

INSPEÇÃO AUTOMATIZADA DE PONTES FERROVIÁRIAS COM MODELO BIM E TECNOLOGIAS EMERGENTES

Rafael Cabral ^(1,2), Ricardo Santos ^(1,2) e Diogo Ribeiro ^(1,2)

(1) iBuilt, ISEP, Politécnico do Porto, Porto, Portugal

(2) CONSTRUCT, Faculdade de Engenharia, Universidade do Porto, Porto, Portugal

Resumo

A inspeção manual continua a ser uma tarefa subjetiva e pouco integrada aos fluxos de trabalho digitais. Embora a visão computacional permita a deteção automatizada de danos, a maioria das abordagens falha na tradução dessas observações para a Modelação de Informação da Construção (BIM). No caso das pontes, esta limitação persiste no âmbito da Modelação de Informação de Pontes (BrIM), em que a geometria, a semântica e a informação do ciclo de vida devem estar rigorosamente alinhadas. Este artigo aborda esta lacuna por meio de uma metodologia agregadora de quatro métodos: modelação otimizada da realidade, perceção híbrida de danos, Scan-to-BIM automatizado e enriquecimento semântico por meio de objetos IFC. Validado em uma ponte ferroviária em operação em Portugal, o método atinge um mAP50 de deteção de danos de 62,1% e desvios de modelação inferiores a 9 mm face à nuvem de pontos de referência, permitindo a geração de modelos BrIM diretamente a partir de dados multissensoriais de captura da realidade.

1. Introdução

As pontes ferroviárias constituem ativos críticos de infraestrutura, cuja segurança e funcionalidade dependem de avaliações regulares de condição. Este requisito torna-se cada vez mais premente à medida que a rede ferroviária europeia envelhece; atualmente, mais de 35% das pontes ferroviárias na União Europeia têm mais de 100 anos, com muitas a aproximarem-se do fim da sua vida útil de projeto [1]. A prática atual de inspeção depende predominantemente de levantamentos visuais manuais, que são inerentemente subjetivos, difíceis de reproduzir e limitados por restrições de acesso, segurança e tempo operacional. Estudos de larga escala demonstraram uma variabilidade substancial entre inspetores nas classificações de condição, afetando diretamente a fiabilidade dos sistemas de gestão de pontes (BMS) e o planeamento da manutenção a longo prazo [2].

Para contornar estas limitações, o progresso recente nas tecnologias emergentes de captura da realidade, especificamente veículos aéreos não tripulados (UAVs), varrimento laser terrestre (TLS) e varrimento laser móvel (MLS), permitiu a aquisição rápida de dados geométricos e visuais de alta resolução [3, 4]. Paralelamente, as técnicas de aprendizagem profunda alcançaram um desempenho notável na deteção e segmentação de danos estruturais em imagens

[5]. No entanto, subsiste uma notória lacuna de interoperabilidade computacional entre a fase de deteção e a digitalização semântica.

Revisões recentes sobre a implementação de Gémeos Digitais [6, 7] indicam que, embora os dados visuais sejam abundantes, raramente são utilizados para atualizar os modelos de engenharia que servem de base para a análise estrutural. A maioria dos fluxos de trabalho de inspeção termina ao nível de imagens 2D ou nuvens de pontos não estruturadas, falhando na tradução dos resultados da perceção para representações estruturadas, paramétricas e computáveis de Modelação de Informação da Construção (BIM) [8, 9]. No domínio das pontes, este paradigma é designado como Modelação de Informação de Pontes (BrIM), estendendo os princípios do BIM aos ativos de infraestrutura. Esta lacuna limita a adoção do BrIM para Operação e Manutenção (O&M) automatizadas, uma vez que as atuais abordagens Scan-to-BIM têm dificuldade em generalizar o processo através de tipologias complexas sem uma intervenção manual substancial [10].

