

OTIMIZAÇÃO DO ALINHAMENTO BIM-SCAN PARA AVALIAÇÃO DE PROGRESSO DA CONSTRUÇÃO

Daniel Pereira ⁽¹⁾, Pedro Ferreira ⁽²⁾, Mário Sousa ⁽¹⁾, João N.D. Fernandes ⁽³⁾, Luís Sanhudo ⁽⁴⁾

(1) Built COLAB, Porto

(2) Built COLAB, Porto, 0000-0003-4187-5033

(3) Built COLAB, Porto, 0000-0003-0590-4861

(4) Built COLAB, Porto, 0000-0002-2578-6981

Resumo

A monitorização automática do progresso da construção enfrenta desafios de alinhamento entre os dados *as-is* de obra e a intenção de projeto representada em modelos de *Building Information Modelling* (BIM), bem como limitações computacionais. Muitos métodos recentes recorrem a redes profundas complexas, com elevado custo de processamento e memória, dificultando a inferência em tempo quase real em dispositivos com recursos limitados, como robots, drones e plataformas móveis. Torna-se, assim, necessário desenvolver metodologias capazes de integrar informação geométrica e semântica de forma integrada, mas com requisitos computacionais reduzidos e boa escalabilidade.

Na prática, os dados recolhidos em obra são frequentemente ruidosos, incompletos e afetados por oclusões e montagens parciais, limitando a fiabilidade das abordagens existentes. Este trabalho explora uma metodologia para melhorar a robustez e a interpretabilidade dos processos de alinhamento BIM-*scan* e de estimativa de progresso. A abordagem enfatiza a integração da estrutura semântica com o raciocínio geométrico, reforçando a correspondência entre elementos digitalizados e modelados e permitindo uma quantificação mais consistente do progresso ao longo das fases de construção. Em particular, a estruturação semântica orienta o alinhamento, em vez de tratar segmentação e registo como etapas isoladas.

Adicionalmente, propõe-se uma estratégia computacional leve e eficiente, adequada à monitorização quase em tempo real e alinhada com a digitalização do ambiente construído. Ao privilegiar a otimização metodológica em detrimento da complexidade arquitetónica, pretende-se avançar na automação mantendo a aplicabilidade prática em obra. O resultado esperado é uma base mais fiável, eficiente e escalável para o acompanhamento do progresso da construção, em fluxos de trabalho suportados em BIM.

1. Introdução

A integração de BIM, tecnologias de captura da realidade e Inteligência Artificial (IA) têm impulsionado a automação da construção, particularmente na monitorização automática do

progresso. Esta combinação permite comparar modelos BIM *as-designed* com condições *as-is*, suportando verificação contínua, alinhamento de cronogramas e controlo de qualidade. Tecnologias como *laser scanning* e fotogrametria geram nuvens de pontos 3D densas, funcionando como representações digitais do estaleiro [1]. Apesar da elevada fidelidade espacial, estes conjuntos de dados são frequentemente não estruturados, ruidosos e incompletos, dificultando a comparação direta com a geometria estruturada dos modelos BIM [2].

A maioria das *pipelines* de estimativa de progresso segue estratégias *scan-vs-BIM*, alinhando nuvens de pontos *as-is* diretamente com a geometria BIM [3], enquanto um subconjunto converte o BIM em nuvens sintéticas para registo ponto-a-ponto [4]. O alinhamento recorre frequentemente a algoritmos como *Iterative Closest Point* (ICP) [5] ou *Random Sample Consensus* (RANSAC) [6], mas estas técnicas permanecem sensíveis a oclusões, artefactos e discrepâncias de escala, conduzindo a estimativas pouco fiáveis [7]. Métodos de quantificação baseados em *voxels* também apresentam limitações quando utilizam grelhas de resolução fixa, podendo produzir estimativas enviesadas em estruturas parcialmente construídas [8].

