

Proposta de algoritmos de inteligência artificial para automatização do processo Scan-to-BIM

<https://doi.org/10.21814/uminho.ed.77.36>

Luís Sanhudo¹, João Poças Martins², Nuno M. M. Ramos³

¹ *BUILT CoLAB – Collaborative Laboratory for the Future Built Environment, Portugal*

² *CONSTRUCT – Gequaltec, Faculdade de Engenharia da Universidade do Porto, Porto*

³ *CONSTRUCT – LFC, Faculdade de Engenharia da Universidade do Porto, Porto*

Resumo

Nos últimos anos, a reabilitação energética do edificado existente tem vindo a ocupar uma posição central na indústria da Construção, com várias diretivas europeias e nacionais a focarem o tópico em busca de sustentabilidade e objetivos económicos. De forma semelhante, a importância do *Building Information Modelling* (BIM) tem vindo a crescer nas comunidades científicas e práticas do setor, evoluindo rapidamente de um conceito puramente futurista para uma das peças centrais da indústria. Com a crescente sobreposição entre as duas áreas, estudos recentes propõem a automatização do processo Scan-to-BIM com o objetivo de viabilizar uma aplicação alargada deste tipo de reabilitação. Contudo, uma solução que permita suportar a automatização deste processo encontra-se ainda em falta na literatura.

O presente artigo visa contribuir com esta solução, propondo a aplicação de algoritmos de Inteligência Artificial para a segmentação, classificação e modelação semântica de nuvens de pontos de um edifício. Subsequentemente, o modelo BIM obtido é automaticamente enriquecido com informação relevante para a realização de análises energéticas em *software* especializado. A solução proposta é aplicada a um caso de estudo, com o objetivo de avaliar o seu desempenho e identificar as suas atuais vantagens e limitações. Os resultados obtidos indicam precisões superiores a 87.64% na segmentação, classificação e modelação de 13 classes de elementos, nomeadamente: paredes; chão; teto; pilares; vigas; janelas; portas; cadeiras; sofás; estantes; e quadros.

1. Introdução

Atualmente, dois dos principais objetivos a nível europeu para a indústria da Arquitetura, Engenharia e Construção (AEC), são o aumento da eficiência energética e a redução do consumo energético [1]. Assim, sendo os edifícios responsáveis por aproximadamente 40% do consumo energético europeu, o sucesso destas estratégias está estritamente ligado à reabilitação do edificado existente [1]. Contudo, atualmente, apenas uma pequena percentagem do edificado é renovada anualmente [2], devido a múltiplos desafios associados a este tipo de projetos, nomeadamente, a difícil identificação de medidas de reabilitação energética eficientes [3].

Neste sentido, nos últimos anos, o *Building Information Modelling* (BIM) tem sido frequentemente associado a esta pesquisa, sendo apontado como parte integrante da solução [3, 4]. Nesta solução, o BIM funciona como uma base de dados centralizada, que tem como objetivo armazenar toda a informação do edifício, enviando, posteriormente, estes dados para *software* de análise energética, onde o modelo pode ser cuidadosamente analisado para identificação de medidas de reabilitação.

Contudo, para que esta metodologia funcione, é necessário existir um modelo BIM do edifício a reabilitar. Para isso, a tecnologia *laser scanning* e, mais proeminentemente, o processo Scan-to-BIM, têm vindo a crescer em popularidade e aplicação dentro das comunidades científicas e práticas do setor, tirando partido da crescente precisão e custos reduzidos associados a esta tecnologia, para ajudar no desenvolvimento de modelos BIM *as-is* [4]. No entanto, este processo apresenta também as suas limitações, com o tratamento, importação e modelação das nuvens de pontos a permanecerem processos altamente manuais, demorados, subjetivos e propensos a erros, reduzindo significativamente a sua viabilidade [5].

Neste sentido, vários estudos [4, 5] identificam a crescente necessidade de desenvolver um método para adquirir automaticamente e com precisão modelos semanticamente enriquecidos, automatizando o processo Scan-to-BIM. Este método evita por completo a importação de nuvem de pontos no *software* de modelação, extraindo as dimensões dos elementos de construção diretamente da nuvem de pontos e utilizando essa informação para realizar a sua modelação automática.

