

20ª Conferência Internacional da LARES

06 e 07 de Outubro de 2021



Avaliação de Preços Imobiliários Usando Aprendizado de Máquina

Marcos A. Albarracin Manrique¹, Fernando Souza^{1,2}

¹Urbit, sagret10@gmail.com

²Cietec – Centro de Inovação, Empreendedorismo e Tecnologia, fernando@urbit.com.br

RESUMO

O mercado imobiliário é um dos mais importantes no mundo, e o maior desafio que enfrenta é a correta avaliação dos preços dos imóveis, já que é bastante dinâmico e exige um acompanhamento constante das principais tendências e perspectivas do setor. O mercado imobiliário está exposto a muitas flutuações de preços devido às correlações existentes entre diferentes parâmetros, alguns dos quais não podem ser controlados ou podem até ser desconhecidos. Nesse aspecto, para avaliar com precisão os custos imobiliários, é necessário um dispositivo que compreenda o impacto dos diferentes parâmetros nos custos da propriedade. Um dispositivo de previsão de preços encontra sua aplicação em vários cenários de tomadas de decisão. Uma previsão precisa sobre o preço de imóveis é importante para incorporadores imobiliários ou corretores de imóveis, potenciais proprietários futuros, desenvolvedores, investidores, avaliadores, assessores tributários e outros participantes do mercado imobiliário, como credores hipotecários e seguradoras. Nesse trabalho, pretendemos desenvolver um AVM (acrônimo da expressão inglesa Automated Valuation Model) baseado no aprendizado de máquina que identifica oportunidades no mercado imobiliário em tempo real. O AVM pode ser útil para investidores interessados no mercado imobiliário, já que permite o fluxo efetivo de informações abrangentes para a tomada de decisões sobre atividades de investimento, desenvolvimento e promoção na área imobiliária. Nos concentramos no caso de ativos imobiliários localizados na cidade de São Paulo y Belo Horizonte (Brasil), e listados em sites brasileiros mais relevante na vendas de apartamentos. O AVM é formalmente implementado como um problema de regressão que tenta estimar o preço de mercado de um apartamento, dados os recursos recuperados de listagens públicas online. Para construir esse aplicativo, realizamos uma etapa de engenharia de recursos a fim de descobrir recursos relevantes que permitem atingir um alto desempenho preditivo, e assim uma confiança nos resultados obtidos.

Palavras-chave: mercado imobiliário, avaliação de imóveis, investimento imobiliário, AVM, aprendizado de máquina..

20ª Conferência Internacional da LARES

06 e 07 de Outubro de 2021



Real Estate Price Valuation Using Machine Learning

ABSTRACT

The real estate market is one of the most important in the world, and the biggest challenge it faces is the correct assessment of property prices, as it is very dynamic and requires constant monitoring of the main trends and perspectives in the sector. The real estate market is exposed to many price fluctuations due to the correlations between different parameters, some of which cannot be controlled or may even be unknown. In this regard, to accurately assess real estate costs, a device is needed that understands the impact of different parameters on property costs. A price forecasting device finds its application in various decision-making scenarios. An accurate forecast on the price of real estate is important for real estate developers or realtors, potential future owners, developers, investors, appraisers, tax advisors and other real estate market participants, such as mortgage lenders and insurance companies. In this work, we intend to develop an AVM (Automated Valuation Model) based on machine learning that identifies opportunities in the real estate market in real time. AVM can be useful for investors interested in the real estate market, as it allows the effective flow of comprehensive information to make decisions about investment, development and promotion activities in the real estate area. We focus on real estate assets located in the city of São Paulo and Belo Horizonte (Brazil), and listed on Brazilian websites most relevant to apartment sales. AVM is formally implemented as a regression problem that tries to estimate the market price of an apartment, given the resources retrieved from public online listings. To build this application, we carried out a resource engineering step in order to discover relevant resources that allow us to achieve high predictive performance, and thus a confidence in the results obtained.

Key-words: real estate market, property valuation, real estate investment, AVM, machine learning.

OBSERVAÇÃO: AINDA QUE O ARTIGO SEJA REDIGIDO EM PORTUGUÊS OU ESPANHOL É OBRIGATÓRIO O ENVIO DO TÍTULO E RESUMO DO ARTIGO TAMBÉM EM INGLÊS, CASO CONTRÁRIO, NÃO SERÃO ACEITOS.