Para superar estas limitações, estudos recentes exploram IA e *deep learning* para segmentação semântica. Arquiteturas modernas [9, 10, 11, 12] permitem classificar elementos estruturais a partir de varrimentos não estruturados, com algumas *pipelines* a combinar filtragem semântica com registo geométrico para melhorar o alinhamento [13]. Contudo, estas tendem a assumir dados de elevada qualidade – condição raramente cumprida em estaleiros ativos, caracterizados por dados incompletos, alterações temporais e desordem estrutural – e implicam custos computacionais elevados.

Neste contexto, este trabalho propõe um *framework* de monitorização da construção baseado em IA que combina segmentação, registo de metadados e voxelização dinâmica num *pipeline* unificado. O sistema melhora a robustez do alinhamento, aumenta a interpretabilidade e fornece estimativas de progresso detalhadas ao nível dos elementos. As principais contribuições incluem: segmentação guiada para reforçar o registo; filtragem de consistência geométrica baseada no BIM para remoção *outliers*; quantificação hierárquica e ponderada do progresso; e validação em *datasets* reais que demonstram escalabilidade e aplicabilidade prática.

2. Estado da arte

A integração de IA e visão 3D nos fluxos de trabalho da construção tem impulsionado a automação de tarefas como alinhamento de modelos, reconhecimento de objetos e monitorização do progresso. A literatura nesta área divide-se em três vertentes principais: registo *scan-vs-BIM*; segmentação semântica de nuvens; e quantificação de progresso baseada em *voxels* – todas fundamentais para a criação de *pipelines* robustos e interpretáveis.

2.1 Registo *scan-vs-BIM*

O registo de varrimentos reais com modelos BIM constitui um passo crítico na comparação *as-is vs as-designed*. Métodos tradicionais, como ICP [5] e RANSAC [6], continuam amplamente utilizados, embora apresentem limitações em ambientes de obra devido a ruído, oclusões e desordem. Abordagens baseadas em descritores locais [14] aumentam a robustez ao explorar características geométricas salientes, enquanto métodos baseados em *deep learning* [15] aprendem representações diretamente a partir das nuvens de pontos, melhorando a correspondência, apesar de enfrentarem desafios de generalização e custos computacionais.

Paralelamente, surgiram *frameworks* conscientes do domínio, como *PMDNet* [16], que combina descritores multi-escala (ponto, linha e malha) com uma função de perda de consistência para reforçar coerência semântica, e *TSGANet* [17], que integra uma estimativa global inicial com afinação fina baseada em *graph neural networks* com atenção, incluindo mecanismos de supressão de correspondências erradas. Apesar da ascensão dos métodos de aprendizagem, estratégias puramente geométricas permanecem relevantes, especialmente em aplicações que exigem eficiência e interpretabilidade, como realidade aumentada móvel [18]. A qualidade de aquisição de dados e o pré-processamento mantêm-se igualmente determinantes para o desempenho global, sendo frequente a utilização de pipelines híbridas que combinam registo geométrico com conhecimento estrutural BIM [19].

2.2 Segmentação semântica de nuvens de pontos

A segmentação semântica permite identificar elementos construtivos em nuvens de pontos, suportando o alinhamento e a estimativa de progresso. Abordagens tradicionais recorrem a primitivas geométricas [6] e *clustering* [20] são sensíveis a ruído, oclusões e densidade de irregular [21].

Arquiteturas modernas, como a *PointNet* [9] e *PointNet++* [10], têm mostrado elevada capacidade de generalização, permitindo capturar hierarquicamente características de nuvens de pontos em grande escala. Mais recentemente, arquiteturas baseadas em transformers, como *Point Transformer* [11] e *SuperPoint Transformer* [12] demonstram forte generalização ao modelar dependências locais e globais, sendo particularmente adequadas para a variabilidade de dados encontrada em estaleiros. O progresso nesta área tem sido apoiado por *benchmarks* como *S3DIS* [22], *Semantic3D* [23] e *ScanNet* [24], que fornecem cenários anotados para avaliar a robustez de algoritmos de segmentação.