Em contraste com trabalhos anteriores que se focam em tarefas isoladas, este trabalho apresenta uma metodologia agregadora para gerar modelos BIM com representação de danos diretamente a partir de dados multimodais de captura de realidade. A estrutura metodológica é validada por meio de um estudo de caso numa ponte ferroviária de betão armado localizada em Portugal.

2. Metodologia

A metodologia agregadora proposta estabelece uma linha de processamento computacional que liga os dados brutos dos sensores a modelos semânticos BrIM. Conforme ilustrado na Figura 1, a arquitetura é composta por quatro métodos sequenciais: i) Modelação otimizada da Realidade; ii) Perceção Híbrida de Danos; iii) Scan-to-BIM Automatizado; e iv) Enriquecimento Semântico BIM por meio de *ray-casting* e instanciação paramétrica de objetos.

2.1 Modelação Otimizada da Realidade

O primeiro método visa gerar modelos 3D da realidade de alta precisão adequados à inferência geométrica. Os ambientes das pontes ferroviárias caracterizam-se por fundos complexos (e.g., vegetação, sistemas de catenária e terreno irregular), que introduzem ruído significativo tanto nos conjuntos de dados fotogramétricos como nos dados LiDAR [11].

Para mitigar estes artefactos, adotou-se uma estratégia de fusão multimodal que integra uma filtragem baseada na remoção do fundo antes da reconstrução [12]. Para os dados fotogramétricos, uma rede de segmentação semântica processa cada imagem em bruto, gerando uma máscara binária onde os píxeis estruturais são preservados e os píxeis de fundo são suprimidos. Isto garante que a subsequente rotina de *Structure-from-Motion* (SfM) reconstrua apenas a geometria estrutural relevante. Simultaneamente, as nuvens de pontos LiDAR adquiridas via TLS ou MLS passam por uma filtragem heurística baseada na proximidade geométrica entre múltiplas fontes (distância Nuvem-a-Nuvem).

Após a fusão de dados, uma estratégia de Filtragem por Grelha de *Voxels* (*Voxel Grid Filtering*) resolve as densidades de pontos não uniformes inerentes à captura multissensor. O espaço 3D é discretizado em elementos volumétricos (voxels) V de dimensão δ (e.g., 0,01 m). Para um conjunto de pontos $P = \{p_1, p_2, \dots, p_n\}$ dentro de um voxel V_k , o centroide do ponto retido $p_{centroid}$ é calculado de acordo com a Equação (1).




Figura 1: Visão geral da metodologia agregadora, ilustrando os quatro métodos sequenciais: i) modelagem otimizada da realidade, ii) percepção híbrida de danos, iii) Scan-to-BIM automatizado e iv) enriquecimento semântico.

$$p_{centroid} = \frac{1}{N_k} \sum_{i=1}^{N_k} p_i \quad (1)$$

onde N_k é o número de pontos no voxel V_k . Neste contexto, os *voxels* não são utilizados para modelação volumétrica final, mas atuam exclusivamente como uma grelha espacial temporária

para a subamostragem. Este processo resolve as variações de densidade e reduz a sobrecarga computacional para a fase posterior de inteligência artificial.

2.2 Percepção Híbrida de Danos

O segundo método visa obter uma segmentação robusta dos danos superficiais, ao nível da instância, sob condições operacionais, nomeadamente fissuras, eflorescências e armaduras expostas. Contudo, abordou-se o desafio da variação de escala em imagens de UAV de alta resolução. Os detetores padrões falham frequentemente na identificação de fissuras finas quando as imagens sofrem *downscaling* (redução de resolução). Assim, propõe-se uma pipeline híbrida que integra YOLO11, *Slicing Aided Hyper Inference* (SAHI) e o *Segment Anything Model* (SAM) [13].