Uma vez que uma solução que permita a completa automatização deste processo está ainda ausente da literatura, o presente artigo apresenta uma metodologia baseada em aprendizagem computacional para automatização da segmentação e classificação da nuvem de pontos em elementos construtivos, seguida da sua modelação em *software* BIM.

2. Estado da Arte

O processo de utilização de nuvens de pontos como referência para modelação BIM é denominado de scan-to-BIM [6, 7]. Este processo visa aliviar o esforço de

desenvolvimento de modelos *BIM as-is*, simultaneamente que melhora a sua precisão e detalhe. Para uma análise detalhada do processo, ver [7].

Apesar de simplificar e aumentar a velocidade de criação de modelos BIM, o processo Scan-to-BIM também apresenta as suas limitações [4, 8]. Nomeadamente, embora o processo de levantamento e subsequente tratamento de nuvens de pontos seja mais rápido comparativamente a métodos tradicionais, este é ainda demasiado complexo e moroso; além disso, apesar de o processo de modelação ser, novamente, mais rápido e preciso que métodos tradicionais, a modelação ainda é expressivamente lenta, requerendo profissionais que interpretem as nuvens de pontos e as modelem manualmente em ambiente BIM [8].

Neste sentido, estudos recentes da indústria AEC têm focado a automatização deste processo através de métodos de aprendizagem computacional tradicional, dividindo a sua automatização em duas etapas: [5]: segmentação da nuvem de pontos em elementos construtivos; e modelação dos elementos segmentados em ambiente BIM. Tendo examinado a literatura associada a estas etapas, é possível identificar a ausência de estudos que: (1) foquem e solucionem ambas as etapas; (2) exibam um amplo leque de aplicações; e (3) tenham um elevado nível de precisão e desempenho computacional. De facto, as soluções propostas tendem a ser demasiado restritas, focando a modelação da geometria de um único elemento construtivo (e.g., paredes [9, 10], tubos [11, 12]), frequentemente sem o seu enriquecimento semântico ou topológico (i.e., modelação CAD 3D em oposição a BIM). Adicionalmente, uma vez que as soluções propostas baseiam-se em algoritmos de aprendizagem computacional tradicional, estas tendem a apoiar-se em *hard-coded knowledge* [9, 10, 11] e bibliotecas de objetos [5, 11, 12], restringindo significativamente o seu leque de aplicação e o seu nível de desempenho e precisão [13].

Isto indica que a pesquisa sobre automatização do processo Scan-to-BIM está desassociada do atual estado da arte de segmentação e classificação de nuvens de pontos em áreas como Ciências da Computação e Eletrotécnica que, em 2015, transitaram para abordagens suportadas por *deep learning*, pelas suas comprovadas vantagens. Como indicado em [13]: métodos atuais de *deep learning* para segmentação e classificação de nuvem de pontos superam expressivamente os métodos tradicionais de aprendizagem computacional, permitindo uma utilização mais eficiente de grandes volumes de dados; prescindindo da aquisição de *handcrafted features*; e gerando melhores níveis de desempenho e precisão em *datasets* públicos.

Face a estas conclusões, a secção seguinte apresenta uma metodologia suportada por tecnologia *deep learning*, capaz de responder aos problemas levantados.

3. Metodologia para Automatização do Processo Scan-to-BIM

A Figura 1 apresenta a metodologia desenvolvida para automatização do processo Scan-to-BIM. Como visível nesta figura, ao contrário das duas etapas para

automatização indicadas na literatura, a presente metodologia divide o processo em seis tarefas: (1) tratamento da nuvem de pontos; (2) segmentação da nuvem de pontos tratada; (3) classificação dos segmentos obtidos em elementos construtivos; (4) caracterização dos elementos construtivos identificados; (5) modelação geométrica; (6) e enriquecimento do modelo com informação não-geométrica.

Na primeira tarefa, é utilizado um processo de *voxel downsampling* [14] para dizimação das nuvens de pontos, seguido da limpeza do ruído existente por remoção de *outliers* estatísticos [14]; posteriormente, é utilizado um processo baseado em *Fast Point Feature Histograms* [15] e *Random Sample Consensus* (RANSAC) [16] para registo das nuvens de pontos, seguido do aperfeiçoamento do registo obtido com recurso ao algoritmo *Point-to-Plane Iterative Closest Point* [17]. Por fim, durante a unificação, é utilizado novamente um processo de *voxel downsampling* para eliminar pontos sobrepostos nas nuvens registadas.

