XXI ENTAC – Encontro Nacional de Tecnologia do Ambiente Construído
14 a 16 de outubro de 2026 | Goiânia-Brasil
DOI: https://doi.org/10.46421/entac.v21i1.8422

Classificação automática de ambientes em habitações unifamiliares brasileiras com redes neurais em grafos

Automatic Room Classification in Brazilian Single-Family Housing Using Graph Neural Networks

Bruno Perdigão de Oliveira
Universidade de São Paulo – MBA ESALQ | São Paulo | Brasil | contato@brunopo.com
Adriana Camargo de Brito
Instituto de Pesquisas Tecnológicas | Universidade de São Paulo – MBA ESALQ | São Paulo | Brasil | adrianab@ipt.br
Adriano Galindo Leal
Instituto de Pesquisas Tecnológicas | São Paulo | Brasil | leal@ipt.br

Resumo

Visando reduzir a inserção manual de nomenclaturas de ambientes em projetos BIM, analisou-se a viabilidade da classificação automática de ambientes em habitações unifamiliares brasileiras via redes neurais em grafos (GNNs). Devido à escassez de dados reais, geraram-se 200 modelos sintéticos de casas térreas, convertidos em grafos com atributos geométricos e relações espaciais. O modelo SAGE-E foi testado sob variadas combinações de camadas ocultas, nós, funções de ativação, taxas de aprendizado, lotes e agregadores, alcançando acurácia de 0,96 no teste. Apesar do alto desempenho, houve limitações na diferenciação de ambientes semanticamente similares, refletindo a complexidade da arquitetura residencial brasileira e do próprio modelo. Conclui-se que a abordagem pode reduzir tarefas repetitivas em fluxos BIM, potencializada pela futura ampliação da base de dados e novos atributos semânticos.

Palavras-chave: Modelagem da Informação da Construção. Redes neurais em grafos. Enriquecimento semântico. Classificação de ambientes. Habitação unifamiliar.

Abstract

Aiming to reduce manual room naming in BIM projects, this study analyzed the feasibility of automatic room classification in Brazilian single-family dwellings via Graph Neural Networks (GNNs). Due to real-world data scarcity, 200 synthetic single-story house models were generated and converted into graphs capturing geometric attributes and spatial relationships. The SAGE-E model was tested under various combinations of hidden layers, nodes, activation functions, learning rates, batch sizes, and aggregators, achieving a 0.96 accuracy on the test set. Despite this high performance, limitations occurred when differentiating semantically similar rooms, reflecting both model constraints and the complexity of Brazilian residential architecture. In conclusion, this approach can reduce repetitive tasks in BIM workflows, a potential that could be enhanced by expanding the database and incorporating additional semantic attributes.

Keywords: Building information modeling. Graph neural networks. Semantic enrichment. Room classification. Single-family housing.

Como citar:
OLIVEIRA, B. P.; BRITO, A. C.; LEAL, A. G.; Classificação automática de ambientes em habitações unifamiliares brasileiras com redes neurais em grafos. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 21, 2026, Goiânia. **Anais**... Goiânia: ANTAC, 2026.

INTRODUÇÃO

O Building Information Modeling (BIM) ampliou a capacidade de representar, em um mesmo modelo digital, a geometria, as propriedades e as relações entre os componentes do ambiente construído [1]. Ainda assim, parte relevante da semântica espacial continua a ser inserida manualmente, sobretudo na identificação de ambientes e no enriquecimento de modelos obtidos em fluxos de Scan-to-BIM. Essa etapa é repetitiva, consome tempo e tende a gerar inconsistências entre os modelos de um mesmo portfólio. Nesse sentido, proporcionar a automatização de tarefas como o preenchimento de informações que identifiquem os ambientes, contribuiria para a melhoria da eficiência do ciclo de projeto de grandes empreendimentos.

Na literatura, o enriquecimento semântico de modelos BIM tem sido abordado por meio de estratégias baseadas em regras e em métodos de aprendizado de máquina [2] [3].