A fase de deteção utiliza o SAHI para particionar sistematicamente imagens de alta resolução I_{HR} em parcelas sobrepostas P_k . Cada parcela é normalizada para uma resolução de 640×640 (o tamanho de entrada nativo do detetor YOLO11), garantindo que as características finas são preservadas sem a degradação espacial normalmente causada pelo *downscaling* global da imagem. Um detetor YOLO11, treinado especificamente para patologias ferroviárias, processa cada parcela de forma independente. O conjunto global de deteções D_{global} é reconstruído fundindo as previsões locais e aplicando *Non-Maximum Suppression* (NMS) para eliminar caixas delimitadoras redundantes.

Para efetuar a transição de caixas delimitadoras aproximadas para uma segmentação "*pixel-perfect*", as caixas detetadas servem como *prompts* geométricos para o *Segment Anything Model* (SAM). Ao contrário das redes de segmentação semântica tradicionais, treinadas em classes fixas, o SAM tira partido de uma arquitetura de *Vision Transformer* (ViT) para gerar máscaras *zero-shot* para cada instância solicitada. O objetivo da segmentação é minimizar o erro de fronteira entre a máscara prevista e a anotação real (*ground truth*) [14].

Esta abordagem híbrida garante que danos finos (e.g., fissuras) sejam detetados em sua resolução nativa, enquanto danos de área significativa têm suas fronteiras segmentadas com precisão.

2.3 Scan-to-BrIM Automatizado

O terceiro método automatiza a conversão de nuvens de pontos não estruturadas em elementos paramétricos de *Bridge Information Modelling* (BrIM). A modelação manual é automatizada por meio de uma rede de regressão de pontos-chave (*keypoints*) baseada em *deep learning*, treinada com dados sintéticos.

Dada a escassez de nuvens de pontos de pontes devidamente rotuladas, utiliza-se um motor de geração processual para gerar um conjunto de dados sintéticos. Este motor, baseado em *Revit*® e *Dynamo*®, é utilizado para aleatorizar os parâmetros geométricos e estruturais das pontes. O *Nvidia Omniverse*® é então utilizado para simular a tecnologia de varrimento a laser e para gerar nuvens de pontos rotuladas semanticamente. Esse processo é ilustrado na Figura 2.

A rede de reconstrução, baseada no YOLO-Pose, aceita fatias da nuvem de pontos ao longo do alinhamento da ponte e regride um conjunto de pontos-chave que definem o perfil transversal. A rede é treinada minimizando o Erro Quadrático Médio (MSE) entre os pontos-chave previstos e os dados reais, conforme definido na Equação (2).




Figura 2: Pipeline de geração de nuvem de pontos sintética de pontes: a) modelagem da ponte e aleatorização de parâmetros utilizando Revit© e Dynamo©; b) simulação de escaneamento a laser e geração de nuvem de pontos semântica utilizando NVIDIA Omniverse©.

$$L_{keypoint} = \frac{1}{m} \sum_{j=1}^m \left\| \hat{k}_j - k_{GT,j} \right\|^2 \quad (2)$$

Uma vez inferidos, estes pontos-chave orientam a instância de entidades *Industry Foundation Classes* (IFC). Os elementos estruturais são gerados através de algoritmos de *lofting*, garantindo que o modelo resultante seja totalmente paramétrico e interoperável, nomeadamente através das entidades *IfcColumn*, *IfcBeam*, *IfcSlab* e *IfcWall* [15].

2.4 Enriquecimento Semântico BIM

O último método transforma o modelo geométrico num modelo BrIM "as-damaged" (estado danificado), mapeando os resultados da perceção bidimensional (2D) no ambiente 3D do modelo BIM.

As máscaras de dano provenientes do segundo método são projetadas no espaço 3D por meio de um algoritmo de *ray-casting*. Para um píxel u, v classificado como dano, um raio u, v é lançado a partir do centro da câmara C , atravessando o píxel no plano da imagem, conforme definido na Equação (3).

$$r(t) = C + t \cdot K^{-1} \cdot [u, v, 1]^T \quad (3)$$

onde K a matriz intrínseca da câmara é tida em conta. A interseção do raio $r(t)$ com a malha 3D determina a localização espacial do defeito. Para consolidar as deteções provenientes de múltiplas imagens sobrepostas, aplica-se um algoritmo de *clustering* espacial refinado por *Otsu thresholding* para filtrar as projeções de baixa confiança.