A segunda e terceira tarefa foram solucionadas em simultâneo com recurso a três processos distintos: segmentação semântica; segmentação de instâncias e segmentação de partes. A Figura 2 demonstra o intuito de cada uma destas segmentações. A primeira e última segmentação é realizada com o auxílio de uma inovadora rede neuronal convolucional [18], baseada em duas vertentes distintas da literatura [18]: *point-based* e *voxel-based*. Estas foram utilizadas em simultâneo para que cada vertente eliminasse as desvantagens da outra. A segunda segmentação é baseada no algoritmo de *clustering* DBSCAN (*Density-based Spatial Clustering of Applications with Noise*) [19], que segmenta a nuvem de pontos conforme a sua densidade.

Focando a quarta tarefa, a caracterização dos elementos construtivos obtidos foi realizada sobre duas vertentes: caracterização geométrica e caracterização não-geométrica. A primeira utiliza os algoritmos RANSAC e *object-oriented minimum bounding box* para aquisição de múltiplas características de cada elemento, como: altura; comprimento; largura; centro; orientação; planos principais; entre outros. A segunda foca a agregação de informação para enriquecimento da geometria após modelação, nomeadamente: classe semântica e de instância; partes constituintes; e até mesmo a rugosidade, refletividade e cor da superfície do elemento, que podem ser usadas na identificação dos seus materiais visíveis [20].

Por fim, a quinta e sexta tarefas foram desenvolvidas para o *software* de modelação *Autodesk Revit*, com recurso ao *Dynamo*. Neste sentido, foram utilizadas as funcionalidades disponibilizadas na *Application Programming Interface* (API) do *Revit*, ao qual o *Dynamo* tem fácil acesso, para modelação da geometria e subsequente enriquecimento, através da informação recolhida durante a caracterização geométrica e não geométrica dos elementos construtivos. Atualmente, já se encontram automatizados os processos de modelação de 13 tipologias de elementos, sendo utilizadas durante a modelação as famílias visíveis na Figura 3. Após finalização da modelação automática, as famílias apresentadas podem ser substituídas por famílias próprias do utilizador.

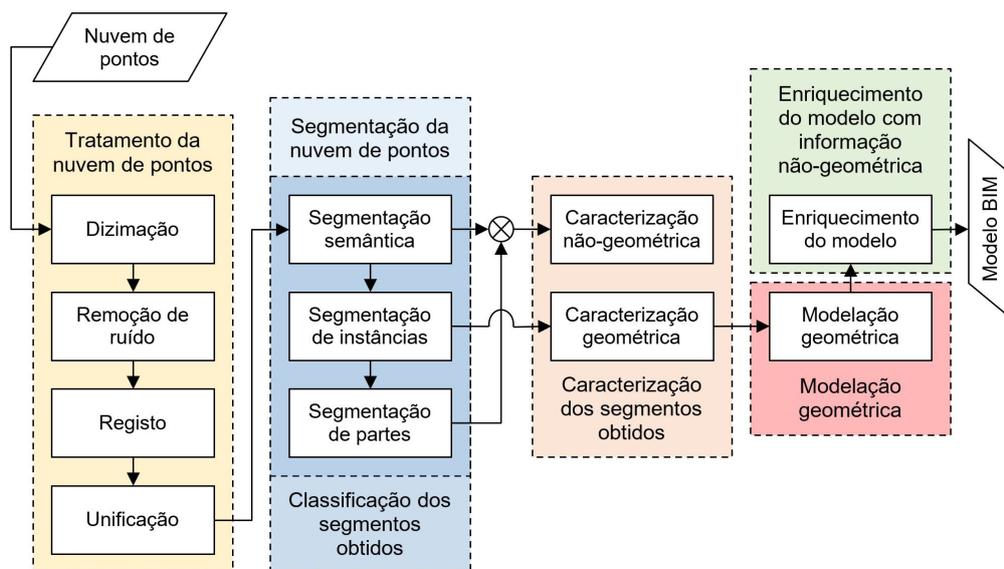


Figura 1
Metodologia para auto-
matização do processo
Scan-to-BIM.

