



Industrialização, Digitalização,  
Desempenho

5º Simpósio Brasileiro de Tecnologia da Informação  
e Comunicação na Construção e 5º Workshop de  
Tecnologia de Processos e Sistemas Construtivos

FLORIANÓPOLIS-SC | 20 a 22 de agosto

# **1º DESENVOLVIMENTO DE MODELO DE APRENDIZADO DE MÁQUINA PARA PRECIFICAÇÃO IMOBILIÁRIA**

## Development of machine learning model for Real State pricing

**Bruno Leão de Brito**

Universidade Federal da Bahia | Salvador, BA | leaodebrito@gmail.com

**Maurício Felzemburgh**

Universidade Federal da Bahia | Salvador, BA | mauriciofzb@gmail.com

**Rei Carlos Jardim**

Senai CIMATEC | Salvador, BA | reijardim.eng.civil@gmail.com

### **RESUMO**

A incorporação imobiliária é um processo complexo, no qual a definição do preço de venda de unidades imobiliárias representa um desafio significativo. Métodos tradicionais de precificação, como a regressão hedônica e a regressão linear múltipla, têm sido amplamente utilizados, mas enfrentam dificuldades para capturar a complexidade e não linearidade do mercado imobiliário. Este trabalho desenvolve um modelo de aprendizado de máquina (ML) baseado em redes neurais artificiais (RNA) para precificação imobiliária, com o objetivo de aprimorar a precisão das estimativas. O modelo é treinado utilizando um conjunto de dados estruturado e tratado metodologicamente, e sua avaliação inclui métricas de desempenho e análise espacial dos erros. Os resultados demonstram que o modelo alcançou um erro médio absoluto (MAE) de R\$ 915,44 e um erro percentual médio (MAPE) de 18,06%, superando abordagens tradicionais. Além disso, a análise comparativa com estudos anteriores reforça a eficácia da abordagem de ML, especialmente na captura de padrões espaciais e na redução de discrepâncias preditivas. Os achados evidenciam o potencial do modelo como uma ferramenta aplicável ao mercado imobiliário, contribuindo para a tomada de decisão por investidores e profissionais do setor.

**Palavras-chave:** Mercado imobiliário; Precificação de imóveis; Aprendizado de máquina

### **ABSTRACT**

*Os autores devem apresentar o resumo do artigo em português e inglês (com no máximo 200 palavras). Observar fonte em itálico. In this section authors should present the Abstract (maximum of 200 words). Fonts in italic.*

*Real estate development is a complex process, with one of its challenges being the definition of the selling price of real estate units. Pricing methods based on linear regression and hedonic regression have been studied, but they struggle to balance selling prices given the complexity of the real estate market. This study aims to develop a machine learning (ML) model for real estate pricing using artificial neural networks, capable of capturing patterns related to location and physical characteristics of properties, such as the number of rooms. To achieve this, a methodological framework based on Design Science Research (DSR) was applied. This framework included theoretical background research on the topic, definition of training and evaluation techniques for the ML model, data collection, model training, and analysis of the obtained results. Through the collected data and the trained model, a characterization of real estate prices in the studied city was achieved, along with a model that presented a mean absolute error of R\$915.44 and an approximate percentage error of 18%. Thus, the contribution of this study lies in the application of machine learning models in the construction industry for real estate pricing.*

**Keywords:** Real Estate Market; Property Pricing; Machine Learning

## **1 INTRODUÇÃO**

A incorporação imobiliária pode ser definida como a construção e venda de uma ou mais edificações com unidades autônomas que podem ser comercializadas ainda na planta (BRASIL, 1964). A responsável pelo empreendimento imobiliário, a Incorporadora, tem como desafios deste processo além da análise de localidade, regras de zoneamento, características da população e análises de custos (aquisição do terreno,

---

<sup>1</sup>BRITO, B. L.; FELZEMBURGH, M.; JARDIM, R. C. Desenvolvimento de Modelo de Aprendizado de Máquina para Precificação Imobiliária. In: 5º SIMPÓSIO BRASILEIRO DE TECNOLOGIA DA INFORMAÇÃO E COMUNICAÇÃO NA CONSTRUÇÃO, 4., 2025, Florianópolis. **Anais [...]**. Porto Alegre: ANTAC, 2025.

financiamento, construção, venda, marketing e impostos), a análise de retorno sobre investimento e análises de mercado, estes dois últimos que impactam diretamente na precificação da unidade imobiliária.