Os aglomerados 3D resultantes são ortorretificados para o cálculo de métricas de engenharia (área, comprimento, largura do dano). Finalmente, os defeitos são instanciados como objetos *IfcBuildingElementProxy* e ligados hierarquicamente ao seu elemento estrutural anfitrião (e.g., *IfcColumn*) por meio da relação *IfcRelContainedInSpatialStructure*.

Este processo estabelece uma ligação direta entre os dados de inspeção visual e o modelo BrIM, permitindo a avaliação automatizada do estado de conservação e o planeamento eficaz da manutenção.

3. Validação e Resultados

3.1 Descrição do Caso de Estudo

A metodologia agregadora proposta foi validada experimentalmente no trecho da ponte ferroviária de betão armado em operação, evidenciada na Figura 3. A ponte está localizada na Linha do Minho, no norte de Portugal.




Figura 3: Vista aérea da Ponte com o trecho de estudo identificado.

A estrutura é constituída por um tabuleiro de via única, com 12,00 m de largura total e uma espessura de 1,50 m. O suporte do tabuleiro é garantido por vigas de travamento embebidas (cujas secções retangulares visíveis apresentam 1,15 m) que se apoiam em pilares cilíndricos de 1,50 m de diâmetro. A ponte transpõe vãos com um máximo de 20,00 m de extensão e possui encontros integrais. A ponte apresenta degradação heterogênea, com fissuras e armaduras expostas.

Esta combinação de complexidade estrutural e variabilidade de danos visíveis fornece um caso de estudo ideal para avaliar a robustez e a fiabilidade da metodologia agregadora de inspeção automatizada proposta. Todas as atividades de aquisição de dados foram conduzidas em conformidade total com os regulamentos aeronáuticos nacionais e os requisitos de segurança ferroviária. Os voos com UAV foram realizados com as devidas autorizações e sob a supervisão e o apoio das autoridades competentes de infraestrutura e ferroviárias.

3.2 Avaliação da Qualidade da Modelação da Realidade

A precisão do modelo de realidade serve como restrição fundamental para todas as tarefas a jusante de perceção e reconstrução. No estudo, a eficácia da estratégia de fusão multimodal proposta, isto é, a combinação da remoção semântica de fundo para a fotogrametria com a filtragem heurística para o LiDAR, foi avaliada com base na completude geométrica.

A inspeção qualitativa da nuvem de pontos fundida confirma que a filtragem a montante suprimiu com sucesso as fontes de ruído de alta frequência típicas dos corredores ferroviários. Este pré-processamento produziu um conjunto de dados focado na estrutura, no qual os elementos primários de suporte de carga (pilares, laje do tabuleiro e vigas) mantiveram a continuidade da superfície. Quantitativamente, a estratégia de filtragem por grelha de *voxels* (*voxel grid filtering*) reduziu significativamente o volume de dados, ao mesmo tempo em que homogeneizou a densidade de pontos.

Esta etapa revelou-se crítica para a fase de Scan-to-BIM: ao remover *outliers* não estruturais, a topologia geométrica efetiva foi preservada, permitindo que a rede de regressão de pontos-chave operasse sobre perfis transversais limpos.

3.3 Desempenho da Perceção de Danos

A identificação de danos (fissuras, eflorescências e armaduras expostas) foi realizada por meio de uma pipeline híbrida que integra YOLO11, SAHI e SAM. O treino seguiu uma estratégia de *transfer learning* sequencial (MS COC → DACL10K → Dataset UAV proprietário de 645 imagens)[13].