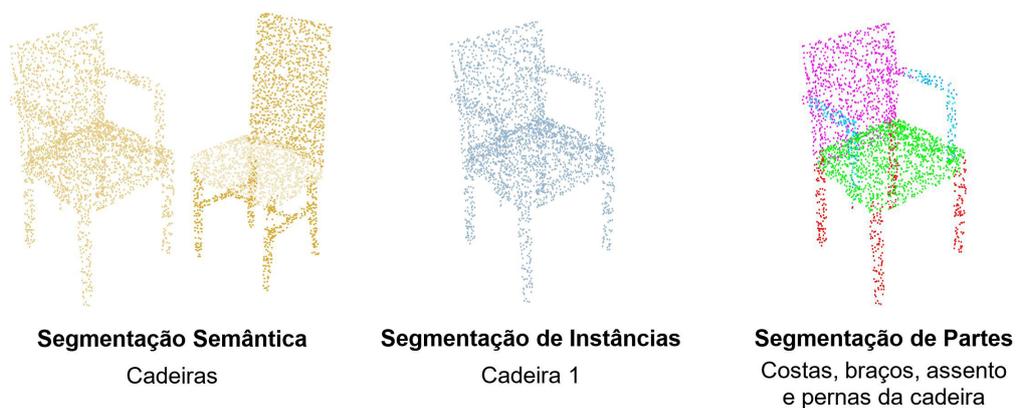


Figura 2
Segmentação semân-
tica, de instâncias e de
partes.

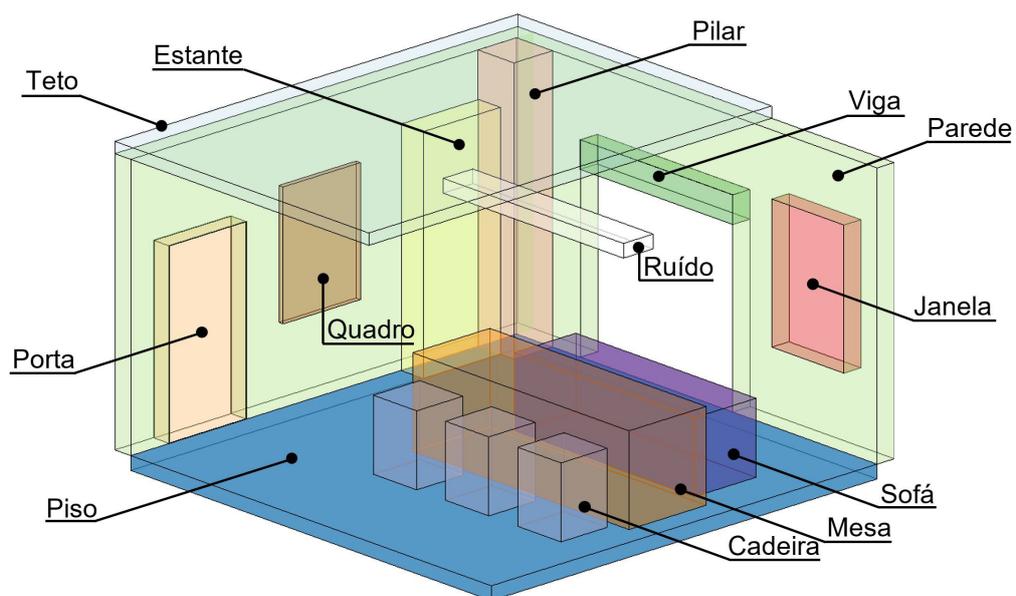


Figura 3
Tipologias de elemen-
tos já automatizadas.

4. Caso de Estudo

4.1. S3DIS

Devido às restrições de dimensão do artigo, o presente caso de estudo valida apenas algumas das componentes da metodologia, nomeadamente, a segmentação semântica e de instâncias, a caracterização dos elementos identificados e, por fim, a sua modelação BIM (i.e., modelação da geometria e posterior enriquecimento). Estas componentes são validadas através da sua aplicação no *dataset* S3DIS (*Stanford Three-Dimensional Indoor Scene*), um extenso *dataset* para segmentação de nuvens de pontos.