As abordagens por regras oferecem maior controle, mas dependem de condições explícitas e têm menor flexibilidade diante de layouts variados. Já as abordagens orientadas por dados conseguem inferir padrões latentes e absorver parte da variabilidade arquitetônica, desde que a representação preserve o contexto relacional do projeto [3][4].

Nesse ponto, grafos e redes neurais gráficas (GNNs) são particularmente adequados. Grafos permitem modelar entidades e relações em estruturas não euclidianas [5], enquanto, em arquitetura, permitem representar a organização espacial de uma edificação por meio de nós e de conexões [6]. No contexto do BIM, diferentes autores têm convertido modelos em grafos para consulta, interoperabilidade e classificação [7] [8][9]. Para a classificação de ambientes, a vantagem central das GNNs é explorar simultaneamente atributos locais e a vizinhança topológica, o que tende a ser mais aderente à lógica do projeto arquitetônico do que os classificadores tabulares isolados.

Apesar do avanço internacional, ainda há escassez de estudos sobre habitações brasileiras. Essa lacuna é relevante porque as tipologias, dimensões e relações entre ambientes variam conforme as práticas projetuais e os condicionantes socioculturais locais [12]. Em habitações brasileiras compactas, ambientes como sala de estar e sala de jantar frequentemente apresentam continuidade espacial, proporções próximas e centralidade semelhante na organização da planta, o que tende a reduzir a separabilidade entre classes semanticamente próximas. Assim, a contribuição deste trabalho não está na proposição de uma nova arquitetura de GNN, mas na avaliação da viabilidade técnica de empregar o aprendizado em grafos para a classificação de ambientes em habitações unifamiliares brasileiras, como prova de conceito orientada à replicabilidade metodológica e ao enriquecimento semântico futuro de modelos arquitetônicos.

MÉTODO

A pesquisa adota uma abordagem experimental, de natureza quantitativa, fundamentada na coleta e análise de dados numéricos para a construção de um

modelo de classificação automatizada de ambientes em projetos de arquitetura. O método empregado utiliza Graph Neural Networks (GNNs) supervisionadas, com foco na identificação de espaços residenciais unifamiliares.

Para treinar um modelo GNN seria necessária a disponibilidade de bases de dados representativas dos projetos na forma de grafos. Todavia, não há disponibilidade de dados com essas características. Por esse motivo, foram gerados dados sintéticos tridimensionais estruturados, a partir de algoritmos paramétricos que simulam a geometria e as características de ambientes habitacionais típicos (sala, cozinha, quarto, banheiro), contemplando informações quantitativas (dimensões, áreas) e categóricas (função dos espaços).

GERAÇÃO DA BASE E REPRESENTAÇÃO EM GRAFO

Foram utilizados algoritmos paramétricos para criar modelos tridimensionais de casas térreas unifamiliares [9][11] por meio da biblioteca TopologicPy [10]. Esses modelos foram construídos a partir da variação de parâmetros arquitetônicos, como quantidade de dormitórios, presença de varanda e área de serviço, além das dimensões de cada ambiente.

A biblioteca TopologicPy permite representar edifícios a partir da lógica de non-manifold topology, em que cada elemento geométrico (vértices, arestas, faces e células) é único e pode ser enriquecido com informações adicionais. Essa característica possibilita converter modelos tridimensionais em grafos, mantendo a lógica espacial do projeto arquitetônico. Assim, um ambiente pode ser entendido como um nó do grafo, e suas conexões (portas ou janelas) como arestas, vinculando informações geométricas (dimensões, área, volume) e funcionais (uso do ambiente).