O modelo atingiu um mAP50 global de 62,1% no conjunto de validação. A utilização do SAHI foi determinante para detetar fissuras finas sem perda de resolução (IoU de 49,5%), recuperando defeitos frequentemente perdidos no *downsampling* padrão. Para danos de área, o refinamento via SAM superou a segmentação nativa, obtendo IoUs de 33,1% para eflorescências e 20,5% para armaduras expostas. Esta abordagem garantiu a definição de máscaras precisas necessárias na inferência do caso de estudo.

3.4 Precisão Geométrica do Scan-to-BIM

A validação geométrica do *Bridge Information Model* (BrIM) gerado foi avaliada por meio da medição dos desvios euclidianos com sinal entre os elementos IFC gerados e a nuvem de pontos da captura da realidade (referência).

Ao contrário das abordagens convencionais, o desvio geométrico global médio verificado na ponte manteve-se consistentemente inferior a 9 mm. É importante notar que a superfície superior do tabuleiro não foi modelada devido à oclusão provocada pelo balastro e pela superestrutura da via, como tal, esta omissão não reflete no cálculo do desvio. Esta precisão está perfeitamente alinhada com os requisitos para o Nível de Desenvolvimento (LOD) 300 [16], que exige que os elementos sejam representados graficamente como sistemas específicos com quantidades, dimensões, formas, localizações e orientações precisas.

Uma análise de erro ao nível dos componentes revela um desempenho de excelência em todos os elementos estruturais. A laje do tabuleiro registrou os desvios médios mais baixos (próximos de 0,00 mm), enquanto os pilares cilíndricos apresentaram desvios médios de 3,66 mm e as vigas, de 8,28 mm. Deve sublinhar-se que este valor traduz o erro do algoritmo de reconstrução (Scan-to-BIM) e assume a nuvem de pontos fundida como referencial. O desvio absoluto final face à estrutura real incluirá, inerentemente, as tolerâncias e incertezas instrumentais do levantamento.

A Figura 4a demonstra o modelo otimizado de realidade georreferenciado, com as respetivas secções dos elementos estruturais e correspondente efeito *lofting* para a criação do modelo IFC.

3.5 Enriquecimento Semântico e Quantificação de Danos

A fase final de validação centrou-se na capacidade de enriquecimento semântico: a transformação do modelo BrIM de uma simples representação estrutural para um modelo "*as-damaged*" (estado danificado). Os algoritmos de *ray-casting* e de *clustering* (otimizados com um *Otsu threshold* de 0,28) mapearam com sucesso os resultados da perceção 2D nas entidades IFC 3D, estabelecendo uma base de dados espacial coerente de defeitos.

O ambiente BIM enriquecido permitiu a extração automática de métricas agregadas de danos. A Figura 4b ilustra os danos mapeados no modelo BrIM georreferenciado, acompanhados dos

atributos dimensionais correspondentes e das ligações à imagem de referência e à respetiva ortofoto. Para a ponte analisada no caso de estudo, a principal contribuição incide na granularidade ao nível da instância; cada defeito é instanciado como um *IfcBuildingElementProxy* e ligado hierarquicamente ao seu elemento anfitrião (e.g., um pilar específico).

Para além das estatísticas locais, o sistema quantificou um comprimento total de fissuração de 18,65 m, uma área de armadura exposta de 0,017 m² e isenção de eflorescência. Este formato de dados estruturado permite que os gestores de ativos consultem o modelo para obter classificações específicas de condição por elemento, colmatando o fosso entre os dados visuais em bruto e a tomada de decisões de manutenção acionáveis.




Figura 4: O modelo BrIM "as-damaged": a) Geração do modelo IFC por técnica *lofting* através do modelo otimizado de realidade, b) visualização de um defeito específico mapeado (azul claro) juntamente com a janela de propriedades associada.