O S3DIS é constituído por nuvens de pontos de três edifícios diferentes da Universidade de Stanford, Califórnia, divididas por seis áreas (Figura 4). O *dataset* contém 272 espaços individuais de distinto estilo arquitetónico, incluindo anfiteatros, arrecadações, casas de banho, corredores, despensas, espaços de convívio, salas de aula, salas de reuniões, salas de escritório, salões e refeitórios. Cada ponto no *dataset* apresenta informação sobre a sua classe semântica e de instância, existindo 13 possíveis classes, já identificadas na Figura 3. Contêm ainda informação sobre as respetivas coordenadas X, Y, Z; cor R, G, B; e normal n_x, n_y, n_z .

Para validação dos algoritmos de segmentação, a nuvem de pontos da Área 5 foi utilizada como dados de teste e as restantes como dados de treino, tal como recomendado pelos autores do S3DIS. A Tabela 1 apresenta a divisão, por classe, dos pontos da Área 5. As métricas utilizadas incluem a precisão global ($oAcc$) e precisão média ($mAcc$):

$$oAcc = \frac{\text{Previsões Corretas}}{\text{Total de Previsões}} \times 100 \quad (1)$$

$$mAcc = \frac{\sum_S (\text{Previsões Corretas}_S / \text{Total de Previsões}_S)}{m} \times 100 \quad (2)$$

onde m representa o total de classes semânticas do *dataset* e S representa a classe semântica avaliada.

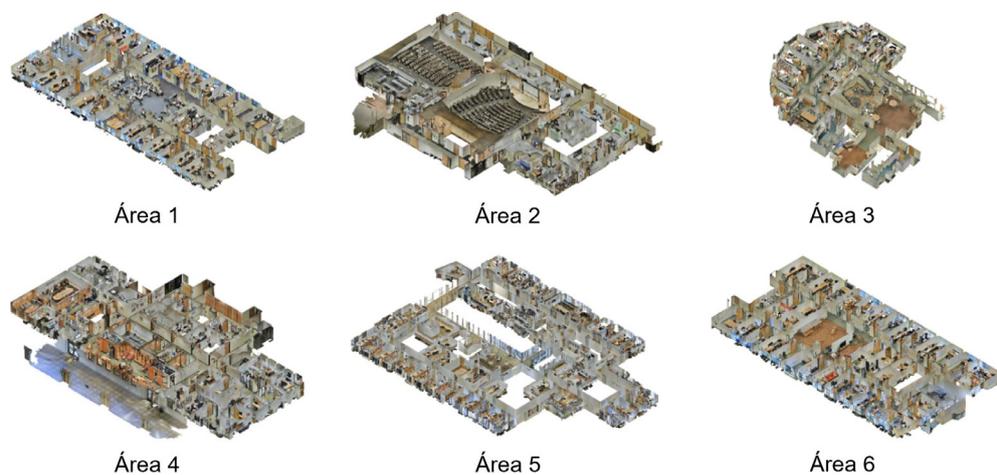


Figura 4
Nuvens de pontos disponíveis no *dataset* S3DIS.

Classe	Teto	Piso	Parede	Viga	Pilar	Janela	Porta	Mesa	Cadeira	Sofá	Estante	Quadro	Ruído	Total
#pontos	7.286.031	6.685.246	5.603.217	6.158	317.406	508.649	701.934	1.267.817	742.458	95.654	1.985.434	195.873	2.669.915	28.065.792
%pontos	25,96	23,82	19,96	0,02	1,13	1,81	2,50	4,52	2,65	0,34	7,07	0,70	9,51	100

Tabela 1

Divisão, por classe, dos pontos da Área 5.

4.2. Resultados

A Tabela 2 apresenta os resultados quantitativos da segmentação semântica do *dataset* S3DIS. Para uma avaliação qualitativa, as Figuras 5, 6, 7 e 8 apresentam algumas das nuvens segmentadas, caracterizadas geometricamente e modeladas, tudo de forma automática.

oAcc (%)	mAcc (%)	Acc por classe												
		Teto	Piso	Parede	Viga	Pilar	Janela	Porta	Mesa	Cadeira	Sofá	Estante	Quadro	Ruído
87,64	62,80	95,32	98,13	95,01	0,15	23,42	68,11	36,96	80,29	89,92	28,26	70,31	60,86	69,64

Tabela 2

Resultados quantitativos da segmentação semântica.

O S3DIS é um *dataset* de difícil segmentação, incluindo pilares não expostos e quadros brancos em paredes brancas. Adicionalmente, é também um *dataset* com classes mal distribuídas, com as classes “teto”, “piso” e “parede” a comporem mais de 60% dos dados.