1. INTRODUÇÃO

Possuir propriedades é um dos investimentos mais importantes que uma pessoa pode fazer em sua vida. Portanto, ser capaz de saber com precisão o valor em tempo real de qualquer propriedade é crucial para fazer vendas e compras inteligentes. Um dos maiores desafios que as imobiliárias enfrentam é avaliar corretamente o valor do imóvel, isso porque o mercado imobiliário é bastante dinâmico o qual exige um acompanhamento constante das principais tendências e perspectivas do setor por parte dos profissionais. As transformações urbanas que vêm ocorrendo nas diversas regiões das principais cidades do Brasil, principalmente nos últimos 30 anos, e as instabilidades econômicas que o país vivenciou nos últimos anos, tornam a precificação uma atividade ainda mais desafiadora. Tanto a compra quanto a venda ou aluguel de um imóvel é considerada uma tarefa complexa que demanda tempo e muita análise. Por isso, profissionais especializados no assunto, os avaliadores de imóveis, precisam considerar um conjunto de critérios, interagindo em um processo estocástico, para definir o preço final de um imóvel.

O mercado imobiliário, que estava evoluindo rapidamente, se viu afetado pela pandemia. Um relatório recente publicado pela MSCI, Inc. (anteriormente Morgan Stanley Capital International) estima que a pandemia devido à COVID-19 acelerou significativamente uma série de mudanças seculares que já estavam começando a ter impactos fundamentais no papel que o setor imobiliário desempenha na economia, bem como nas carteiras de investimento. Essa interrupção aumenta a necessidade de evolução de dados e análises para entender os impulsionadores de desempenho e risco que mudam rapidamente em todos os tipos de investimentos imobiliários. O MSCI afirma que essa interrupção aumenta a necessidade de evolução de dados e análises para entender os impulsionadores de desempenho e risco que mudam rapidamente em todos os tipos de investimentos imobiliários (ROBSON, 2021). No entanto, olhar para a evolução do mercado de uma perspectiva global acaba sendo muito simplista. Embora o mercado em escala global esteja estreitamente correlacionado, há muitos aspectos que influenciam o comportamento dos mercados em escala local, como instabilidade política ou o surgimento de “pontos quentes” altamente demandados que podem mudar rapidamente. Além disso, diferentes segmentos de mercado evoluem em ritmos diferentes, como condomínios de luxo de alto padrão.

Não podemos negar que a dinâmica das transformações urbanas é o principal fator contribuinte do aumento da complexidade na procura de um modelo de avaliação automática o comumente chamado modelo de precificação que produza estimativas objetivas, precisas e confiáveis. Fatores como tempo de deslocamento diário ao trabalho, universidade e escola, influenciado por engarrafamentos, aumento de novos paisagens homogêneos, uso alternativos de galpões industriais, a proliferação das cabines de segurança que bloqueiam as passagens e controlam o acesso aos espaços residenciais e áreas de lazer, a verticalidade súbita de ruas e bairros antes horizontais, aumento do fluxo de veículos que fazem rodovias ganharem ares de avenidas e avenidas que ganham equipamentos de controle de velocidade para não se transformarem em rodovias, entre outros, são fatores principais que afetam as características que influenciam diretamente no valor do imóvel (FÁVERO; BELFIORE; DE LIMA, 2008).

Características como a localização e vizinhança, tipo de construção, infraestrutura de tecnologia e lazer, proximidade com lojas e serviços, arborização, segurança, estrutura do terreno, idade da construção, acabamento, estado de conservação, acessibilidade, entre outras, influenciam significativamente o setor imobiliário e remetem a novas formas de ocupação e deslocamento social, espacial e temporal. Este último fato, é um indicativo da importância do estudo da

precificação de imóveis não é só importante para avaliar com precisão os custos imobiliários e seus padrões futuros que fazem parte da estruturação do mercado imobiliário, senão, é essencial para ajudar as escolhas na organização urbana. No entanto, algumas dificuldades surgem na coleta de dados para fatores qualitativos, de aí da importância de análises estatísticos prévios e do desenvolvimento de melhores técnicas de coleta de dados no setor imobiliário (AHN et. al., 2012).