ENGENHARIA DE ATRIBUTOS

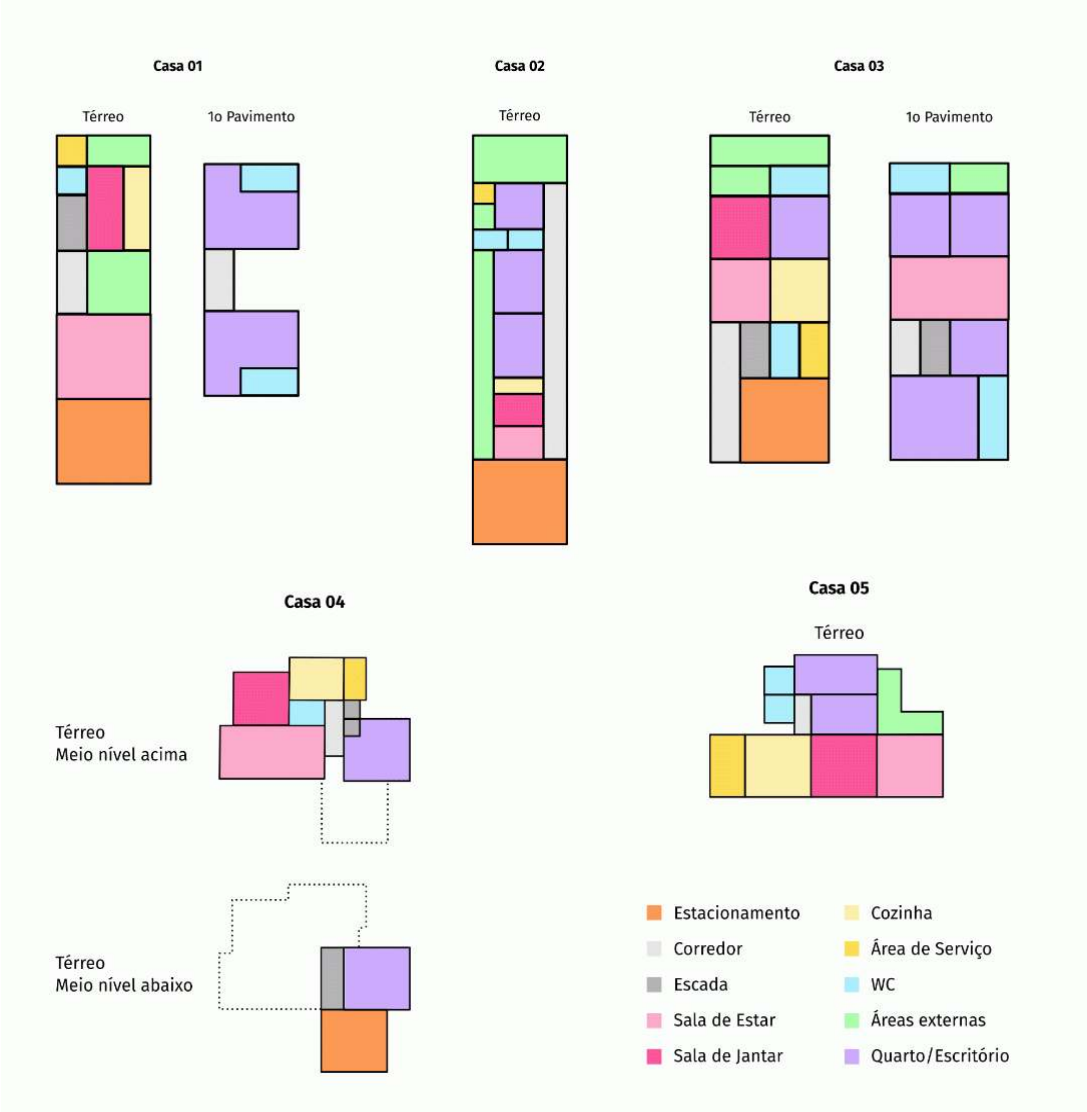
Para geração dos dados sintéticos foram adotadas como base tipologias de casas unifamiliares (Figura 1) comuns no mercado nacional tanto para uso como residências ou escritórios, com base em informações de importante portal de arquitetura[1]. A seleção das tipologias de casa foi feita com o intuito de proporcionar diversidade de composições e conexões, sendo consideradas casas com área de piso de 100 a 250 m².