Começando pelos resultados quantitativos, é possível verificar que o algoritmo proposto atinge uma precisão global de 87,64%, baixando para 62,80% no que diz respeito à sua precisão média. Isto deve-se ao algoritmo ter uma precisão elevada nas classes com mais dados de treino (e.g., “teto”, “piso” e “parede”), mas baixas precisões em classes com escassos dados (e.g., “viga”, “pilar”, “porta”, “sofá”). Ou seja, pode concluir-se que o desequilíbrio de dados por classe do *dataset* conduz a uma falha, por parte do algoritmo, na capacidade de generalização das classes com menos dados. Esta falha deve ser corrigida com a aquisição e treino de nuvens de pontos focadas nas classes com menor volume de dados.

Passando à avaliação qualitativa, é possível observar nas Figuras 5, 6, 7 e 8 que, apesar desta fraca capacidade de generalização, a modelação automática dos segmentos classificados permanece robusta, uma vez que muitos dos erros de segmentação semântica originam *outliers* que são eliminados aquando da segmentação por

instâncias e da caracterização geométrica. De facto, os maiores erros de modelação estão associados à segmentação de instâncias em espaços com muito ruído, como é possível observar pela segmentação das cadeiras na Figura 8.

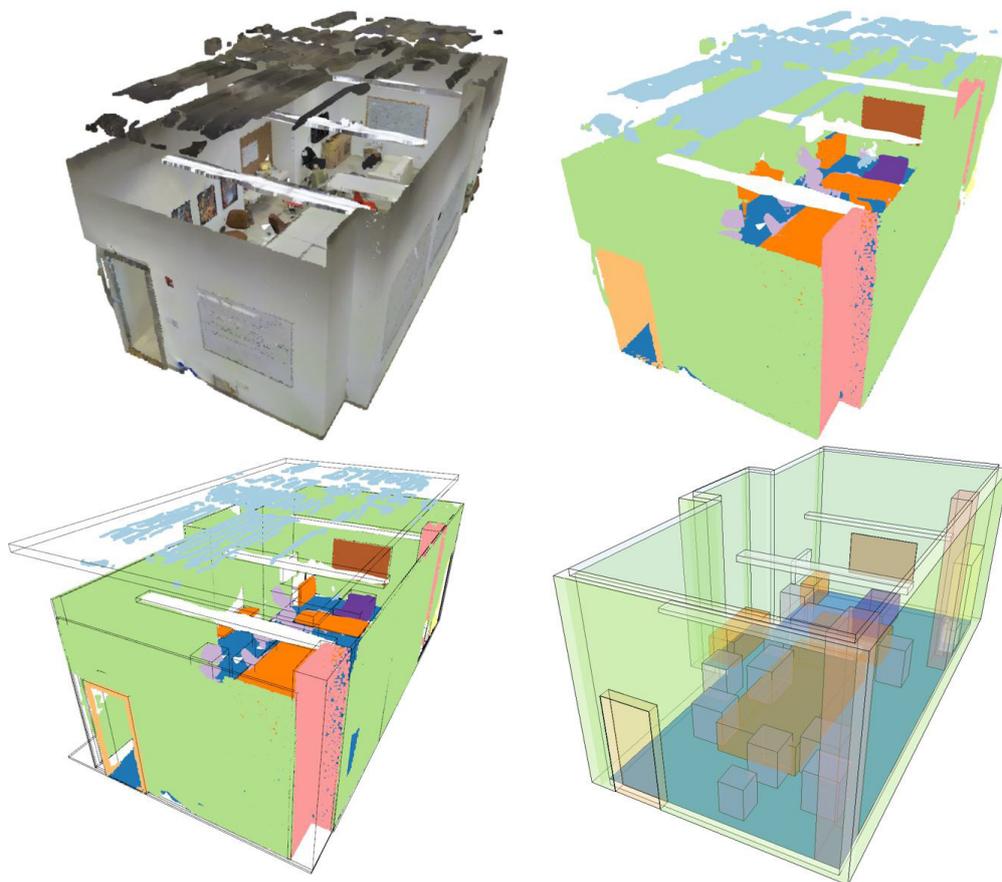


Figura 5
Segmentação, caracterização e modelação BIM de uma sala de reuniões.