A precificação de imóveis urbanos que, como quaisquer outras mercadorias, passa pelo crivo da oferta e da demanda (MOSCOVITCH, 1997) é um processo complexo que requer a análise de variáveis econômicas, sociais e estruturais, sendo amplamente estudada em modelos de avaliação imobiliária (ROSEN, 1974; HARRISON JR.; RUBINFELD, 1978; MALPEZZI, 2003). Abordagens tradicionais frequentemente utilizam modelos lineares, como regressão hedônica e regressão linear múltipla (GAZOLA, 2002), mas enfrentam dificuldades para capturar a complexidade e não linearidade dos mercados imobiliários. Essas abordagens tradicionais consideram relações fixas entre variáveis, o que pode ser impreciso devido à natureza dinâmica do mercado, que é influenciado por múltiplos fatores interligados (SOLTANI; LEE, 2024).

Estudos anteriores que aplicaram regressão linear múltipla evidenciam desafios na previsão de preços imobiliários com métodos tradicionais. Worzala et al. (1995) apontaram dificuldades significativas na precisão das previsões, indicando que os modelos tradicionais podem apresentar variações consideráveis em relação aos valores reais. De forma semelhante, Zancan (1995) observou limitações na capacidade de estimativa dos preços de venda, reforçando as restrições inerentes a abordagens lineares. Em contrapartida, Gazola (2002) reportou resultados relativamente mais precisos, mas ainda sujeitos a desafios na modelagem preditiva do setor. Esses estudos ressaltam a necessidade de aprimoramento dos modelos preditivos, considerando a complexidade do mercado e a multiplicidade de fatores que influenciam os preços dos imóveis.

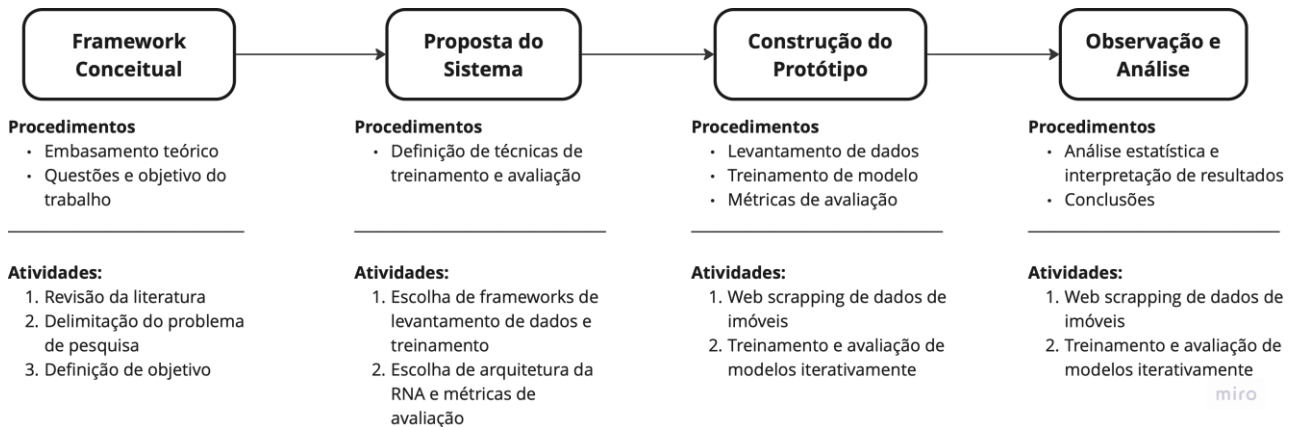
Nesse contexto, o uso de aprendizado de máquina tem se mostrado eficaz para aumentar a precisão na previsão de preços imobiliários (CALAINHO; VAN DE MINNE; FRANCKE, 2024). Modelos baseados em redes neurais artificiais podem proporcionar estimativas mais precisas ao identificar interdependências complexas entre atributos do imóvel e sua valorização no mercado. Deste modo, o problema central deste estudo está na necessidade de aprimorar a precisão das estimativas de preços de venda de imóveis, mitigando vieses existentes e otimizando a análise de fatores determinantes. O objetivo deste trabalho é desenvolver um modelo de aprendizado de máquina para a precificação de imóveis, utilizando uma Rede Neural Artificial (RNA) para capturar padrões complexos nos dados e fornecer previsões mais acuradas.