4. Conclusões

Este estudo apresentou e validou uma metodologia agregadora computacional completa (*end-to-end*) que concilia eficazmente a captura multimodal da realidade com a Modelação Semântica de Informação de Pontes (BrIM). Ao integrar a remoção de fundo baseada em

Inteligência Artificial (IA), um motor de percepção híbrido YOLO11–SAHI–SAM e uma reconstrução Scan-to-BIM treinada com dados sintéticos, a metodologia supera as limitações de escalabilidade inerentes à inspeção manual tradicional.

A validação experimental na ponte da Linha do Minho no norte de Portugal, confirma que a modelação da realidade de alta precisão é um pré-requisito para a inspeção automatizada. A estratégia proposta de filtragem multimodal de envolvente mostrou-se essencial para reduzir o ruído geométrico, permitindo que os algoritmos de reconstrução automatizada convergissem com precisão subcentimétrica (desvios médios < 9 mm).

Além disso, os resultados demonstram que os detetores de objetos padrão são insuficientes diante da complexidade das patologias em infraestruturas. A integração do *Slicing Aided Hyper Inference* (SAHI) e do *Segment Anything Model* (SAM) foi crítica para dissociar a deteção da segmentação, permitindo a quantificação precisa de defeitos finos, tais como fissuras, que tipicamente se perdem (devido à perda de resolução) nos processos normais de *downsampling*. Em última análise, o verdadeiro valor de engenharia desta estrutura reside na fase de enriquecimento semântico, que transforma com sucesso um modelo BrIM estático num modelo BrIM "*as-damaged*" (estado danificado). Ao incorporar os defeitos quantificados como objetos inteligentes *IfcBuildingElementProxy*, o sistema fornece dados estruturados e interoperáveis, diretamente utilizáveis para a manutenção preditiva e a gestão de ativos.

A investigação futura dará prioridade à validação comparativa desta estrutura automatizada em relação aos referenciais tradicionais de inspeção manual para o mesmo ativo. Adicionalmente, a estratégia de treino sintético será expandida para abranger tipologias complexas de alvenaria e de treliças metálicas, melhorando, assim, a capacidade de generalização do modelo. Por fim, os esforços serão direcionados à integração de dados de ensaios não destrutivos (END) subsuperficiais no ambiente BrIM, proporcionando uma visão holística da saúde estrutural que se estende para além dos defeitos localizados à superfície.

Agradecimentos

Este trabalho foi financiado pelo financiamento base – UID/04708 – do CONSTRUCT – Instituto de I&D em Estruturas e Construções – financiado pela Fundação para a Ciência e a Tecnologia, I.P./MCTES através de fundos nacionais, e cofinanciado pelo COMPETE 2030, pelo Portugal 2030, e pela União Europeia, no âmbito do projeto Digi4RailBridges – *DIGItal twin aided condition assessment FOR resilient and sustainable RAILway BRIDGES*, com a referência 16985 e código de operação na Plataforma de Fundos COMPETE2030-FEDER-00827300. Foi adicionalmente suportado pela bolsa de investigação UI/BD/150970/2021 da Fundação para a Ciência e a Tecnologia, FCT/MCTES.

Referências

- [1] A. Tomor, Life-cycle assessment and deterioration models for masonry arch bridges, WIT Transactions on Ecology and the Environment 179 (2013) 535-546, DOI: <https://doi.org/10.2495/SC130451>.
- [2] M. Moore, B.M. Phares, B. Graybeal, D. Rolander, G. Washer, and J. Wiss, Reliability of visual inspection for highway bridges, volume I, Turner-Fairbank Highway Research Center, 2001.
- [3] P. Olaszek, E. Maciejewski, A. Rakoczy, R. Cabral, R. Santos, and D. Ribeiro, Remote Inspection of Bridges with the Integration of Scanning Total Station and Unmanned Aerial