O mercado imobiliário é um dos mais importantes no mundo, nesse aspecto, o mercado imobiliário brasileiro, tem se destacando no mundo, especialmente a cidade de São Paulo, como um dos mercados mais atraente para aplicações em imóveis entre as grandes metrópoles internacionais no ano de 2012 (AGUIRRE, 2012). Para avaliar com precisão os custos imobiliários, é necessário um dispositivo que compreenda esses padrões e o impacto de diferentes parâmetros nos custos da propriedade, devido a isso, é exigido um modelo que possa prever as estimativas atuais e futuras de propriedade com uma notável precisão e um mínimo porcentagem de erro.

Neste artigo, mostramos, apresentaremos um esboço do modelo de avaliação automática (modelo preditivo) desenvolvido pela Urbit e que já foi utilizado em diversos projetos nacionais. O restante deste artigo está estruturado da seguinte forma: a Seção 2 descreve o estado da arte na previsão de preços de apartamentos e coloca este trabalho em seu contexto. Posteriormente, a Seção 3 descreve a metodologia usada no nosso modelo, na Seção 4 mostramos dois casos de estudo onde avaliamos nosso modelo. Finalmente, algumas observações conclusivas e futuras linhas de trabalho são fornecidas na Seção 5.

2. ESTADO DA ARTE

Os modelos tradicionais utilizados para a avaliação ou estimativa de ativos imobiliários têm se baseado na regressão hedônica, que divide o ativo em suas características constituintes, de modo a estabelecer uma relação entre cada um deles e o preço da propriedade. O modelo aprendido com a regressão hedônica pode então ser usado para estimar o preço de um ativo cujas características são conhecidas com antecedência (JIANG; PHILLIPS; YU, 2014; JIANG; PHILLIPS; YU, 2015).

Porém, evidências empíricas de estudos anteriores mostraram que técnicas tradicionais de avaliação tendem a produzir estimativas imprecisas, são subjetivas por natureza, não atrelam de fora ótima os fatores intrínsecos e extrínsecos e não são confiáveis (PARIS, 2008). O advento da tecnologia de computadores levou à introdução de técnicas de modelagem de Inteligência Artificial (IA), que incluem a técnica de Aprendizado de Máquina, Aprendizagem Profunda e Redes Neurais Artificiais, projetada para imitar o cérebro humano (MORA-ESPERANZA, 2004).

Alguns artigos têm recorrido ao uso de técnicas de aprendizado de máquina para estimar ou prever o preço de ativos imobiliários individuais (MANGANELLI et. al., 2007; PARK; KWON, 2015, DEL GIUDICE et al., 2017; SINGH et al., 2020). Para estes artigos, o problema pode ser visto como uma classificação para decidir se um investimento vale ou não, ao invés de um problema de regressão. Aplicam diferentes metodologias, programação linear, por exemplo, para analisar os dados imobiliários, obtendo coeficientes para seus modelos, obtendo um erro percentual médio aceitável.

Em particular, o artigo de Singh et al. empregou o conceito de big data para prever dados de venda de casas, usando três modelos para prever preços de venda de casas: regressão linear, floresta aleatória e gradient boosting. Os resultados numéricos indicaram que o modelo de gradient boosting supera os outros modelos de previsão em termos de precisão de previsão.

Em realidade, a literatura sobre a aplicação do aprendizado de máquina à avaliação de ativos imobiliários é relativamente escassa, porém mostra um grande aumento nos últimos anos, muito mais ao nível nacional. Porém, a construção de um modelo de avaliação automática (modelo preditivo) baseado no modelo de aprendizado de máquina visando a predição do preço (modelagem de precificação) de imóveis no mercado imobiliário brasileiro e mundial, tomando em conta de forma esquemática os principais fatores, com suas respectivas variações espaciais e temporais, preponderantes na previsão dos preços de imóveis é de primordial importância.

3. METODOLOGIA

Nosso modelo é um algoritmo de aprendizado de máquina moderno usado para modelar e prever o preço de um imóvel a partir de informações numéricas que representam suas características. São utilizados tanto atributos intrínsecos dos imóveis, como sua área, número de quartos, número de banheiros, etc., quanto atributos extrínsecos, como oferta de serviços, parques, ciclovias, meios de transporte, entre outros nos arredores da propriedade.