O algoritmo desenvolvido para a geração dos modelos tridimensionais introduziu variações aleatórias em até 25% em dimensões horizontais, e até 15% na altura (mantendo dimensões compatíveis com as do mercado) e alterações na disposição de ambientes das casas (número de dormitórios, posição). No Quadro 1 são indicadas as variáveis abordadas.

[1] https://www.archdaily.com.br/search/br/projects

DOI: https://doi.org/10.46421/entac.v21i1.8422

Figura 1: Esquema de distribuição dos ambientes nas cinco tipologias de habitações



Fonte: Autores

Quadro 1 – Descrição das variáveis consideradas na geração dos dados sintéticos

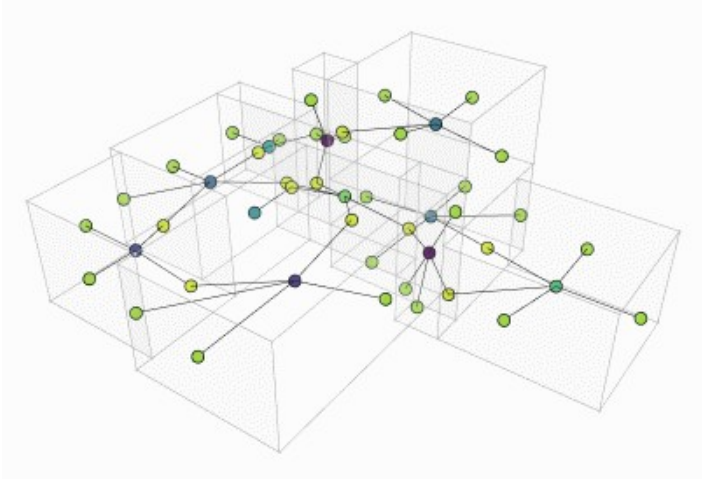
Tipologias	Variáveis específicas	Variáveis comuns às tipologias
Casa 1	Presença ou ausência de pátio Presença de um quarto ou Presença dos dois quartos	Dimensões horizontais Altura do pé direito Largura de corredores
Casas 2 e 3	Presença de dois quartos ou Presença de três quartos	
Casa 4	Profundidade do sanitário Profundidade da escada Variações nos eixos	
Casa 5	Largura do terraço Presença de dois quartos ou Presença de três quartos	

Fonte: Autores

A base experimental foi composta por 200 habitações unifamiliares térreas sintéticas totalizando mais de 1000 ambientes rotulados. Embora a literatura da área frequentemente aborde a cadeia BIM-IFC-grafo, o fluxo experimental adotado concentrou-se na geração paramétrica, na representação topológica e no aprendizado de grafos. Assim, a conversão para grafo ocorreu diretamente a partir do modelo topológico, sem a etapa intermediária de exportação para IFC. Cada instância resultou em um grafo com nós associados a ambientes e a elementos de conexão relevantes ao uso espacial, e arestas representando adjacência e acesso (Figura 2).

Os atributos de entrada do classificador foram largura, comprimento, altura, área, volume, condição do ambiente de entrada, condição do ambiente externo e presença de instalações hidráulicas. As classes consideradas no problema foram escada, estacionamento, sala de estar, sala de jantar, cozinha, dormitório, banheiro, área de serviço, jardim/pátio, terraço, corredor, janela e porta. No Quadro 2 é apresentada uma síntese das características da base sintética e da representação em grafo.

Figura 2: Exemplo de habitação convertida em grafos



Nota: Observações: Cada prisma representa um ambiente nos quais os nós são o centroide de cada elemento ou ambiente, conectados entre si pelas arestas. Fonte: autores.

Quadro 2: Síntese da base sintética e da representação em grafo

Tipologias base	Cinco tipologias de casas térreas unifamiliares
Número de grafos	200 habitações sintéticas
Faixa de área	100 a 250 m²
Variações	Dormitórios, varanda, pátio, área de serviço, corredores, posição relativa e dimensões
Atributos nodais	Largura, comprimento, altura, área, volume, entrada, exterior, e hidráulica
Classes	13 rótulos entre ambientes e elementos de conexão
Tipologias base	Cinco tipologias de casas térreas unifamiliares
Número de grafos	200 habitações sintéticas

Fonte: autores.