Em contextos BIM, a segmentação semântica é crítica para isolar elementos estruturais e facilitar a correspondência com objetos do modelo. Trabalhos recentes têm avançado para segmentação ao nível de instâncias, possibilitando a conversão direta para objetos paramétricos e reduzindo intervenção manual [25]. Apesar destes avanços, desafios persistem em cenários reais, nomeadamente varrimentos incompletos, superfícies reflexivas e condições dinâmicas de obra.

2.3 Estimativa de progresso e quantificação baseada em *voxels*

A estimativa do progresso da construção visa quantificar a conclusão de elementos estruturais comparando dados *as-is* com modelos BIM *as-designed*. Uma abordagem comum é a quantificação baseada em *voxels*, onde tanto o *scan* como o modelo BIM são convertidos em grelhas e a sobreposição dos *voxels* ocupados serve como *proxy* para o progresso [21]. No entanto, grelhas de resolução fixa apresentam limitações na representação de elementos com escalas diferentes e em cenários com visibilidade parcial.

Para ultrapassar estas limitações, estratégias de voxelização adaptativa ajustam a resolução de forma dinâmica segundo a complexidade local e densidade de pontos [26], preservando detalhes geométricos e garantindo processamento eficiente em nuvens de elevada magnitude. Além disso, *frameworks* que combinam voxelização com raciocínio semântico e regras aumentam a robustez da estimativa, inferindo conclusão de componentes mesmo quando os dados apresentam incompletude [27]. Ainda assim, a integração destes conceitos em pipelines modulares e aplicáveis a cenários reais permanece limitada, evidenciando a necessidade de *frameworks* unificados e escaláveis.

3. Metodologia

Esta secção descreve o *pipeline* automático proposto para a monitorização do progresso da construção através da integração *scan-vs-BIM*. A metodologia assenta em quatro componentes principais: arquitetura global do sistema; segmentação semântica da nuvem; registo e filtragem baseada em descritores geométricos; e voxelização dinâmica para estimativa de progresso.

3.1 Arquitetura geral do sistema

O *framework* proposto (Figura 1) integra segmentação semântica, registo geométrico, voxelização dinâmica e heurísticas de estimativa de progresso num fluxo unificado. O processo inicia-se com duas entradas paralelas: uma nuvem de pontos do estaleiro (*as-is*) e um modelo BIM, em formato *Industry Foundation Classes* (IFC) (*as-designed*). A nuvem real é previamente processada, incluindo remoção de *outliers* e estimativa de normais, enquanto o ficheiro IFC é analisado para gerar uma nuvem sintética que serve de referência geométrica.

A segmentação semântica é aplicada à nuvem real, produzindo classes de elementos construtivos. Segue-se o registo geométrico com descritores extraídos pela rede GeDi [15], utilizando RANSAC [6] para alinhamento inicial ICP [5] para refinamento. Para reduzir ruído e correspondências espúrias, aplica-se uma filtragem geométrica baseada no fecho convexo do modelo, seguida de novo refinamento do registo para maior precisão.

A nuvem registada é submetida a um módulo de voxelização dinâmica, no qual a resolução é refinada em regiões estruturalmente complexas e menor em zonas homogêneas, reduzindo custos computacionais. O progresso é estimado ao nível dos *voxels* e agregada hierarquicamente para produzir métricas por elemento e modelo, incluindo heurísticas de consistência vertical que refletem sequências construtivas realistas.




Figura 1: Visão geral da *framework* proposta para a estimativa do progresso de construção

3.2 Processo de segmentação semântica

A segmentação semântica desempenha um papel central na estruturação da nuvem de pontos real em componentes construtivos, como paredes, lajes, colunas e vigas. O módulo é concebido de forma modular e independente da arquitetura de *deep learning* utilizada.

Inicialmente, a nuvem de pontos é carregada com informação geométrica e cromática (quando disponível) e submetida a pré-processamento, incluindo remoção de *outliers*, *downsampling* e estimação de normais. Após transformações de normalização para otimização em GPU, um modelo pré-treinado gera probabilidades de classe por ponto, posteriormente convertidas em rótulos finais. O resultado é uma nuvem semanticamente segmentada, compatível com os módulos de registo e voxelização, capaz de melhorar a correspondência entre nuvem e modelo.