A base de dados que alimenta o modelo é construída a partir fontes públicas, de anúncios de diferentes tipos de imóveis (casas, apartamentos residenciais, salas comerciais, terrenos, etc.) da cidade em estudo. Apenas alguns são parcerias com empresas especializadas. O desempenho e o poder preditivo do modelo são avaliados extensivamente até serem considerados satisfatórios. O modelo utiliza métodos estatísticos para estimar a influência de fatores tipológicos, físicos e territoriais no preço de imóveis.

O nosso modelo é utilizado para a precificação de imóveis, atuando tanto no âmbito do arrendamento como no âmbito da compra e venda. O conjunto de dados para isso se origina do banco de dados Urbit e inclui uma grande variedade de atributos intrínsecos e extrínsecos, pertencentes a cada propriedade analisada. A precisão média do nosso modelo, ou seja, a confiabilidade da previsão, está em torno de 90%, o que significa que a precisão do nosso modelo é confiável.

O algoritmo é baseado no esquema de aprendizado de máquina, mais conhecido como “Machine Learning”. O algoritmo específico usado no contexto do aprendizado de máquina é o algoritmo “Gradient Boosting”, uma das técnicas mais poderosas para a construção de modelos preditivos. É uma técnica de aprendizado de máquina para problemas de regressão e classificação, que produz um modelo de previsão na forma de um conjunto de modelos de previsão fracos, geralmente árvores de decisão. Este algoritmo faz parte de uma família de técnicas poderosas de aprendizado de máquina que têm mostrado um sucesso considerável em uma ampla gama de aplicações práticas. Eles são altamente personalizáveis para as necessidades específicas da aplicação estudada, como ser aprendido com relação a diferentes funções de perda (NATEKIN; KNOLL, 2013).

Também, têm mostrado um sucesso considerável não apenas em aplicações práticas, mas também em vários desafios de aprendizado de máquina e mineração de dados (HUTCHINSON et al., 2011; JOHNSON; ZHANG, 2012). Essa alta flexibilidade torna o algoritmo “Gradient Boosting” altamente personalizáveis para qualquer tarefa específica baseada em dados. Ele

introduz muita liberdade no projeto do modelo, tornando a escolha da função de perda mais adequada uma questão de tentativa e erro.

Nosso algoritmo de precificação é organizado em diferentes estágios interligados por módulos, onde os dados, com atributos intrínsecos, são tratados estatisticamente para serem somados os atributos extrínsecos relacionados à região onde cada imóvel está localizado. As etapas são: exploração de dados, extração de atributos extrínsecos, cálculos estatísticos e precificação. Na seguinte seção será apresentado dois casos de estudos onde nosso modelo de avaliação automática mostrou um bom desempenho.

4. ESTUDOS DE CASO

Nesta seção apresentamos dois estudos de caso, onde mostramos o processo de uso, características básicas e resultados de nosso modelo. Detalhes não são expostos devido ao caráter informativo do artigo.

4.1 Caso: Belo Horizonte

Nosso modelo utiliza métodos estatísticos para estimar a influência de fatores tipológicos, físicos e territoriais no preço dos imóveis. Para o caso da cidade de Belo Horizonte, o modelo de precificação foi calibrado com o objetivo de estimar os preços de venda de apartamentos. Para cada lote de imposto foi considerado um imóvel de 80 m², 3 dormitórios, 1 suíte e 1 banheiro, com base nos valores médios desses atributos encontrados no perímetro da cidade de Belo Horizonte, conforme o banco de dados Urbit.

O modelo foi treinado com aproximadamente 16000 observações (edifícios dentro do perímetro da cidade), com as seguintes características intrínsecas: dormitórios (entre 1 e 4), banheiros (entre 1 e 5), suítes (entre 1 e 3) e vagas (entre 1 e 4) e um valor de área útil média de aproximadamente 108 m². Além desses atributos intrínsecos, os atributos intrínsecos de valor condominial também foram considerados amplamente.


Os atributos extrínsecos usados foram: número de equipamentos culturais em 1 km, estações de metrô em 800 metros, ciclovias em 500 metros, estações e linhas de BRT em 800 metros, pontos de ônibus em 800 metros, parques e praças em 800 metros, favelas em 1 km, e se a área é atendida por serviços municipais de esgoto.