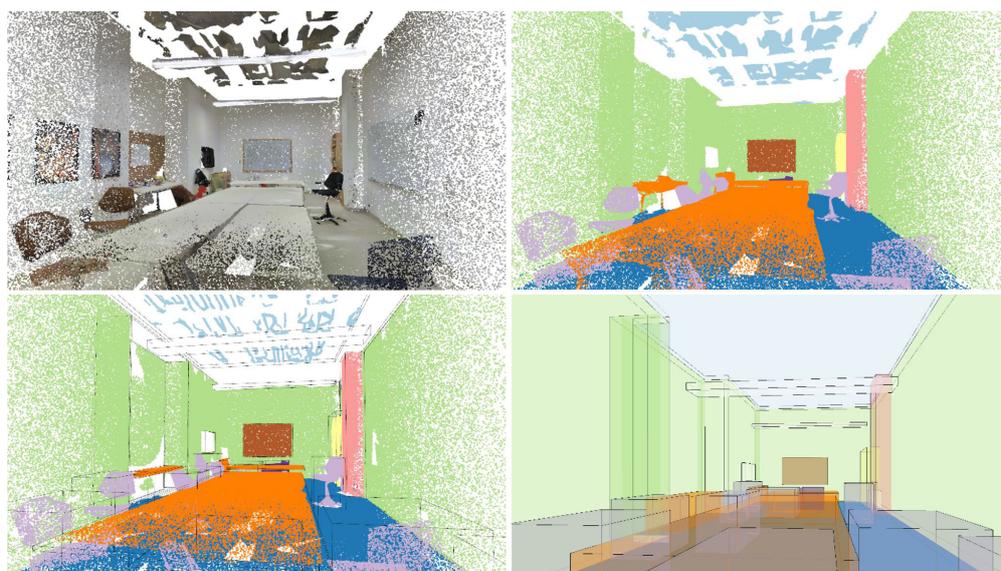


Figura 6
Vista interior da sala de reuniões visível na Figura 5.

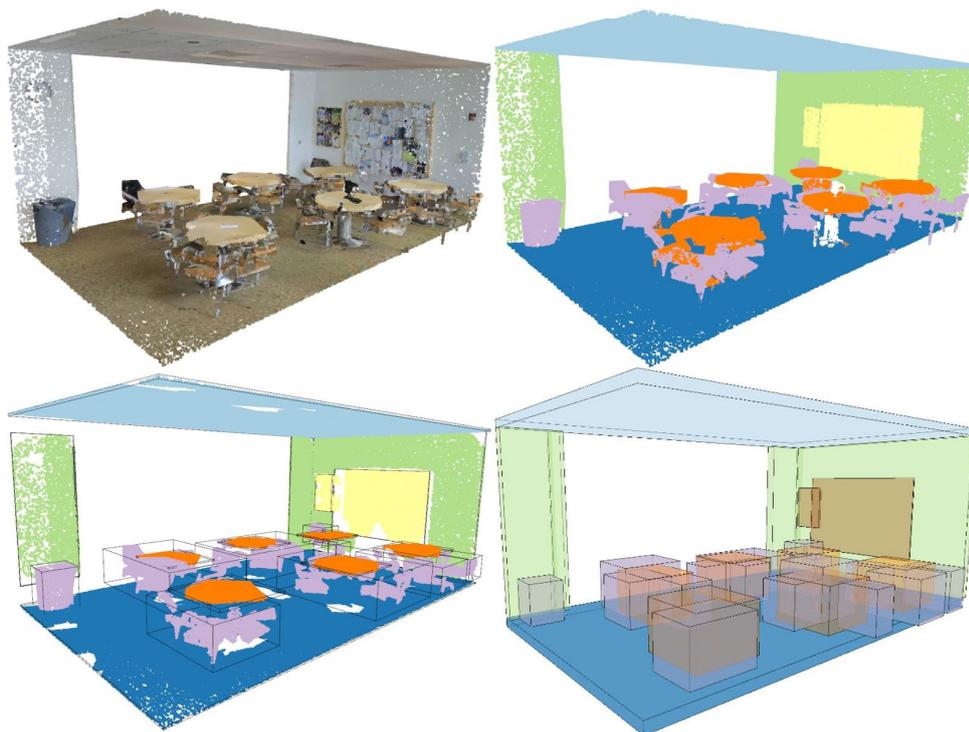


Figura 7
Segmentação, caracterização geométrica e modelação BIM de um refeitório.