TREINAMENTO E MÉTRICAS

Foi adotada a arquitetura SAGE-E, variante do GraphSAGE com atributos de aresta, devido ao seu caráter indutivo e ao uso prévio em tarefas de classificação espacial em modelos arquitetônicos [8][9][11]. A escolha por GNNs decorre do fato de que o problema investigado depende não apenas de atributos isolados dos ambientes, mas também de sua posição relativa na configuração espacial da habitação. A base foi dividida em 70% para treinamento, 10% para validação e 20% para teste. O processo de ajuste utilizou 50 épocas, o otimizador Adam e a função de perda por entropia cruzada.

A seleção de hiperparâmetros foi realizada por meio de busca em grade, testando o número de camadas ocultas (2, 3, 4 e 5), o número de nós por camada (25, 50 e 100), a função de ativação (ReLU e Tanh), a taxa de aprendizado (0,01; 0,005; 0,001; 0,0005), o tamanho do lote (16, 32 e 64) e o agregador (Mean, Pool e LSTM).

Para a avaliação quantitativa do desempenho dos modelos, foram adotadas as métricas de Acurácia, Precisão, Sensibilidade (ou Recall) e F1-Score. Estas métricas fundamentam-se nos valores de Verdadeiros Positivos (TP), Verdadeiros Negativos (TN), Falsos Positivos (FP) e Falsos Negativos (FN), sendo formalmente definidas pelas expressões 1 a 4.

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precisão = \frac{TP}{TP + FP} \quad (2)$$

$$Sensibilidade = \frac{TP}{TP + FN} \quad (3)$$

$$F1 = \frac{2.Precisão}{Precisão + Sensibilidade} \quad (4)$$

Os algoritmos e scripts desenvolvidos estão disponíveis em um repositório público[2].

RESULTADOS

A melhor configuração observada na busca em grade utilizou três camadas ocultas, 100 nós por camada, ativação Tanh, taxa de aprendizado de 0,01, lote de 64 e agregador Mean (Tabela 1). Com essa configuração, o modelo atingiu acurácia de 0,96 no conjunto de teste. Esse valor, embora elevado, deve ser interpretado em conjunto com as métricas por classe e com o F1 macro, uma vez que o desempenho não foi homogêneo entre os diferentes rótulos. A partir dos valores de precisão e sensibilidade por classe, obteve-se um F1 macro aproximado de 0,89, indicando desempenho global elevado, mas com heterogeneidade significativa entre as classes.

[2] https://github.com/brunoperdigao/Plan-Classification-Topologic-DGL

Tabela 1: Configuração final do modelo e métricas globais

Parâmetro	Valor
Camadas ocultas	3
Nós por camada	100
Função de ativação	Tanh
Taxa de aprendizado	0,01
Tamanho do lote	64
Agregador	Mean
Acurácia no teste	0,96

Fonte: autores.

Os melhores resultados foram obtidos em classes mais distintas do ponto de vista topológico e funcional, como escada, estacionamento, corredor, terraço, janela e porta. Em contrapartida, sala de estar, sala de jantar e dormitório apresentaram maior confusão, com destaque para a sala de jantar, cuja sensibilidade foi 0,38 e o F1 0,49. Esses resultados sugerem que a estrutura relacional do grafo foi suficiente para reconhecer classes com assinatura espacial mais forte, mas ainda limitada para separar ambientes compactos e semanticamente próximos (Tabela 2).

Tabela 2: Configuração final do modelo e métricas globais

Classe	Precisão	Recall	F1
Sala de jantar	0,69	0,38	0,49
Sala de estar	0,83	0,67	0,74
Dormitório	0,67	0,86	0,75
Área de serviço	0,91	0,74	0,82
Cozinha	0,96	0,91	0,93
Banheiro	0,86	0,96	0,91
Sala de jantar	0,69	0,38	0,49

Fonte: autores.