Este estudo contribui para a literatura ao combinar aprendizado de máquina com um processo sistematizado de coleta e tratamento de dados, permitindo a aplicação dessa abordagem a diferentes mercados imobiliários. Além disso, ao utilizar um modelo automatizado, espera-se reduzir subjetividades e aumentar a precisão das estimativas, favorecendo a tomada de decisões por parte de investidores, compradores e profissionais do setor.

## 2 METODOLOGIA

O estudo adota a abordagem do *Design Science Research* (DSR) por sua capacidade de estruturar a criação e validação de artefatos tecnológicos voltados à resolução de problemas práticos, como aponta Lacerda et al. (2013). No contexto deste trabalho, essa abordagem permite o desenvolvimento de um modelo de aprendizado de máquina para precificação de imóveis, garantindo um processo sistemático de concepção, implementação e avaliação do artefato. A Abordagem adotada é quantitativa, tendo como prioridade resultados numéricos e uso de métodos estatísticos para análise, avaliação e interpretação de resultados. Este trabalho seguiu a estrutura para desenvolvimento de sistemas proposta por Nunamaker, Chen e Purdin (1990) (Figura 1).

Figura 1: Estrutura metodológica



Fonte: Autor.

A primeira etapa, Framework Conceitual, teve como objetivo, por meio do embasamento teórico, definir o problema de pesquisa e os objetivos do estudo. Na sequência, na etapa Proposta do Sistema, foram estabelecidos os recursos para o levantamento e processamento dos dados. O Selenium e o Webdriver\_manager foram utilizados para a extração dos dados, enquanto o Pandas (Versão 2.2.2) e o NumPy (Versão 1.26.4) foram empregados para a organização e manipulação dessas informações. O levantamento de dados foi conduzido em um Mac Mini M2 com 8 GB de RAM. Para o tratamento dos dados, foram aplicadas técnicas de processamento com Pandas e NumPy, além da visualização por meio das bibliotecas Seaborn e Matplotlib. O tratamento consistiu no cálculo de novos atributos e exclusão de outliers ou anúncios que não apresentassem todas as informações necessárias. Já o treinamento do modelo e a extração de métricas, conduzidos em um Mac M2 Pro com 16GB de RAM, foram realizados com Scikit-Learn e TensorFlow Keras. A arquitetura do modelo escolhida foi uma Rede Neural Artificial (RNA) *feedforward*, no qual os dados fluem em uma única direção, da camada de entrada às camadas ocultas e, finalmente, à camada de saída (SILVA; SPATTI; FLAUZINO, 2016)

Com o sistema proposto, foi realizado um levantamento automatizado de anúncios de apartamentos na cidade de Salvador/BA. Os anúncios coletados contemplam imóveis residenciais de padrão variado, incluindo unidades direcionadas a públicos de renda baixa, média e alta não se restringindo a uma tipologia específica, considerando o mercado geral de imóveis urbanos ofertados na cidade. O script, desenvolvido com Selenium e Webdriver\_manager, foi executado para a coleta de dados entre os dias 22 e 24 de novembro de 2024. O período de coleta escolhido reflete o mercado de imóveis no último trimestre de 2024, não foi realizada uma análise temporal longitudinal, o que implica que variações históricas ou tendências anteriores (como crescimento geral dos preços) não foram incorporadas.

Como resultado, foram obtidas informações sobre o título do anúncio, data da coleta (dia, mês e ano), data de publicação do anúncio, número de suítes, quartos, banheiros e vagas para veículos, área privativa, preço de venda, idade do imóvel, bairro, presença de elevador no prédio, latitude, longitude e endereço formal. As características detalhadas da vizinhança e das áreas comuns não foram incluídas explicitamente como variáveis no modelo devido à limitação de disponibilidade padronizada nos anúncios coletados. Entretanto, atributos como localização (latitude, longitude) e bairro foram utilizados indiretamente para captar parte do efeito da vizinhança.