- Vehicle Data, Remote Sensing 16 (22) (2024) 4176, DOI: <https://doi.org/10.3390/rs16224176>.
- [4] A.M. Rakoczy, D. Ribeiro, V. Hoskere, Y. Narazaki, P. Olaszek, W. Karwowski, R. Cabral, Y. Guo, M.M. Futai, and P. Milillo, Technologies and platforms for remote and autonomous bridge inspection–review, *Structural Engineering International* 35 (3) (2025) 354-376.
- [5] D. Ribeiro, A.M. Rakoczy, R. Cabral, V. Hoskere, Y. Narazaki, R. Santos, G. Tondo, L. Gonzalez, J.C. Matos, M. Massao Futai, Y. Guo, A. Trias, J. Tinoco, V. Samec, T.Q. Minh, F. Moreu, C. Popescu, A. Mirzazade, T. Jorge, J. Magalhaes, F. Schmidt, J. Ventura, and J. Fonseca, Methodologies for Remote Bridge Inspection-Review, *Sensors (Basel)* 25 (18) (2025) 5708, DOI: <https://doi.org/10.3390/s25185708>.
- [6] M. Franciosi, M. Kasser, and M. Viviani, Digital twins in bridge engineering for streamlined maintenance and enhanced sustainability, *Automation in Construction* 168 (2024) 105834, DOI: <https://doi.org/10.1016/j.autcon.2024.105834>.
- [7] L. Nichols, A. Ashmawi, and P.H.D. Nguyen, Digitalizing Bridge Inspection Processes Using Building Information Modeling (BIM) and Business Intelligence (BI), *Applied Sciences-Basel* 15 (20) (2025) 10927, DOI: <https://doi.org/10.3390/app152010927>.
- [8] J.H. Lee, J.J. Park, and H. Yoon, Automatic Bridge Design Parameter Extraction for Scan-to-BIM, *Applied Sciences-Basel* 10 (20) (2020) 7346, DOI: <https://doi.org/10.3390/app10207346>.
- [9] X.F. Yang, E.D. Castillo, Y. Zou, L. Wotherspoon, J.X. Yang, and H. Li, Automated Concrete Bridge Damage Detection Using an Efficient Vision Transformer-Enhanced Anchor-Free YOLO, *Engineering* 51 (2025) 311-326, DOI: <https://doi.org/10.1016/j.eng.2025.02.018>.
- [10] J. Patil and M. Kalantari, Automatic Scan-to-BIM-The Impact of Semantic Segmentation Accuracy, *Buildings* 15 (7) (2025) 1126, DOI: <https://doi.org/10.3390/buildings15071126>.
- [11] R. Maskeliūnas, S. Maqsood, M. Vaškevičius, and J. Gelšvartas, Fusing LiDAR and photogrammetry for accurate 3D data: A hybrid approach, *Remote sensing*. 17 (3) (2025) 1-27.
- [12] R. Cabral, R. Santos, J. Correia, and D. Ribeiro, Optimal reconstruction of railway bridges using a machine learning framework based on UAV photogrammetry and LiDAR, *Structure and Infrastructure Engineering* 173 (2025) 1-21, DOI: <https://doi.org/10.1080/15732479.2025.2531562>.
- [13] R. Cabral, R. Santos, J. Correia, and D. Ribeiro, A Hybrid YOLO and Segment Anything Model Pipeline for Multi-Damage Segmentation in UAV Inspection Imagery, *Sensors (Basel)* 25 (21) (2025), DOI: <https://doi.org/10.3390/s25216568>.
- [14] P.A.S. Santos and M.T.M. Carvalho, Multi-class segmentation of structural damage and pathological manifestations using YOLOv8 and Segment Anything Model, *Automation in Construction* 172 (2025) 106037.
- [15] A. Amroune, J.C. Cuillière, and V. François, Automated Lofting-Based Reconstruction of CAD Models from 3D Topology Optimization Results, *Computer-Aided Design* 145 (2022) 103183, DOI: <https://doi.org/10.1016/j.cad.2021.103183>.
- [16] BIMForum. Level of development (LOD) specification. 2024 [cited [2025 January 2]; Available from: <https://bimforum.org/resource/lod-level-of-development-lod-specification/>.