3.3 Geração de descritores, registo e filtragem

O alinhamento entre a nuvem segmentada e a geometria BIM segue três etapas: geração de descritores; registo; e filtragem espacial.

A rede GeDi [15] é utilizada para extrair descritores geométricos robustos entre a nuvem real e a nuvem sintética. O registo é efetuado em duas fases: alinhamento global com RANSAC [6], que estima uma transformação grosseira maximizando a consistência geométrica; seguido de um refinamento local com ICP [5], que melhora o alinhamento minimizando distâncias entre pontos. Após este passo, é aplicada uma filtragem baseada no fecho convexo do modelo BIM, expandido em 10%, removendo pontos fora da região de interesse e reduzindo significativamente ruído e artefactos. Esta filtragem assume que o alinhamento inicial já posiciona corretamente as regiões relevantes – hipótese confirmada experimentalmente.

A Figura 3 apresenta a sobreposição entre a nuvem de pontos real e a nuvem sintética derivada do modelo IFC após o processo de registo. A inspeção visual confirma um alinhamento global consistente, particularmente evidente em superfícies verticais contínuas e elementos estruturais de grande dimensão. Pequenas discrepâncias locais são compatíveis com limitações de scan e imperfeições da construção. Esta validação é relevante, visto a estimativa de progresso depender do alinhamento. Assim, as diferenças discutidas na secção 4 decorrem de efeitos associados à visibilidade parcial e à discretização voxelizada e não de desalinhamentos.

3.4 Voxelização dinâmica e estimativa de progresso

A fase final do *pipeline* combina voxelização e estimativa de progresso. As nuvens são ambas convertidas para uma representação volumétrica, permitindo comparar a ocupação espacial planeado vs construído. Para lidar com regiões ambíguas ou estruturalmente complexas, como interseções entre elementos, é adotada uma estratégia de voxelização dinâmica. Em vez de alterar diretamente a grelha, o método ajusta pesos, limiares de distância e centros de *voxel* no cálculo da sobreposição, reduzindo erros associados a sobreposições parciais e ruído.

A estimativa de progresso é hierárquica. Ao nível do elemento IFC, cada componente recebe uma pontuação baseada no progresso das suas camadas horizontais, agregadas por média ponderada segundo o número de *voxels*. O progresso global resulta da agregação ponderada de todos os elementos. Para lidar com *scans* parciais, o sistema desacopla a percentagem de sobreposição do valor final de progresso, recorrendo a mapeamentos definidos pelo utilizador e específicos por classe IFC. Adicionalmente, uma heurística de correção impõe consistência física: se uma camada atinge 100% de progresso, camadas inferiores são consideradas concluídas, refletindo a natureza *bottom-up* da construção. O resultado é um relatório estruturado com métricas globais e detalhadas por elemento.

4. Aplicação

Esta secção descreve o enquadramento experimental adotado para a avaliação do *framework* proposto, incluindo as métricas utilizadas para quantificar o desempenho do registo e a caracterização dos dados utilizados nos ensaios. O objetivo é assegurar uma análise rigorosa e reproduzível da robustez e precisão do método, recorrendo tanto a métricas geométricas estabelecidas como a dados reais provenientes de um contexto de construção ativo.

4.1 Dados

A avaliação experimental foi conduzida recorrendo a um modelo BIM em formato IFC e a um conjunto alargado de nuvens de pontos obtidas (Figura 2). O modelo IFC foi gerado a partir da exportação direta de um modelo desenvolvido em Autodesk Revit, assegurando a preservação da estrutura semântica e geométrica dos elementos construtivos relevantes para o processo de registo e análise de progresso. Este conjunto de dados reflete condições realistas de obra, incluindo ruído, oclusões, várias superfícies refletivas (e.g., zonas húmidas, envidraçados), múltiplos elementos detalhados (e.g., tubagens, bombas) e variações de densidade, constituindo um cenário exigente para a validação da robustez do *pipeline* proposto.