A partir dos dados coletados, foi realizado um tratamento estatístico com remoção de outliers e o cálculo de novos atributos, como o preço de venda unitário, quantidade de banheiros e quartos por área e a qualidade do imóvel, esta última definida com base na quantidade de desvios-padrão que o preço unitário do imóvel se distancia da média do respectivo bairro. Para o treinamento do modelo, feito com o conjunto de dados tratado e cujo atributo alvo foi o preço unitário de venda do imóvel, foram testadas diferentes configurações de parâmetros de entrada, incluindo localização (latitude e longitude), relação entre quartos e banheiros por área privativa, quantidade de vagas de garagem e qualidade do imóvel. Em cada iteração de treinamento, a arquitetura da RNA com a definição de quantidade de camadas e quantidade de neurônios em cada camada, bem como seus hiperparâmetros, foram ajustados de forma iterativa com o objetivo de otimizar o desempenho do modelo com base em suas métricas.

As métricas utilizadas para avaliação do desempenho foram calculadas com um grupo de validação independente, ou seja, com dados diferentes daquele utilizados durante o treinamento. As métricas adotadas incluíram o Erro Médio Absoluto (MAE), Erro Percentual Médio Absoluto (MAPE), Raiz do Erro Quadrático Médio (RMSE) e Coeficiente de Determinação ( $R^2$ ). Para MAE, MAPE e RMSE, valores próximos a zero indicam um melhor desempenho do modelo, enquanto para  $R^2$ , valores próximos de 1 refletem uma maior capacidade de explicação da variabilidade dos preços unitários de venda. Essas métricas foram calculadas com base na diferença entre os valores previstos pelo modelo e os valores reais contidos nos dados de validação.

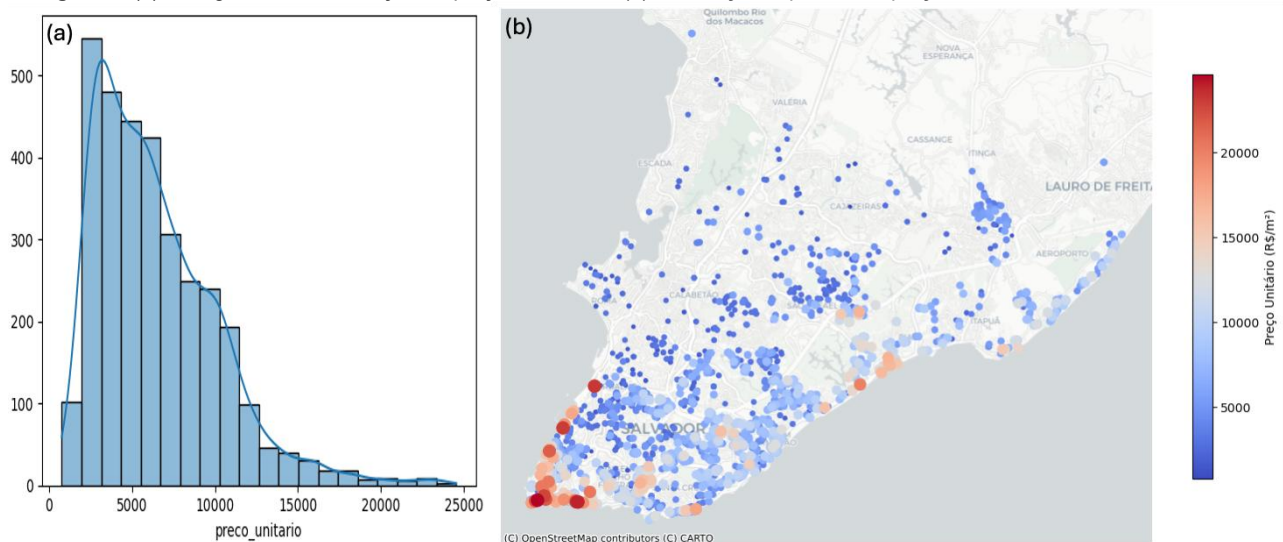
Além das métricas numéricas, foi utilizado um gráfico “Valor Real x Valor Previsto”, permitindo uma avaliação visual da precisão do modelo. A dispersão dos pontos em relação à linha de referência de  $45^\circ$  indica o quão próximas as previsões estão dos valores reais, facilitando a identificação de padrões de erro e possíveis desvios sistemáticos. Foi analisado também a distribuição do erro percentual na cidade, para identificar possíveis tendências geográficas do treinamento. Com base nas métricas obtidas e nos gráficos, o modelo é avaliado e as conclusões sobre a qualidade do modelo são feitas.

