

MAPEAMENTO IFC AUTOMATIZADO POR IA EM NUVENS DE PONTOS PARA GESTÃO DE DANOS EM ATIVOS

Paulo Alberto Sampaio Santos⁽¹⁾, Clarissa Caetano⁽²⁾, Isabela Ribeiro Ferreira⁽³⁾, Lissa Gomes Araujo⁽⁴⁾, Michele Tereza Marques Carvalho⁽⁵⁾

(1) Universidade de Brasília, Brasília - Brasil, 0000-0002-9801-1423

(2) Universidade de Brasília, Brasília - Brasil, 0009-0007-5967-1596

(3) Universidade de Brasília, Brasília - Brasil, 0000-0002-3918-5669

(4) Universidade de Brasília, Brasília - Brasil, 0000-0002-9517-1202

(5) Universidade de Brasília, Brasília - Brasil, 0000-0001-7969-9341

Resumo

Nos últimos anos, a aplicação de tecnologias voltadas para a gestão de ativos de infraestrutura tem sido impulsionado pela metodologia Building Information Modeling (BIM). Um exemplo é a convergência entre BIM e inteligência artificial (IA), que permite a geração automatizada de representações digitais, fundamentais para refletir o estado real de ativos. Nesse cenário, o uso de scanners a *laser* surge como alternativa eficiente aos métodos tradicionais, reduzindo custos e riscos operacionais. Porém, para bom uso do modelo digital do ativo, é necessário boas práticas da metodologia BIM em padronização da informação, como é o caso do formato de classes hierárquicas de informações do *Industry Foundation Classes* (IFC). Este artigo apresenta fluxo de trabalho para mapeamento automatizado de danos estruturais em IFC 4x3. Foram aplicados modelos de IA disponibilizados previamente para o reconhecimento automático de danos estruturais em nuvens de pontos. Os danos foram convertidos para malha contínua e exportados formatos 3D mapeados com padrão IFC 4.3 e adicionados a um modelo BIM, consolidando um fluxo de trabalho automatizado que mapeia danos para as entidades dos elementos. Esta abordagem estabelece um banco de dados semântico para Gêmeos Digitais, viabilizando a gestão de ativos com inventários precisos, necessário para a manutenção preditiva.

1. Introdução

Ativos de infraestrutura como pontes, rodovias, ferrovias e túneis, tendem a ser empreendimentos de alto custo, alto impacto aos usuários e longo ciclo de vida, portanto, com significativo valor agregado. Para garantir esta longevidade e contínuo desempenho adequado às necessidades dos usuários, a gestão destes ativos em conjunto com manutenções periódicas são indispensáveis. Neste contexto, inspeções são, em grande maioria, realizadas manualmente

por visitas de campo. O processo em si, por não ter uma abordagem detalhada por ensaios precisos, é muitas vezes baseado em análises visuais, o que traz ao fator humano um importante impacto, por estar sujeito a interpretações subjetivas [1]. Além disso, a gestão de fotos das inspeções é morosa, exigindo localização e rotulagem manual em plantas para a produção de relatórios e orçamentos.

Avanços em visão computacional e nuvens de pontos, aliados ao padrão IFC 4.3, otimizam a compreensão da gestão de ativos e suas necessidades. Aliada ao BIM, esta estrutura de dados garante a interoperabilidade necessária para automatizar inspeções, permitindo que detecções por IA sejam armazenadas de forma universal e acessível ao longo do ciclo de vida da obra.

Além disso, algoritmos de aprendizado profundo, vêm sendo propostos como ferramentas para auxílio na identificação de elementos danificados e possíveis patologias estruturais. As Redes Neurais Convolucionais (CNNs), por exemplo, são algoritmos de inteligência artificial (IA) capazes de extrair automaticamente características de dados brutos ou gerar variações utilizando recursos avançados, sem a necessidade de pré-processamento de imagens ou pré-extração de características [1]. Modelos CNNs têm se mostrado uma ferramenta eficaz na detecção automatizada de anomalias durante a gestão de ativos de edificações [2]. Visto o aspecto de treinamento das redes neurais, ou seja, da necessidade de dados nos quais o algoritmo precisa ser embasado, o caso brasileiro apresenta potencial, visto que o órgão responsável por esses ativos é centralizado nacionalmente. O Departamento Nacional de Infraestrutura em Transportes brasileiro (DNIT), gerencia cerca de 8 mil estruturas rodoviárias, através do Sistema de Gerenciamento de Obras de Arte Especiais (SGO) e possui um banco com 560 mil imagens provenientes de inspeções cadastrais e rotineiras, todas avaliadas por especialistas conforme normas técnicas vigentes [3].

