 2016.
- [7] HOCHREITER, S., AND SCHMIDHUBER, J. Long Short-Term Memory. *Neural Computation* 9, 8 (1997), 1735–1780.
- [8] LIOW, K. H., AND WEBB, J. R. Dynamic analysis of REIT returns: Multivariate var analysis. *Real Estate Economics* 37, 1 (2009), 99–126.
- [9] NELSON, D. M. Q., PEREIRA, A. C. M., AND DE OLIVEIRA, R. A. Stock market’s price movement prediction with LSTM neural networks. In *2018 International joint conference on neural networks (IJCNN)* (2017), Ieee, pp. 1419–1426.
- [10] PEREIRA, L., AND PERLIN, M. S. Qual é a taxa de retirada sustentável para o Brasil? *Brazilian Review of Finance* 21, 3 (2023), 37–72.
- [11] RAPACH, D. E., AND STRAUSS, J. K. Differences in housing price forecastability across US states. *International Journal of Forecasting* 25, 2 (2009), 351–372.
- [12] STEVENSON, S. New empirical evidence on heteroscedasticity in hedonic housing models. *Journal of Housing Economics* 13, 2 (2004), 136–153.
- [13] YILMAZ, B., AND SELCUK-KESTEL, A. A stochastic approach to model housing markets: The US housing market case. *Numerical Algebra Control and Optimization* 8, 4 (2018).