DISCUSSÃO

Os resultados confirmam a capacidade das GNNs em capturar relações topológicas relevantes entre os ambientes, mesmo quando aplicadas a dados sintéticos. Do ponto de vista aplicado, embora a abordagem seja promissora como mecanismo de apoio ao projetista e de enriquecimento semântico de modelos, ainda precisaria ser aprimorada para se tornar uma ferramenta autônoma.

O comportamento do modelo mostrou-se coerente com a literatura internacional sobre enriquecimento semântico e classificação em modelos arquitetônicos [3][8][9][11]. Ainda assim, a aproximação com estudos internacionais deve ser interpretada apenas de modo indicativo, pois há diferenças importantes, especialmente quanto ao tamanho da base de treinamento dos modelos, à natureza sintética ou real dos dados e ao escopo arquitetônico considerado.

As dificuldades do modelo em distinguir ambientes como salas e dormitórios decorre, não somente de limitações quanto à quantidade de dados disponíveis para seu

treinamento, mas também à complexidade semântica da habitação e ao contexto cultural no qual se insere.
Em habitações brasileiras compactas, sala de estar e sala de jantar frequentemente compartilham proporções, posição central e continuidade espacial; os dormitórios, por sua vez, podem apresentar dimensões e conectividade semelhantes em diferentes tipologias. Nesses casos, apenas atributos geométricos básicos e adjacência imediata mostraram-se insuficientes para desambiguar o uso pretendido do espaço.

Além disso, é necessário considerar que a organização espacial das residências reflete práticas próprias de cada localidade. Por exemplo, uma habitação popular em Portugal tende a apresentar dimensões significativamente maiores do que residências populares no Brasil, que em muitos casos, se aproximam em área construída das habitações de classe média [12]. Essa variação não se limita ao tamanho, mas também ao modo como os ambientes são organizados e integrados, às soluções construtivas adotadas e aos materiais utilizados. Assim, para que uma ferramenta de classificação de ambientes seja aplicável de maneira ampla, ela deve ser alimentada com projetos que representem as particularidades arquitetônicas e culturais de diferentes contextos locais.

Nesse sentido, seria adequado incorporar ao modelo atributos semânticos complementares, capazes de enriquecer a representação dos ambientes e fornecer ao modelo maior contexto interpretativo [13]. Elementos como mobiliário, materiais de acabamento, tipos de aberturas desempenham papel fundamental na diferenciação dos espaços e podem ser utilizados para reduzir ambiguidades que apenas informações geométricas não conseguem resolver.

Dessa forma, embora promissora, a abordagem desse estudo oferece limitações, decorrentes de fatores como: base sintética restrita; representação com atributos semânticos limitados e foco em habitações térreas unifamiliares. Como continuidade do trabalho, para a criação de ferramenta prática robusta, é necessário ampliar a base de dados de treinamento, incluindo representação de projetos reais representativo da arquitetura nacional e maior variedade tipológica, considerando atributos semânticos ricos, como mobiliário, materiais e tipologia de aberturas, além de comparar a SAGE-E com outras arquiteturas, como GAT e variantes multimodais.

CONCLUSÕES

O estudo forneceu evidências de viabilidade do uso de GNN para classificação automática de ambientes em habitações brasileiras modeladas como grafos. A combinação entre representação topológica e atributos geométrico-funcionais permitiu alcançar acurácia de 0,96 em uma base sintética controlada, com melhor desempenho em classes espacialmente mais distintas.

A principal contribuição do trabalho é demonstrar, em um cenário experimental controlado, que a lógica relacional capturada pelos grafos pode apoiar o enriquecimento semântico inicial de modelos arquitetônicos brasileiros, inclusive em contexto de escassez de bases de dados abertas. Ao mesmo tempo, o estudo explicita

que a generalização do método depende da ampliação da variabilidade tipológica, do enriquecimento dos atributos e da consolidação de protocolos reprodutíveis mais completos. Em síntese, a abordagem é tecnicamente promissora, mas seu uso operacional em larga escala ainda requer ampliação da base de dados, dos atributos e do referencial experimental.