Diante deste cenário, este estudo propõe o desenvolvimento de um fluxo de trabalho automatizado para mapeamento automatizado de danos estruturais e manifestações patológicas em IFC 4x3, com foco no reconhecimento de fissuras, deslocamento de concreto, manchas de corrosão, armadura exposta e eflorescência, para integração a um modelo BIM, visando a superação de lacunas na representação digital de danos. Dessa forma, o presente trabalho foca em abrir caminhos para a padronização da informação, a partir da metodologia BIM e o mapeamento preciso de classes IFC. Portanto este estudo estrutura-se em:

- Propor um processo de mapeamento de danos estruturais e manifestações patológicas em IFC 4x3 resultantes de modelos de IA utilizadas em captura de nuvens de pontos via scanners a laser;
- Consolidar um processo de conversão sistemática de malhas de nuvens de pontos para transformação em BIM.

2. Estado da Arte

Compreender os componentes e as informações de um ativo é fundamental para garantir a eficiência na execução e gestão operacional. Os avanços tecnológicos recentes para processamento de dados e Internet das Coisas (IoT) são uma oportunidade de aplicação estruturada para a indústria da construção por meio da metodologia BIM. Quando aplicada corretamente, permite que os dados gerados no contexto da construção, sejam organizados e tenham aplicação prática para resolução dos problemas nos fluxos de processos.

2.1. Industry Foundation Classes (IFC) para interoperabilidade de informações

No contexto da metodologia BIM, a eficiência na comunicação entre as partes interessadas depende da acessibilidade e da continuidade dos dados gerados. Nesse cenário, o padrão IFC consolida-se como um modelo de informação extensível, cujo propósito central é apoiar o compartilhamento de dados em código aberto durante todo o ciclo de vida do ativo [9].

Tecnicamente, o esquema armazena parâmetros geométricos e metadados fundamentados na linguagem EXPRESS, estabelecendo um padrão semântico de regras e nomenclaturas. Esta linguagem formal, inspirada no paradigma da Programação Orientada a Objetos (POO), organiza as informações em uma hierarquia de classes que integra comportamentos e heranças, o que favorece a modularidade e a manutenção do ativo [10]. Ao capturar dados, o IFC assegura a interoperabilidade plena entre diferentes softwares, mitigando perdas de informação e garantindo a persistência dos dados no ecossistema digital [11].

2.2. Enriquecimento semântico do IFC

O enriquecimento semântico de modelos BIM é definido como o processo no qual algoritmos, sejam eles baseados em inteligência artificial ou não, adicionam informações específicas necessárias a um modelo, objeto ou elemento que originalmente apresentava ausência de dados [12]. Em metodologias que propõem o uso de IAs em etapas do BIM, seja em modelos federados, parciais ou na concepção de componentes, os usuários devem extrair as informações e compilá-las em dados tabulares, como arquivos .csv, ou em arquivos estruturados voltados ao enriquecimento semântico do padrão IFC [13].

Para operacionalizar o processamento dos dados gerados na nuvem de pontos, as pesquisas apontam o uso da Inteligência Artificial, que tem sido estruturada em três eixos fundamentais: (i) visão computacional e aprendizado profundo para a classificação de informações e monitoramento de canteiros; (ii) gestão de empreendimentos e Gêmeos Digitais, utilizando o enriquecimento semântico para manutenção de ativos; e (iii) mineração de dados para previsão de riscos e suporte estratégico à decisão [4].