Figura 2: Nuvem de pontos e modelo utilizados

4.2 Estimativa de progresso com adaptação por camadas

A estimativa de progresso é obtida através da comparação voxelizada entre a nuvem de pontos real (após registo) e a geometria de referência extraída do modelo BIM. A razão de sobreposição é convertida numa percentagem de conclusão ao nível do elemento e posteriormente agregada para obtenção de um indicador global. Dado que os elementos estruturais considerados apresentam um estado real binário (0% ou 100%), valores intermédios resultam exclusivamente de limitações geométricas, tais como oclusões, ruído ou discretização voxelizada.

Para reduzir subestimações sistemáticas associadas a visibilidade parcial, foi introduzido um mecanismo de adaptação por camadas, baseado numa regra de obstrução vertical. Cada elemento é discretizado em camadas cuja dimensão e número dependem da respetiva geometria. Uma camada é classificada como completa quando a sua ocupação voxelizada atinge pelo menos 85%. Quando uma camada superior satisfaz este critério, todas as camadas inferiores são automaticamente marcadas como completas.




Figura 3: Registo entre nuvem real (vermelho) e nuvem sintética do modelo IFC (azul)

A Tabela 1 apresenta um subconjunto representativo dos resultados obtidos antes e após a aplicação da adaptação por camadas. Os exemplos foram selecionados para ilustrar três situações distintas: elementos não iniciados; forte variação após adaptação; e elementos corretamente identificados como concluídos.

Tabela 1: Progressos obtidos para diferentes elementos

ID do elemento	Classe IFC	Progresso sem adaptação (%)	Progressão com adaptação (%)	Diferença ($\Delta\%$)
2TCMmvYdzFrB33qtdwvdan	IfcPlate	0.0	0.0	0.0
3rggkNslL3FBZIH4ugKcfY	IfcColumn	0.0	0.0	0.0
3rggkNslL3FBZIH4ugKcMI	IfcColumn	20.9	96.5	75.6
3rggkNslL3FBZIH4ugKcLk	IfcColumn	18.5	94.3	75.7
2y8BZMQW16N9xUaEZO47	IfcWall	15.2	100.0	84.8
2TCMmvYdzFrB33qtdwvd5d	IfcMember	100.0	100.0	0.0
19PFIE45jAxhSw415\$dBFc	IfcMember	100.0	100.0	0.0

Conforme observado na Tabela 1, alguns elementos apresentam diferenças muito significativas após adaptação (até 84.8 pontos percentuais). Nestes casos, a estimativa puramente geométrica indicava valores reduzidos ($\approx 15\text{--}22\%$), apesar de o elemento se encontrar instalado. A análise sugere que pelo menos uma camada superior se encontrava próxima do limiar de completude (85%), mas ligeiramente abaixo do mesmo, impedindo a ativação da regra de obstrução no cenário não adaptado. Após adaptação, essa camada passa a ser considerada completa, desencadeando o preenchimento automático das camadas inferiores e conduzindo a valores próximos de 100%.

Em contraste, elementos corretamente identificados como totalmente concluídos (100%) ou não iniciados (0%) mantêm-se inalterados após a aplicação da regra, conforme igualmente

evidenciado na Tabela 1. Tal comportamento indica que o mecanismo introduzido não distorce estimativas já consistentes com a evidência geométrica disponível.

Ao nível agregado, o progresso global estimado foi de 22.48% sem adaptação por camadas e 26.21% com adaptação. A diferença absoluta entre as duas estimativas corresponde a 3.73% (MAE = 3.73). Em termos relativos, esta variação corresponde a uma MAPE de 14.23. Embora o impacto global seja moderado quando comparado ao impacto nos elementos (Tabela 1), a adaptação introduz um aumento consistente do valor agregado. Isto indica que as subestimações locais associadas à não adaptação têm um efeito cumulativo na estimativa global.