Conforme nossa experiência com a prefeitura de São Paulo e na sequência de uma série de trabalhos acadêmicos, além de aumentar o número de observações, é necessário agregar variáveis que darão um grande “upgrade” ao modelo e tornar a previsão o mais precisa possível, realidade observada no mercado imobiliário de Belo Horizonte. Entre essas variáveis podemos citar as seguintes: ano de construção do imóvel, áreas de lazer do imóvel, renda média familiar, acesso a serviços, acesso ao ensino público e privado, furtos de veículos e telefones celulares, uso predominante de áreas e transitabilidade.

Porém, os resultados obtidos para a cidade de Belo Horizonte com as variáveis descritas acima mostraram-se aceitáveis. Nosso modelo atingiu uma precisão aproximada de 84% com respeito aos valores dos preços dos imóveis precificados, o que é um resultado expressivo. A seguir apresentamos um mapa de correlação entre as variáveis e o preço do imóvel (figura 1).

Na barra horizontal da figura, o índice de correlação (coeficiente de correlação de Pearson) variando de 0 a 1 é mostrado e está vinculado a uma intensidade de cor. Uma gama de significados para o índice de correlação pode ser a seguinte: 0.9 mais ou menos indica uma correlação muito forte. 0.7 a 0.9 positivo ou negativo indica uma forte correlação. 0.5 a 0.7 positivo ou negativo indica uma correlação moderada. 0.3 a 0.5 positivo ou negativo indica uma correlação fraca. 0 a 0.3 positivo ou negativo indica uma correlação desprezível.

Figura 1: mapa de correlação




Podemos perceber que as variáveis intrínsecas, “valor do condomínio”, “área útil”, “suítes e número de vagas” apresentam uma forte ligação, diretamente proporcional, ao valor do imóvel, como se poderia esperar, enquanto as variáveis “dormitórios” e “banhos” apresentam correlação moderada e diretamente proporcional. Das demais variáveis, todas extrínsecas, apenas a variável “número de espaços culturais em 1 km” apresenta correlação fraca. O resto das variáveis extrínsecas mostram uma correlação desprezível, seja direta ou inversamente proporcional.

O atual cenário de correlações pode ser fortemente modificado, à medida que mais observações e mais variáveis intrínsecas e extrínsecas são adicionadas, o que proporcionou uma maior diversidade na correlação entre as variáveis e o preço. Nesse cenário, será necessário construir um estudo maior e melhor, que objetive produzir indicadores necessários para avaliar a influência de cada uma das variáveis no preço.

Abaixo mostramos uma variação do mapa de correlação anterior (figura 2), aqui a variável objetivo é o preço por metro quadrado, que para estudos similares realizados na cidade São Paulo se apresentou como sendo uma variável muito mais expressiva que variável preço. Para esta variação, é observado que as intensidades das correlações diminuiriam minimamente em relação ao primeiro mapa de correlação, no entanto, é mantida a ordem de importância das variáveis.

Figura 2: mapa de correlação



4.1 Caso: São Paulo

Para o caso da aplicação de nosso algoritmo para a cidade de São Paulo, temos como principal objetivo a precificação de apartamentos. Para isto, usamos as variáveis intrínsecas, “área útil”, “dormitórios”, “banheiros”, “suítes e número de vagas”. Os atributos extrínsecos usados foram aproximadamente 50 atributos, entre os principais podemos nomear: renda média familiar, estação de trem e de metro a 800 metros, linhas de ônibus a 800 metros, centros de educação privada e pública a 600 metros, diversos serviços a 5 minutos, caminhabilidade, furto e roubo de carros e celulares a 500 metros, densidade populacional, etc.

O modelo foi treinado com aproximadamente 98000 observações, com os seguintes valores das características intrínsecas: dormitórios (entre 1 e 4), banheiros (entre 1 e 4), suítes (entre 1 e 3) e vagas (entre 1 e 3) e um valor de área útil média de aproximadamente 102 m². Na figura 3 apresentamos um mapa de correlação entre as variáveis e o preço do imóvel. Nosso modelo atingiu uma precisão aproximada de 89% com respeito aos valores dos preços dos imóveis precificados, o que é um resultado muito expressivo.