O processo de coleta de informações vem sendo explorado por pesquisadores em diversas proposições metodológicas, como o uso de IAs no campo da visão computacional para coleta de inspeções de pontes utilizando dispositivos conectados à internet das coisas (IoT) [5], e a coleta de dados de anomalias em nuvem de pontos de escaneamento a laser para utilização em IA para gestão de ativos [6].

Em [1] uma CNN é utilizada na coleta de dados com servidores móveis e com web para detecção de fissuras de acordo com os limites definidos (largura e comprimento da fissura) em concretos pré-moldados. Um processo similar foi realizado com o algoritmo Inception-V3 em [7], [8], propondo uma CNN voltada para detecção de fissuras de sistemas de mecânica, elétrica e hidráulica (MEP), a partir de nuvem de pontos.

3. Metodologia

O fluxo de trabalho proposto neste estudo baseia-se no mapeamento automatizado de danos estruturais em formato IFC 4x3, estruturado e proposto em quatro etapas principais: Os estágios iniciais (i) e (ii) focam no tratamento dos dados recebidos pela inspeção através da seção (i) aquisição e ortoprojeção de dados; e seção (ii) detecção e segmentação em instâncias de patologias por visão computacional. Na sequência, é apresentado o processo de tratamento dos

dados na seção (iii) reconstrução e otimização do modelo 3D. Relativamente ao mapeamento do IFC, é apresentada a seção (iv) a conversão da malha para IFC. Todo o resultado do processo é discutido e analisado nos capítulos que seguem.

3.1 Etapa 1 - Aquisição e ortoprojeção de dados

Nesta etapa é realizada a criação automatizada dos modelos BIM. Inicialmente, realizou-se a captura de nuvens de pontos via *scanner* terrestre a partir de inspeções prediais, com foco na varredura de partes degradadas de edificações prediais. Para a extração de informações bidimensionais (2D), um algoritmo matemático é utilizado para simplificar as nuvens de pontos para vetorização das perspectivas, preservando a precisão dos dados, e convertendo as coordenadas de um sistema 3D para 2D.

Para isso, foram implementadas programações em linguagem *Python* para o posicionamento multiangular de câmeras virtuais. Esta automação gera posicionamentos de imagens 2D a partir de quatro perspectivas de visão em cada amostra de nuvem de pontos analisada. Esse processo permitiu a captura sistemática de imagens a partir da nuvem de pontos bruta.

A precisão geométrica e o georreferenciamento das patologias foram assegurados pela aplicação de uma matriz de transformação homogênea $[4 \times 4]$, que aplica rotações nos eixos *Y* e *Z* através de funções trigonométricas. Isso garante que cada ponto da imagem seja representado em múltiplas perspectivas. Essa matriz é o componente que permite o georreferenciamento da patologia, pois as coordenadas dos *pixels* das imagens geradas podem ser transformadas em informações geográficas precisas, quando integradas a estações de referência como *Differential GPS* (DGPS) ou *Real-Time Kinematic* (RTK).

3.2 Etapa 2 - Detecção e segmentação em instâncias de patologias por visão computacional

Para esta etapa, as imagens geradas foram submetidas a uma análise automatizada, utilizando uma arquitetura híbrida de modelos de visão computacional: modelo YOLOv8l refinado para a detecção dos danos e o SAM para segmentação e recorte das instâncias de patologias identificadas nas ortoimagens, culminando na transferência desse mapeamento para a nuvem de pontos. A solução híbrida tem precisão, recall, mAP_{50} e mAP_{50-95} , de 0.946, 0.916, 0.951 e 0.892 respectivamente e utiliza os modelos disponibilizados em Santos et al. [14], treinado a partir do banco de dados de 41.132 anotações com foco em elementos estruturais de pontes e viadutos, refinado para reconhecimento de fissuras, deslocamento de concreto, manchas de corrosão, armadura exposta e eflorescência.