A Figura 4 apresenta a visualização dos elementos estruturais classificados segundo o progresso estimado após adaptação por camadas. Os elementos representados a verde correspondem a valores iguais ou superiores a 99%, os elementos a vermelho correspondem a valores iguais ou inferiores a 1%, e os elementos a amarelo representam estados intermédios. Esta codificação permite uma leitura imediata da distribuição espacial do progresso no modelo.




Figura 4: Elementos estruturais coloridos de acordo com o progresso estimado com adaptação por camadas: verde ($\geq 99\%$), amarelo (intermédio) e vermelho ($\leq 1\%$).

5. Discussão

Os resultados confirmam que a robustez do método decorre da integração coerente entre segmentação semântica, registo em duas fases com filtragem baseada no envelope BIM e quantificação voxelizada com adaptação por camadas. A contribuição principal não está num único componente, mas na articulação do *pipeline* para lidar com ruído, oclusões e montagens parciais em contexto real.

A adaptação por camadas revelou-se particularmente relevante para mitigar subestimações induzidas por ocupações voxelizadas próximas do limiar de 85%. Correções significativas foram observadas ao nível do elemento (até 84.%), sem alterar casos corretamente

identificados. Ao nível global, o progresso aumentou de 22.48% para 26.21% (MAE = 3.73; MAPE = 14.23%), evidenciando um efeito cumulativo de subestimações locais.

O método mantém-se interpretável, sendo adequado para monitorização periódica baseada em BIM. Contudo, o desempenho depende da qualidade do registo e segmentação, da definição do limiar de ocupação e da suposição de progressão vertical. Não foi realizada análise de sensibilidade a estes parâmetros, o que constitui trabalho futuro, juntamente com a calibração por classe de elemento.

Em síntese, a *pipeline* proposta oferece uma solução robusta e aplicável para estimativa automatizada de progresso em contexto real de construção.

Agradecimentos

Este documento é emitido no âmbito e para os fins do projeto CRIARTE. Este projeto é cofinanciado pelo programa Portugal 2030, ao abrigo da referência COMPETE2030-FEDER01192200. Este trabalho tem o cofinanciamento do PRR – Plano de Recuperação e Resiliência e União Europeia – www.recuperarportugal.gov.pt | PRR – Investimento RE-C05-i02: Missão Interface – CoLAB.

Referências

- [1] P. Tang, D. Huber, B. Akinci, R. Lipman, A. Lytle, Automatic re construction of as-built building information models from laser-scanned point clouds: A review of related techniques, *Automation in construction* (2010).
- [2] C. Dore, M. Murphy, Current state of the art historic building information modelling, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* (2017).
- [3] P. Kavaliauskas, J. B. Fernandez, K. McGuinness, A. Jurelionis, Automation of construction progress monitoring by integrating 3d point cloud data with an ifc-based bim model, *Buildings* (2022).
- [4] Z. Jiang, X. Shen, M. H. Ibrahimkhil, K. Barati, J. Linke, Scan-vs-bim for real-time progress monitoring of bridge construction project, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* (2022).
- [5] S. Huang, Z. Gojcic, M. Usvyatsov, A. Wieser, K. Schindler, Predator: Registration of 3d point clouds with low overlap, *IEEE/CVF Conference on Computer Vision and Pattern Recognition* (2021).
- [6] M. A. Fischler, R. C. Bolles, Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography, *Communications of the ACM* (1981).
- [7] F. Pomerleau, F. Colas, R. Siegwart, et al., A review of point cloud registration algorithms for mobile robotics, *Foundations and Trends in Robotics* (2015).
- [8] F. Bosché, Automated recognition of 3d cad model objects in laser scans and calculation of as-built dimensions for dimensional compliance control in construction, *Advanced engineering informatics* (2010).
- [9] C. R. Qi, H. Su, K. Mo, L. J. Guibas, Pointnet: Deep learning on point sets for 3d classification and segmentation, *IEEE/CVF Conference on Computer Vision and Pattern Recognition* (2017).