DECLARAÇÃO SOBRE USO DE IA GENERATIVA

Foi utilizado o modelo de linguagem Gemini 3, para efetuar correções ortográficas no texto, bem como aprimoramentos de redação, com base em textos originais redigidos pelos autores. Destaca-se que os autores são os únicos responsáveis pelo conteúdo do trabalho.

REFERÊNCIAS

[1] GOLDMAN, G.; ZARZYCKI, A. **Smart buildings/smart(er) designers:** BIM and the creative design process. In: CHENG, R.; JARBOE, K.; EASTMAN, C. M. (ed.). Building Information Modeling: BIM in current and future practice. Hoboken: John Wiley & Sons, 2014.

[2] BELSKY, M.; SACKS, R.; BRILAKIS, I. **Semantic enrichment for Building Information Modeling.** Computer-Aided Civil and Infrastructure Engineering, [S. l.], v. 31, n. 4, p. 261-274, 2016. DOI: 10.1111/mice.12128.

[3] BLOCH, T.; SACKS, R. **Comparing machine learning and rule-based inferencing for semantic enrichment of BIM models**. Automation in Construction, [S. l.], v. 91, p. 256-272, 2018. DOI: 10.1016/j.autcon.2018.03.018.

[4] XUE, F.; WU, L.; LU, W. **Semantic enrichment of building and city information models: a ten-year review**. Advanced Engineering Informatics, [S. l.], v. 47, art. 101245, 2021. DOI: 10.1016/j.aei.2020.101245.

[5] CHAMI, I. et al. **Machine learning on graphs: a model and comprehensive taxonomy.** arXiv, 2022. Disponível em: https://arxiv.org/abs/2005.03675. Acesso em: 10 abr. 2024.

[6] VARDOULI, T. **Skeletons, shapes, and the shift from surface to structure in architectural geometry.** Nexus Network Journal, [S. l.], v. 22, p. 487-505, 2020. DOI: 10.1007/s00004-020-00478-0.

[7] KHALILI, A.; CHUA, D. H. **IFC-based graph data model for topological queries on building elements**. Journal of Computing in Civil Engineering, [S. l.], v. 29, n. 3, 2015. DOI: 10.1061/(ASCE)CP.1943-5487.0000331.

[8] WANG, Z.; SACKS, R.; YEUNG, T**. Exploring graph neural networks for semantic enrichment: room type classification**. Automation in Construction, [S. l.], v. 134, art. 104039, 2022. DOI: 10.1016/j.autcon.2021.104039.

[9] ALYMANI, A.; JABI, W.; CORCORAN, P. **Graph machine learning classification using architectural 3D topological models**. Simulation, [S. l.], v. 99, n. 11, p. 1117-1131, 2023. DOI: 10.1177/00375497221105894.

[10] JABI, W. et al. **Topologic: a toolkit for spatial and topological modelling**. In: eCAADe CONFERENCE, 36., 2018, Lodz. Proceedings [...]. Lodz: Lodz University of Technology, 2018. v. 2, p. 449-458.

[11] JABI, W.; LI, Y. **Graph neural networks for node classification and attribute allocation in architectural BIM**. In: eCAADe CONFERENCE, 42., 2024, Nicosia. Proceedings [...]. Nicosia: University of Cyprus, 2024. v. 1, p. 675-684.

[12] PEDRO, J. B.; BOUERI FILHO, J. J. **Exigências de espaço aplicáveis à construção de habitações de interesse social: comparação entre Portugal e o município de São Paulo**. Pós. Revista do Programa de Pós-Graduação em Arquitetura e Urbanismo da FAUUSP, [S. l.], v. 19, n. 32, p. 116-135, 2012.

[13] CAI, G.; PAN, Y. Automated generation of room usage semantics from point cloud data. ISPRS **International Journal of Geo-Information** [S. l.], v. 12, n. 10, p. 427, 2023.