3.3. Etapa 3 - Reconstrução e otimização do modelo 3D

Nesta etapa realiza-se a triangulação de nuvens de pontos para o encerramento do fluxo com a projeção da máscara 2D de volta ao ambiente tridimensional, para que um arquivo IFC seja mapeado. Inicialmente, somente a parte segmentada das instâncias de patologias das imagens são retornadas às nuvem de pontos através de algoritmos de programação e recortadas para que representem só as instancias identificadas da nuvem de pontos. Todo o processo nesta etapa é realizado por meio de códigos de programação em *Python* baseado na metodologia de [15].

Em seguida, a biblioteca Open3D foi aplicada, que utiliza o processo de reconstrução da superfície pelo Algoritmo de *Poisson* [15] por ter boa performance em nuvens de pontos densas, com grandes conjuntos de dados. A escolha manteve-se neste algoritmo por se tratar de um processo matemático amplamente utilizado em diversos softwares, como o *CloudCompare* e o

Autodesk Recap. A replicação das etapas deste estudo é facilitada em diversos ambientes e *softwares* por conta da acessibilidade da biblioteca Open3D.

3.4. Etapa 4 - Conversão dos pontos para IFC

A etapa final de consolidação dos dados consiste na conversão das nuvens de pontos segmentadas em objetos paramétricos dentro do padrão IFC 4.3. Para este propósito, utilizou-se o ecossistema *open-source* composto pelo software Blender e o plugin BonsaiBIM, que integra a biblioteca IfcOpenShell (v0.7.0).

4. Resultados

O processamento iniciou-se pela geração de imagens (ortoprojeções) a partir de ângulos distintos de nuvens de pontos, utilizando rotações sistemáticas de 30° nos eixos Y e Z (eixo X em 0°). Este procedimento converte a nuvem de pontos em imagens RGBD de 1404×795 pixels, posteriormente redimensionadas para 640×640 para atender o pré-requisito de dado de entrada para o modelo de IA utilizado. Esta IA reconhece somente imagens, o que justifica a necessidade de transformar nuvem de pontos em ortoprojeções. Na sequência do processo se faz necessário retornar os resultados para a nuvem de pontos, dessa forma a inclusão de uma matriz de transformação 4×4 na programação preservou o georreferenciamento original da nuvem de pontos, permitindo a integração posterior com sistemas GPS e o padrão IFC.

A definição das imagens baseou-se nos limites das coordenadas X e Y , mapeando as propriedades de cada ponto $(x_i, y_i, z_i, r_i, g_i, b_i)$ aos pixels correspondentes para gerar a variável *matriz_de_rotação*. Este fluxo garantiu a extração precisa de patologias, conforme ilustrado na Figura 1 para uma das amostragens do conjunto de dados.




Figura 1: Visão geral do posicionamento multiangular para captação de imagens.

O retorno do resultado das identificações da segmentação das instâncias de patologia, utilizou-se do armazenamento das informações $(x_i, y_i, z_i, r_i, g_i, b_i)$ dos pixels.

Na sequência, retornado à nuvem de pontos o processo de reconstrução geométrica consistiu em filtrar somente os pixels identificados como patologia, realizando a segmentação (Figura 2a). A nuvem de pontos resultante é submetida à uma normalização de vetores unitários (Figura 2b), etapa essencial para orientar os pontos e garantir a precisão topológica da malha. Por fim, o algoritmo *Poisson surface reconstruction* (Figura 2c) baseado na programação proposta em [15] é aplicado para converter os pontos em uma malha contínua, servindo de base para a futura modelagem e integração BIM.




Figura 2: Reconstrução de sólidos via algoritmo de Poisson.

Diante do modelo resultante da nuvem de pontos segmentada, utiliza-se outro algoritmo de programação para realizar a conversão do arquivo para um formato *.obj* (objeto 3D) para que aceite mapeamento do IFC 4x3. Este processo utilizou o *script obj2ifc* da biblioteca *IfcOpenShell*, a automação preservou as coordenadas que já havia nas propriedades do objeto. Para confirmar o resultado, foi inicialmente criado um modelo em Revit da parede utilizada (Figura 3a). Na sequência sobrepomos a nuvem de pontos segmentada sem a conversão de malha (Figura 3b) confirmando que a *matriz_de_rotação* foi preservada. Na sequência, atribuindo o objeto 3D em formato IFC (Figura 3c), e validando que a informação da *matriz_de_rotação* transferida ao IFC 4x3 automaticamente por meio da entidade (*IfcLocalPlacement*) contida nas informações.