- [10] C. R. Qi, L. Yi, H. Su, L. J. Guibas, Pointnet++: Deep hierarchical feature learning on point sets in a metric space, *Advances in neural information processing systems* (2017).
- [11] X. Wu, L. Jiang, P.-S. Wang, Z. Liu, X. Liu, Y. Qiao, W. Ouyang, T. He, H. Zhao, Point transformer v3: Simpler faster stronger, *IEEE/CVF Conference on Computer Vision and Pattern Recognition* (2024).
- [12] D. Robert, H. Raguét, L. Landrieu, Efficient 3d semantic segmentation with superpoint transformer, *IEEE/CVF International Conference on Computer Vision* (2023).
- [13] M. Mahmoud, L. Yaxin, M. Adham, C. Wu, Automated material-aware bim generation using deep learning for comprehensive indoor element reconstruction, *Automation in Construction* (2025).
- [14] I. Sipiran, B. Bustos, Harris 3d: a robust extension of the harris operator for interest point detection on 3d meshes, *The Visual Computer* (2011).
- [15] F. Poiesi, D. Boscaini, Learning general and distinctive 3d local deep descriptors for point cloud registration, *IEEE Transactions on Pattern Analysis and Machine Intelligence* (2022).
- [16] H. Jiang, Y. Liu, G. Nader, Z. Wu, T. Tanasnitikul, P. Lasang, Feature consistent point cloud registration in building information modeling, *6th International Conference on Machine Vision and Applications* (2023).
- [17] X. Zhang, J. Li, W. Zhang, Y. Xu, F. Li, Two-stage point cloud registration framework based on graph neural network and attention, *Electronics* (2024).
- [18] B. Mahmood, S. Han, D.-E. Lee, Bim-based registration and localization of 3d point clouds of indoor scenes using geometric features for augmented reality, *Remote Sensing* (2020).
- [19] L. Sanhudo, N. M. Ramos, J. P. Martins, R. M. Almeida, E. Barreira, M. L. Simões, V. Cardoso, A framework for in-situ geometric data acquisition using laser scanning for bim modelling, *Journal of Building Engineering* (2020).
- [20] M. Ester, H.-P. Kriegel, J. Sander, X. Xu, et al., A density-based algorithm for discovering clusters in large spatial databases with noise, *kdd* (1996).
- [21] F. Bosché, A. Guillemet, Y. Turkan, C. T. Haas, R. Haas, Tracking the built status of mep works: Assessing the value of a scan-vs-bim system, *Journal of Computing in Civil Engineering* (2014).
- [22] I. Armeni, O. Sener, A. R. Zamir, H. Jiang, I. Brilakis, M. Fischer, S. Savarese, 3d semantic parsing of large-scale indoor spaces, *IEEE/CVF Conference on Computer Vision and Pattern Recognition* (2016).
- [23] T. Hackel, N. Savinov, L. Ladicky, J. D. Wegner, K. Schindler, M. Pollefeys, Semantic3d. net: A new large-scale point cloud classification benchmark, *arXiv preprint* (2017).
- [24] A. Dai, A. X. Chang, M. Savva, M. Halber, T. Funkhouser, M. Nießner, Scannet: Richly-annotated 3d reconstructions of indoor scenes, *IEEE/CVF Conference on Computer Vision and Pattern Recognition* (2017).
- [25] D. Campagnolo, E. Camuffo, U. Michieli, P. Borin, S. Milani, A. Giordano, Fully automated scan-to-bim via point cloud instance segmentation, *IEEE International Conference on Image Processing* (2023).
- [26] H. Yang, D. Liang, D. Zhang, Z. Liu, Z. Zou, X. Jiang, Y. Zhu, Avs-net: Point sampling with adaptive voxel size for 3d scene understanding, *Neurocomputing* (2025).
- [27] A. Braun, S. Tuttas, A. Borrmann, U. Stilla, A concept for automated construction progress monitoring using bim-based geometric constraints and photogrammetric point clouds, *Journal of Information Technology in Construction* (2015).