Com o objetivo de observar melhor nossos resultados, analisamos a partir de nossos dados, como o valor do preço por m² varia com respeito a serviços básicos. Para este propósito, centramos nossa atenção em apartamentos em lançamentos no bairro de “Santa Cecília” o qual corresponde aproximadamente a 1500 observações em nossa base de dados. Na figura 4, é mostrado o mapa de correlação entre o preço por m² e os principais serviços a 5 minutos. É observado que o preço por m² é relacionado à quantidade de restaurantes, academias, supermercado e ao total de serviços.

Figura 3: mapa de correlação

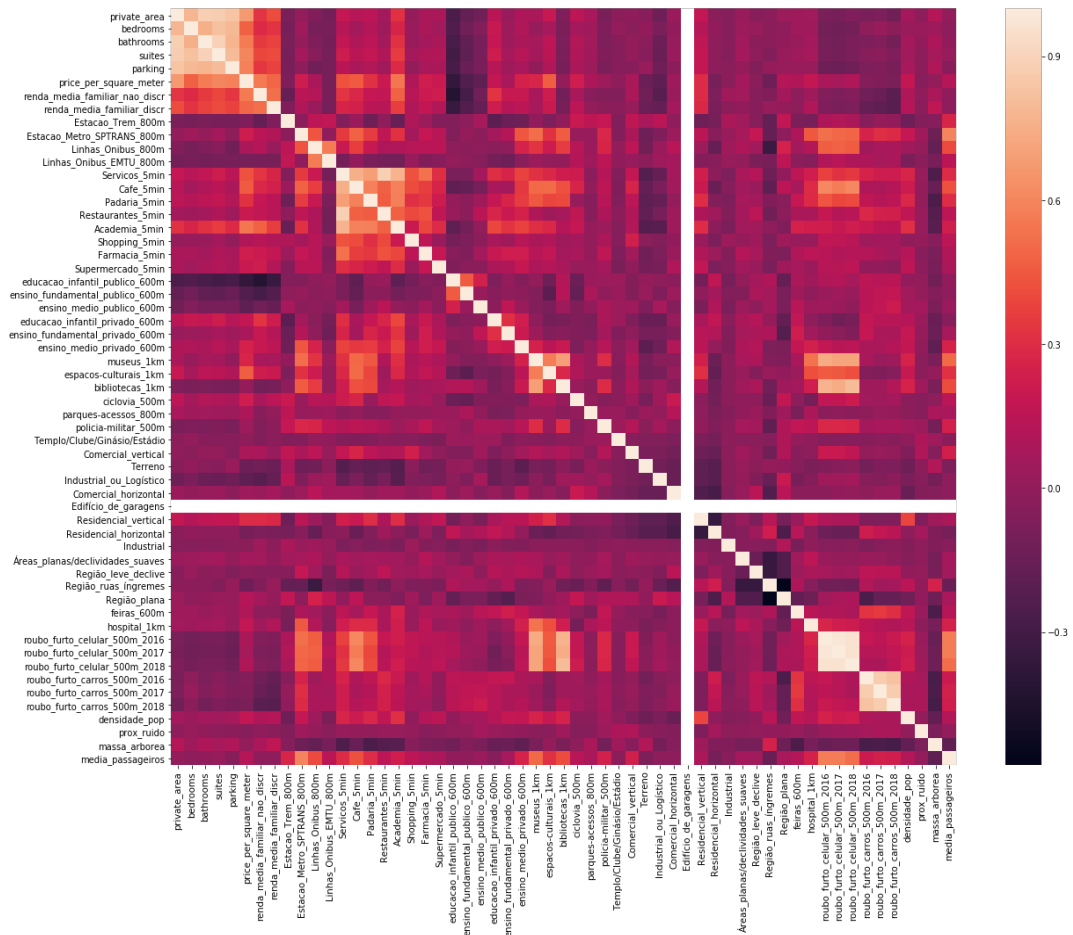


Figura 4: mapa de correlação



Na figura 5 mostramos a distribuição do número de restaurantes no bairro de “Santa Cecília” e na figura 6 e apresenta um grafico “boxplot” que ajuda a observar como se relaciona o número de restaurante com o valor médio do preço por m².