Figura 3. Resultado de triangulação das nuvens de pontos.

Para o enriquecimento semântico do modelo, as patologias detectadas foram integradas ao fluxo de dados conforme a hierarquia ilustrada na Figura 4. O mapeamento vincula as informações geométricas e textuais aos elementos estruturais hospedeiros através da entidade *IfcRelVoidsElement*. Nesta estrutura, as proposições de dano são classificadas como *IfcFeatureElement* (tipo *damageProposal*). A geometria detalhada das falhas é descrita pela

entidade subordinada *IfcSurfaceFeature*, que define as alterações de massa e superfície por meio de um *IfcProductDefinitionShape*.




Figura 4. Estrutura do mapeamento IFC para os danos detectados

A consolidação semântica e geométrica ocorre pela agregação ao elemento base via atributo inverso *ContainedInStructure*, vinculando o estado patológico às descrições técnicas. Esta integração utiliza a entidade *IfcSurfaceFeature* (via USERDEFINED no campo *damageName*) para categorizar as patologias no atributo *ObjectType* no atributo *ObjectType* como: *Crack* (fissura), *Efflorescence* (eflorescência), *Ruststain* (corrosão), *Exposed Reinforcement* (armadura exposta) e *Scaling* (desplacamento). Finalmente, a relação de adjacência e impacto entre o dano e o elemento hospedeiro é estabelecida pela entidade *IfcRelVoidsElement*.

Por fim, a adoção da entidade *IfcSurfaceFeature* possibilita o aprimoramento semântico via *Pset_Condition*. Essa abordagem converte o formato EXPRESS para configurar conceitos ausentes no IFC 4x3, mapeando entidades com o prefixo "dot" (como dot:DamageArea) para definir semanticamente áreas afetadas e seus padrões de danos.

A leitura e extração de dados do IFC é ilustrada na Figura 5, onde são realizadas no Blender via *IfcOpenShell*, utilizando a função *ifcopenshell.open* para acessar atributos como *GlobalId*, *ObjectPlacement* e *ObjectType*. O fluxo operacional foca na entidade *IfcBuildingElementProxy*, atualizada para *IfcElementAssemblyType* com o tipo *damageProposal* para representar patologias, conforme ilustrado no processo de processamento de dados. Esta relação de montagem viabiliza a associação geométrica e semântica entre patologias e elementos construtivos via operações booleanas. Como exemplo, a integração de uma fissura *IfcSurfaceFeature* vinculado à parede (*IfcWall*). ocorre pela subtração ou união de geometrias, preservando a integridade do esquema IFC.




Figura 5. Estrutura do mapeamento IFC para os danos detectados

5. Discussão

Os resultados demonstram que as etapas incluídas para automação do processamento de nuvens de pontos, por meio de ortoprojeções e matrizes de transformação homogênea, foram eficazes para preservar o georreferenciamento original e garantir a precisão topológica das malhas geradas via algoritmo de *Poisson* dia *matriz_de_rotação*, o que é ilustrado na sobreposição dos exemplos da Figura 3. Portanto, a linguagem EXPRESS do IFC 4x3 é bem recebida em objetos *.obj*, ao que é validado um fluxo para transformação direta de uma nuvem de pontos em IFC, abrindo precedentes para novas tecnologias não só de segmentação de instancias de patologia mas diversas outras informações de ativos que se queira gerenciar.

A estruturação semântica (Figura 4) no padrão IFC 4.3, utilizando a hierarquia entre *IfcFeatureElement* e *IfcSurfaceFeature*, consolidou um fluxo de dados interoperável onde patologias como fissuras e corrosão são categorizadas com precisão no atributo *ObjectType*. Essa abordagem booleana entre o dano e o elemento hospedeiro (como o *IfcWall*) assegura a integridade geométrica.