### 3 RESULTADOS E DISCUSSÕES

No total, foram coletados 5.736 anúncios. Após o tratamento dos dados, foram removidos outliers com base no preço unitário de venda, além de anúncios incompletos que não apresentavam informações mínimas sobre quantidade de quartos, banheiros ou vagas de garagem. Após essa filtragem, o conjunto final de dados utilizado para o treinamento do modelo foi composto por 3.268 anúncios.

A partir dos dados para treinamento, observou-se o comportamento dos preços de venda na cidade (Figura 1). É possível notar que os preços de venda em Salvador variam entre R\$790,00 e R\$24.000,00 por metro quadrado e tem uma média de R\$ 6.442,19/m<sup>2</sup>, estando concentrados abaixo de R\$10.000,00/m<sup>2</sup>. Em questões espaciais, observa-se que a maior concentração de anúncios ocorre nas regiões sul e sudoeste da cidade, que paralelamente tende a apresentar o maior preço por metro quadrado.

**Figura 2:** (a) Histograma de distribuição de preços de venda. (b) Distribuição espacial dos preços unitários de venda em Salvador



Fonte: Autores.

No que tange o treinamento, as combinações dos possíveis parâmetros de entrada e arquitetura da RNA foram ajustadas em busca de um melhor desempenho do modelo. A descrição da RNA assim como os valores para as métricas de avaliação é apresentada na Tabela 1.

**Tabela 1:** Descrição da RNA e métricas de avaliação


Característica	Descrição
Pré-processamento	Normalização dos dados
Estrutura da RNA	Rede densa com múltiplas camadas em progressão simétrica e <i>Dropout</i>
Função de ativação	ReLU nas camadas ocultas e Linear na saída
Função de perda	<i>Huber Loss</i>
Otimização	Adam
Crítérios de parada do treinamento	<i>EarlyStopping</i> baseado na validação
Monitoramento	Registro de logs do treinamento
Métricas de avaliação	<b>R<sup>2</sup>: 0,87, MAE: R\$ 915,44, RMSE: R\$ 1.206,62, MAPE: 18,06%</b>

Fonte: Autores.

O modelo final apresentou um coeficiente de determinação ( $R^2$ ) de 0,87, o que demonstra sua elevada capacidade preditiva. Isso significa que 87% da variação nos preços unitários dos imóveis pode ser explicada pelas variáveis selecionadas, evidenciando a efetividade do modelo em captar padrões complexos no mercado imobiliário. No entanto, os 13% restantes indicam a existência de fatores não contemplados pelo modelo, podendo ser, por exemplo, aspectos subjetivos da percepção de valor dos compradores. Apesar desse alto índice de determinação, novas iterações de treinamento com diferentes combinações de parâmetros podem ser exploradas para aproximar esse indicador de 1,0 e melhorar a precisão das previsões.

O MAE indica que, em média, as previsões do modelo diferem do valor real em cerca de R\$915,44 por metro quadrado. Considerando que o preço médio unitário em Salvador é de R\$6.442,19/m<sup>2</sup>, esse erro representa aproximadamente 14% do valor médio. Já o MAPE aponta que, em média, as previsões do modelo apresentam uma variação relativa de 18,06% em relação aos valores reais do preço unitário de venda, com erro individual máximo de 59,07%. Cabe destacar que um MAPE de 18,06% pode ser considerado elevado do ponto de vista comercial, pois se aproxima ou ultrapassa as margens médias de resultado do setor (15% e 20%). Erros dessa magnitude podem comprometer significativamente a precisão das estimativas de viabilidade e os retornos financeiros previstos. Dessa forma, aprimoramentos adicionais no modelo podem ser fundamentais para reduzir o erro percentual médio e assegurar maior confiabilidade nas análises de precificação. O RMSE de R\$1.206,62 complementa essa análise ao medir a raiz da média dos erros ao quadrado, uma métrica que penaliza erros maiores de forma mais intensa. Quando o RMSE aumenta, os pontos no gráfico “Valor Real x Valor Previsto” (Figura 3) tendem a se afastar da linha de referência de 45°, evidenciando maior dispersão nas previsões. Assim, o RMSE se torna um indicador fundamental para avaliar a robustez do modelo, permitindo identificar casos em que os erros são mais expressivos e que podem exigir ajustes adicionais.