Figura 5: distribuição





Figura 6: boxplot



5. CONCLUSÃO

Neste artigo, apresentamos resumidamente nosso modelo de avaliação automática ou modelo de precificação, mostrando seu um bom desempenho o qual é sustentado no seu uso em diversos projetos nacionais onde a Urbit tem participado exitosamente. O modelo apresenta uma boa precisão o qual se reflete em resultados concordantes com valores observados no mercado imobiliário.

Atualmente, estamos trabalhando em diversos esquemas de inteligência artificial, por exemplo, redes neurais, para serem comparados com nosso esquema atual. Também estamos trabalhando na aplicação de variáveis dependente do tempo o qual nos permitiram estudar a evolução temporal dos preços e efetuar previsões temporais. É esperado apresentar todos estes avanços proximamente, através de artigos muito mais detalhados que o presente.

6. REFERÊNCIAS

AGUIRRE, L. L. Modelo de precificação de imóveis no DF. Portal VGV. Brasília, Brasil. 2012. Available online: <https://www.portalgv.com.br/site/wp-content/uploads/2009/08/Modelo-de-precificacao-de-imoveis-no-DF.pdf>

AHN, J. J.; BYUN, H. W.; OH, K. J.; KIM, T. Y. Using ridge regression with genetic algorithm to enhance real estate appraisal forecasting. *Expert Syst. Appl.* 2012, 39, 8369–8379.

DEL GIUDICE, V.; DE PAOLA, P.; FORTE, F. Using Genetic Algorithms for Real Estate Appraisals. *Buildings* 2017, 7, 31.

DEL GIUDICE, V.; DE PAOLA, P.; FORTE, F.; MANGANELLI, B. Real Estate appraisals with Bayesian approach and Markov Chain Hybrid Monte Carlo Method: An Application to a Central Urban Area of Naples. *Sustainability* 2017, 9, 2138.

FÁVERO, L. P. L.; BELFIORE, P. P.; and DE LIMA, G. A. S. F. 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*, v. 38, no 1, 73-96, 2008.

HUTCHINSON, R. A., LIU, L.-P., and Dietterich, T. G. (2011). “Incorporating boosted regression trees into ecological latent variable models,” in *AAAI’11*, (San Francisco, CA), 1343–1348.

JIANG, L.; PHILLIPS, P.C.B.; YU, J. A New Hedonic Regression for Real Estate Prices Applied to the Singapore Residential Market. Technical Report, Cowles Foundation Discussion Paper No. 1969, 2014. Available online: <https://ssrn.com/abstract=2533017>.

JIANG, L.; PHILLIPS, P.C.B.; YU, J. New Methodology for Constructing Real Estate Price Indices Applied to the Singapore Residential Market. *J. Bank. Financ.* 2015, 61, S121–S131.

JOHNSON, R., and ZHANG, T. (2012). Learning Nonlinear Functions Using Regularized Greedy Forest. Technical Report. arXiv:1109.0887. doi: 10.2172/1052139

MANGANELLI, B.; PAOLA, P. D.; GIUDICE, V. D. Linear Programming in a Multi-Criteria Model for Real Estate Appraisal. In Proceedings of the International Conference on Computational Science and its Applications, Part I, Salamanca, Spain, 12–16 November 2007; Volume 9786, pp. 182–192.

MORA-ESPERANZA, J. G. Artificial intelligence applied to real estate valuation: An example for the appraisal of Madrid. *CATASTRO*, April(1), 255-265. 2004.

NATEKIN A, KNOLL A. Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*. 2013;7:21.

PARIS, S. D. Using artificial neural networks to forecast changes in national and regional price indices for the UK residential property market. (Doctoral dissertation), University of Glamorgan, Wales, UK. 2008.

PARK, B.; KWON BAE, J. Using Machine Learning Algorithms for Housing Price Prediction: The Case of Fairfax County, Virginia Housing Data. *Expert Syst. Appl.* 2015, 42, 2928–2934.

ROBSON, W. 2021 Real Estate Trends to Watch. Jan 12, 2021. Available online: <https://www.msci.com/www/blog-posts/2021-real-estate-trends-to/02273729217>.

SINGH, A.; SHARMA, A.; DUBEY, G. Big data analytics predicting real estate prices. *Int. J. Syst. Assur. Eng. Manag.* 2020.