No entanto, a dificuldade em identificar propriedades implícitas e as relações subjetivas entre a manifestação visual e a análise estrutural profunda permanecem como desafios estruturais para a interpretação totalmente automatizada, o que é destacado em [14][15] apresentando resultados em locais de baixa luminosidade ou falta de precisão no equipamento para detecção em locais de alta umidade, por exemplo. Outros processos podem trazer subjetividade até para treinamento de IA quando se trata de dados estruturados [2]. O mapeamento do IFC vem de uma automação por IA, o que fica submetido à como foi realizado o treinamento da IA, se foi aplicada em diferentes tipos de estruturas (pontes, túneis, viadutos, edificações), ou em condições ambientais variáveis, pois, ainda se identifica o risco do fator humano na subjetividade destas análises [1]. Dessa forma o mapeamento é validado pelo fluxo, mas a IA anexada precisa ser criteriosamente avaliada.

O fluxo de trabalho também apresenta limitações quanto ao mapeamento dos dados IFC 4x3. Em se tratando de dados específicos e maiores informações para utilização em manutenção, a estrutura EXPRESS ainda carece de melhor detalhamento de informações em patologias. Este problema também é apresentado em [11] e [12] ao que se propõe enriquecimento semântico dos dados através de outros esquemas de subclasses.

Dessa forma [12] propõe a extensão do esquema por meio da integração com ontologias como *ifcOWL* e DOT (Ontologia de Topologia de Danos). Essa abordagem permitiria configurar conceitos ausentes no IFC e definir semanticamente as áreas afetadas, garantindo que as informações de manutenção permaneçam acessíveis e atualizáveis durante todo o ciclo de vida do ativo, em conformidade com normas de manutenção estrutural.

6. Conclusão

A integração entre modelos de visão computacional e o padrão IFC 4.3 consolidou um fluxo automatizado para a gestão de infraestrutura, cumprindo a meta de mapear danos estruturais e manifestações patológicas de forma automatizada no BIM.

Este estudo validou a preservação da precisão topográfica advinda de escaneamento de nuvem de pontos sem perder o georreferenciamento via matrizes de transformação, permitindo que a informação fosse compartilhada até o resultado do modelo BIM 4x3, e portanto, gerando modelos fiéis ao estado atual dos ativos.

Após todo o preparo dos dados advindos de um modelo de IA e incorporá-los à conversão sistemática de malhas para o padrão IFC 4.3, o padrão estrutural de informações do formato assegurou o registro preciso de áreas degradadas sem perda de informação. Dessa forma, validou-se um fluxo completo e automatizado de dados adquiridos por IA e *laser scanner* até um modelo digital de ativos, tendo completado o enriquecimento semântico de toda a informação capturada, tanto geométrica quanto documental. Praticamente, esta aplicação garante a interoperabilidade e a persistência de dados rastreáveis em um banco de dados dinâmico voltado à manutenção preditiva. No entanto, o fluxo ainda não assegura a completa substituição da inspeção manual pela automatizada. Em se tratando de dados adquiridos pela IA, é necessária uma análise criteriosa de qual modelo será integrado ao processo, por considerar inferências de classificações importantes para manutenção dos ativos sem contar com maiores análises de campo. Ou seja, o fluxo de trabalho assegura o compartilhamento da informação sem perda documental, até a representação digital em BIM mas não mitiga o risco de subjetividade na análise dos danos.

Esta pesquisa fundamenta a qualificação de modelos de infraestrutura, viabilizando a integração de IAs granulares a Gêmeos Digitais. No âmbito da gestão de ativos, o método permite gerar inventários de alta fidelidade para otimização de investimentos e políticas de conservação embasadas em dados auditáveis.

Financiamento

O presente estudo foi realizado com o apoio do Programa de Apoio à Pós-Graduação (PROAP) da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior do Brasil (CAPES).

Referências

- [1] S. Lee *et al.*, “Deep Learning-Based PC Member Crack Detection and Quality Inspection Support Technology for the Precise Construction of OSC Projects”, *Applied Sciences*, v. 12, n. 19, p. 9810, set. 2022, doi: 10.3390/app12199810.