**Figura 3:** Gráfico de dispersão Valor Real x Valor Previsto



Fonte: Autores.

Comparativamente, o MAPE obtido indica que, em relação aos trabalhos de Worzala et al. (1995) e Zancan (1995), o modelo desenvolvido apresenta menor erro individual, evidenciando maior estabilidade na previsão dos preços de venda. Worzala et al. (1995) relataram um erro de predição individual de 60,7%, enquanto o modelo desenvolvido por Zancan (1995) apresentou erro individual de 72%, destacando as dificuldades desses modelos na estimativa precisa dos preços de venda.

Por outro lado, ao comparar com os resultados de Gazola (2002), observa-se que o erro percentual médio do modelo aqui desenvolvido (18,06%) foi superior ao reportado por Gazola (11,9%). No entanto, essa diferença deve ser analisada com cautela, pois a comparação direta é limitada pelas diferenças nos contextos de mercado e nas bases de dados utilizadas. O estudo de Gazola (2002) trabalhou com uma amostra menor e potencialmente mais homogênea, o que pode ter contribuído para a obtenção de um erro médio menor.

Além disso, ao analisar a distribuição dos erros dentro de diferentes faixas, verifica-se que o modelo de Zancan (1995) apresentou 23,2% dos imóveis com erro inferior a 5%, enquanto no presente estudo 38,59% das previsões ficaram dentro dessa margem (Tabela 2), indicando maior precisão nesta categoria.

**Tabela 2:** Comparação de erros percentuais do modelo treinado com Zancan (1995)

Faixa de erro	Zancan (1995)	Este trabalho
≤ 5%	23,2%	38,59%
≤ 10%	45,3%	63,07%
≤ 15%	66,5%	77,54%
≤ 20%	78,1%	84,33%
≤ 40%	97,5%	95,32%

Fonte: Autores.

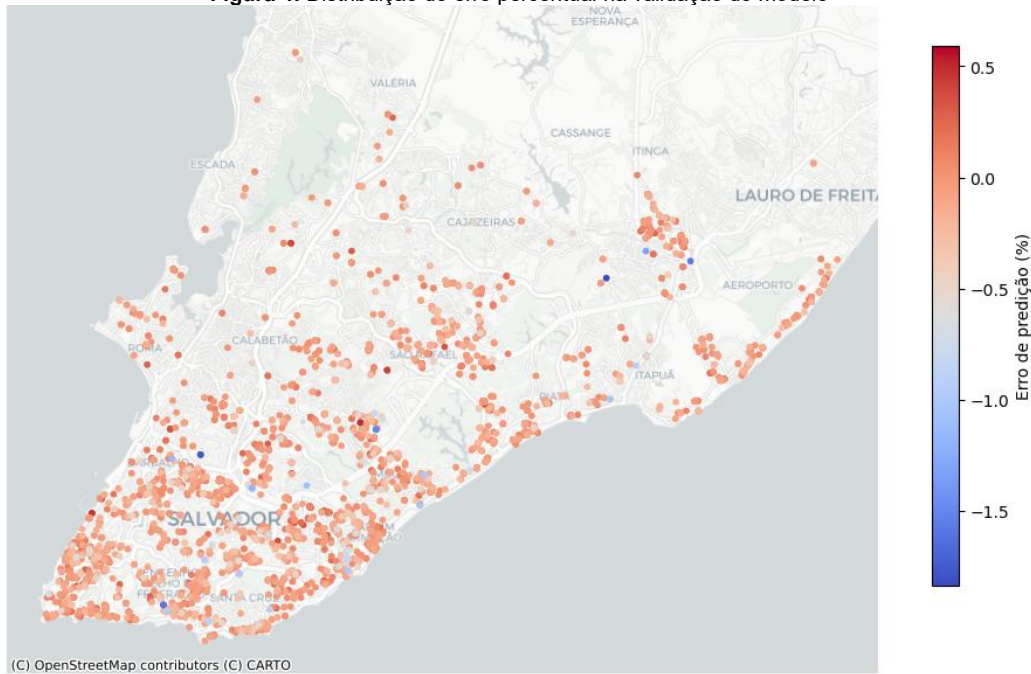
Os resultados indicam que o modelo desenvolvido apresenta um percentual maior de previsões dentro das faixas de erro de 5%, 10% e 20%, sugerindo maior precisão em relação ao modelo de Zancan (1995). No entanto, para a faixa de 40%, o modelo de Zancan obteve um desempenho ligeiramente superior (97,5% contra 95,32%), o que pode estar relacionado à menor variabilidade dos dados utilizados em seu estudo.