- [2] A. N. Beskopylny *et al.*, “Concrete Strength Prediction Using Machine Learning Methods CatBoost, k-Nearest Neighbors, Support Vector Regression”, *Applied Sciences*, v. 12, n. 21, p. 10864, out. 2022, doi: 10.3390/app122110864.
- [3] D. A. Moura e L. G. Araújo, “Reality Capture and BIM for Bridges: A Bibliometric Analysis of Scientific Production in Civil Infrastructure”, em *Anais do 8º Congresso Internacional A Era BIM*, 8ª., São Paulo: SINAENCO, 2025, p. 783–794. [Online]. Disponível em: <https://erabim.com/wp-content/uploads/2025/11/ANAIS-8-CONGRESSO-INTERNACIONAL-A-ERA-BIM.pdf>
- [4] P. Santos *et al.*, “Avaliando o potencial da integração da Inteligência Artificial ao Building Information Modelling (BIM) na Indústria 4.0”, em *5º Congresso Português de Building Information Modelling Volume 1: ptBIM*, 1º ed., UMinho Editora, 2024. doi: 10.21814/uminho.ed.142.22.
- [5] T. Bloch e R. Sacks, “Comparing machine learning and rule-based inferencing for semantic enrichment of BIM models”, *Automation in Construction*, v. 91, p. 256–272, jul. 2018, doi: 10.1016/j.autcon.2018.03.018.
- [6] D. Isailović *et al.*, “Bridge damage: Detection, IFC-based semantic enrichment and visualization”, *Automation in Construction*, v. 112, p. 103088, abr. 2020, doi: 10.1016/j.autcon.2020.103088.
- [7] A. Q. Syed, J. A. A. Jothi, e K. Anusree, “Crack identification from concrete structure images using deep transfer learning”, em *2nd International Conference on Artificial Intelligence and Signal Processing (AISP)*, Vijayawada, India: IEEE, fev. 2022, p. 1–7. doi: 10.1109/AISP53593.2022.9760670.
- [8] B. Wang *et al.*, “Object verification based on deep learning point feature comparison for scan-to-BIM”, *Automation in Construction*, v. 142, p. 104515, out. 2022, doi: 10.1016/j.autcon.2022.104515.
- [9] ISO, *19650-1:2018 - Organization and digitization of information about buildings and civil engineering works, including building information modelling (BIM) — Information management using building information modelling*, Standard 19650–1:2018, 2018.
- [10] B. Sofiato *et al.*, “Towards an order-aware object comparison”, em *Proceedings of the 24th Brazilian Symposium on Context-Oriented Programming and Advanced Modularity*, Natal Brazil: ACM, out. 2020, p. 64–71. doi: 10.1145/3427081.3427090.
- [11] P. Pauwels e W. Terkaj, “EXPRESS to OWL for construction industry: Towards a recommendable and usable ifcOWL ontology”, *Automation in Construction*, v. 63, p. 100–133, mar. 2016, doi: 10.1016/j.autcon.2015.12.003.
- [12] M. Belsky, R. Sacks, e I. Brilakis, “Semantic Enrichment for Building Information Modeling”, *Computer aided Civil Eng.*, v. 31, n. 4, p. 261–274, abr. 2016, doi: 10.1111/mice.12128.
- [13] R. Sacks, M. Girolami, e I. Brilakis, “Building Information Modelling, Artificial Intelligence and Construction Tech”, *Developments in the Built Environment*, v. 4, p. 100011, nov. 2020, doi: 10.1016/j.dibe.2020.100011.
- [14] P. A. S. Santos e M. T. M. Carvalho, “Multi-class segmentation of structural damage and pathological manifestations using YOLOv8 and Segment Anything Model”, *Automation in Construction*, v. 172, p. 106037, abr. 2025, doi: 10.1016/j.autcon.2025.106037.
- [15] F. Poux *et al.*, “Automatic region-growing system for the segmentation of large point clouds”, *Automation in Construction*, v. 138, p. 104250, jun. 2022, doi: 10.1016/j.autcon.2022.104250.