Além disso, ao comparar o erro individual máximo, Zancan (1995) obteve um erro máximo de 72%, enquanto Gazola (2002) relatou um erro máximo de 28,3%, inferior ao obtido no presente estudo (59,07%). Esse maior erro pode ser atribuído à maior complexidade e variabilidade do conjunto de dados utilizado, o que resulta em uma distribuição de erros mais ampla.

Esses resultados reforçam a robustez do modelo baseado em aprendizado de máquina, destacando sua capacidade de capturar padrões não lineares e minimizar discrepâncias preditivas, especialmente no controle de erros extremos e na estabilidade das previsões dentro de faixas de menor erro. No entanto, os achados também sugerem que, apesar do bom desempenho geral, há espaço para refinamentos, especialmente na redução do erro percentual médio e no tratamento de outliers.

Além da análise numérica, foi avaliada a distribuição espacial dos erros para entender o comportamento do modelo em diferentes regiões da cidade. A Figura 4 apresenta um mapa da cidade de Salvador com a distribuição espacial do erro percentual de predição do modelo em comparação a valores apresentados em anúncios. Os pontos no mapa representam os anúncios analisados, enquanto a coloração reflete a magnitude e a direção do erro percentual.

**Figura 4:** Distribuição do erro percentual na validação do modelo



Fonte: Autores.

A análise do mapa indica que o modelo não apresenta vieses geográficos significativos, uma vez que o erro percentual se mantém distribuído de forma homogênea ao longo da cidade, com valores próximos de 0%. Desvios podem ser observados, mas não há uma concentração evidente de pontos com erro elevado. Os pontos que apresentam variações maiores podem estar relacionados a discrepâncias entre os anúncios utilizado para validação do modelo e as características reais dos bairros. Mas ainda assim, essa característica não descarta a possibilidade de aprimoramento nos atributos de entrada ou no processo de treinamento do modelo com o objetivo de minimizar discrepâncias regionais.

#### 4 CONSIDERAÇÕES FINAIS

Este estudo avançou na aplicação do aprendizado de máquina para a precificação imobiliária, demonstrando que redes neurais artificiais podem capturar padrões complexos e fornecer estimativas mais acuradas do que abordagens tradicionais. Os resultados obtidos não apenas validam a eficácia do modelo proposto, mas também abrem caminhos para a aplicação dessa tecnologia em diferentes mercados e contextos urbanos, oferecendo uma ferramenta valiosa para incorporadoras, investidores e demais agentes do setor imobiliário. A abordagem adotada baseou-se no *Design Science Research* (DSR), permitindo a criação de um artefato computacional para resolver o problema de estimação de preços unitários de venda de imóveis na cidade de Salvador/BA. Os resultados obtidos demonstram que o modelo desenvolvido é capaz de explicar 87% da variabilidade dos preços unitários, apresentando um erro médio absoluto de R\$ 915,44/m<sup>2</sup>, um erro percentual médio absoluto de 18,06% e um RMSE de R\$ 1.206,62/m<sup>2</sup>.

A análise espacial dos erros indicou que o modelo não apresenta vieses geográficos acentuados, com a distribuição do erro percentual sendo relativamente homogênea ao longo da cidade. Discrepâncias foram identificadas, especialmente em regiões onde os valores anunciados podem divergir das condições reais dos bairros. Essa observação reforça a necessidade de aprimoramento dos atributos de entrada e do refinamento do treinamento do modelo para minimizar discrepâncias regionais.

O estudo demonstra a viabilidade do uso de redes neurais artificiais para a previsão de preços imobiliários, fornecendo uma abordagem sistemática para a coleta, tratamento e modelagem dos dados. Além disso, a implementação de um pipeline automatizado de extração e tratamento de dados possibilita a reprodução do estudo em diferentes contextos urbanos e de mercado. Ressalta-se que os estudos continuam em andamento, com novas versões do modelo atualmente em fase de treinamento e avaliação, buscando aprimorar a precisão das estimativas e ampliar as aplicações em diferentes cenários.

Como limitações do estudo observa-se que, o modelo depende exclusivamente dos dados de anúncios, que podem não refletir com precisão o preço final das transações imobiliárias. Aspectos subjetivos, como valor percebido do imóvel, qualidade da construção e preferências individuais dos compradores, não foram considerados na modelagem.

Para pesquisas futuras, sugere-se a exploração de outras arquiteturas de redes neurais ou técnicas de *ensemble learning*, visando aprimorar a acurácia do modelo. Além disso, a inclusão de novas variáveis, como infraestrutura do bairro, dados socioeconômicos e acessibilidade, pode contribuir para um refinamento das previsões. Ajustes finos de hiperparâmetros e experimentações com diferentes técnicas de regularização também podem ser explorados para reduzir erros e melhorar a generalização do modelo em diferentes contextos urbanos.

## REFERÊNCIAS

- CALAINHO, Felipe D.; VAN DE MINNE, Alex M.; FRANCKE, Marc K. A machine learning approach to price indices: applications in commercial real estate. *The Journal of Real Estate Finance and Economics*, v. 68, n. 4, p. 624-653, 2024.
- GAZOLA, Sebastião. **CONSTRUÇÃO DE UM MODELO DE REGRESSÃO PARA AVALIAÇÃO DE IMÓVEIS**. 2002. 104 f. Dissertação (Mestrado) - Curso de Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 2002.
- HARRISON JR, David; RUBINFELD, Daniel L. Hedonic housing prices and the demand for clean air. *Journal of environmental economics and management*, v. 5, n. 1, p. 81-102, 1978.
- LACERDA, Daniel Pacheco et al. Design Science Research: método de pesquisa para a engenharia de produção. *Gestão & produção*, v. 20, p. 741-761, 2013.
- MALPEZZI, Stephen. *Hedonic Pricing Models: A Selective and Applied Review*. Housing Economics and Public Policy/Blackwell Publishing, 2003.
- MOSCOVITCH, Samy Kopit. Qualidade de vida urbana e valores de imóveis: um estudo de caso para Belo Horizonte. *Nova Economia*, número especial, p. 247-279, 1997.
- NUNAMAKER JR, Jay F.; CHEN, Minder; PURDIN, Titus DM. Systems development in information systems research. *Journal of management information systems*, v. 7, n. 3, p. 89-106, 1990
- ROSEN, Sherwin. Hedonic prices and implicit markets: product differentiation in pure competition. *Journal of political economy*, v. 82, n. 1, p. 34-55, 1974.
- SILVA, I.; SPATTI, D.; FLAUZINO, R. *Redes Neurais Artificiais para engenharia e ciências aplicadas*. 2. ed. [s.l.] ArtLiber, 2016.
- SOLTANI, Ali; LEE, Chyi Lin. The non-linear dynamics of South Australian regional housing markets: A machine learning approach. *Applied Geography*, v. 166, p. 103248, 2024.
- WORZALA, Elaine; LENK, Margarita; SILVA, Ana. An exploration of neural networks and its application to real estate valuation. *Journal of Real Estate Research*, v. 10, n. 2, p. 185-201, 1995.
- ZANCAN, Evelise Chemale et al. Metodologia para avaliação em massa de imóveis para efeito de cobrança de tributos municipais-caso dos apartamentos da cidade de Criciúma, SC. 1995.