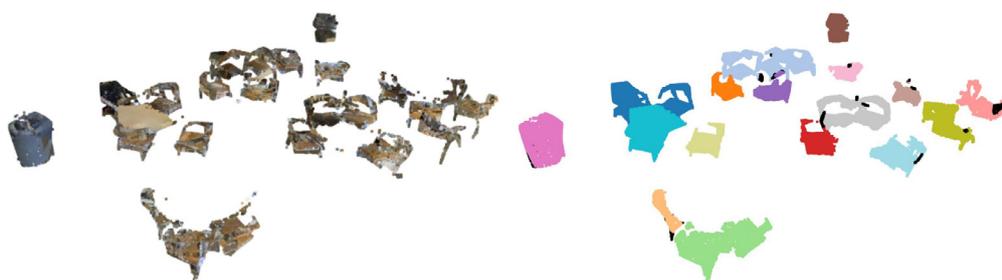


Figura 8
Segmentação de instâncias das cadeiras visíveis na Figura 7.

6. Conclusões

O presente artigo teve como objetivo desenvolver uma metodologia para automatização do processo Scan-to-BIM. Este objetivo teve como contexto a reabilitação do edificado existente, por forma a possibilitar uma rápida geração de modelos BIM e permitir uma rápida análise energética do modelo para identificação de medidas de reabilitação eficientes.

Neste sentido, o processo Scan-to-BIM foi dividido em seis etapas a automatizar, sendo proposta uma metodologia baseada em aprendizagem computacional e, mais especificamente, *deep learning*, para proceder à automatização.

A aplicação da metodologia num caso de estudo revelou resultados positivos, sendo atingida uma precisão global de 87,64% na segmentação semântica do *dataset* S3DIS. A modelação das referidas classes em ambiente BIM foi também considerado um sucesso.

Como trabalhos futuros, estão planeadas várias vertentes de ação, desde a expansão do *dataset* de treino à integração de novas tipologias de dados (e.g., de imagens termográficas).

7. Agradecimentos

Este trabalho foi financiado por: Financiamento Base – UIDB/04708/2020 e Financiamento programático – UIDP/04708/2020 da Unidade de Investigação CONSTRUCT – Instituto de I&D em Estruturas e Construções – financiada por fundos nacionais através da FCT/MCTES (PIDDAC). Este trabalho é também cofinanciado pelo Fundo Social Europeu (FSE). através do Programa Operacional Regional do Norte (Norte 2020) [Referência de Financiamento: NORTE-06-3559-FSE-000176].

Referências

- [1] European Parliament and Council of the European Union, “Directive (EU) 2018/844 of the European Parliament and of the Council of 30 May 2018 amending Directive 2010/31/EU on the energy performance of buildings and Directive 2012/27/EU on energy efficiency”, *Official Journal of the European Union*, vol. 156, 2018.
- [2] European Commission, “Energy performance of buildings directive”, 2019 [Online]. Disponível: <https://ec.europa.eu/energy/en/topics/energy-efficiency/energy-performance-of-buildings/energy-performance-buildings-directive> [Acedido 02/03/2021]
- [3] Ö. Göçer, Y. Hua e K. Göçer, “A BIM-GIS integrated pre-retrofit model for building data mapping”, *Building Simulation*, vol. 9, 2016.
- [4] L. Sanhudo, N. M. M. Ramos, J. P. Poças, R. M. S. F. Almeida, E. Barreira, M. L. Simões e V. E. M. Cardoso, “Building information modelling for energy retrofitting – A review”, *Renewable and Sustainable Energy Reviews*, vol. 89, 2018.
- [5] P. Tang, D. Huber, B. Akinci, R. Lipman e A. Lytle, “Automatic reconstruction of as-built building information models from laser-scanned point clouds: A review of related techniques”, *Automation in construction*, vol. 19, 2010.
- [6] Q. Wang, J. Guo e M.-K. Kim, “An application oriented scan-to-BIM framework”, *Remote sensing*, vol. 11, 2019.
- [7] L. Sanhudo, N. M. M. Ramos, J. P. Poças, R. M. S. F. Almeida, E. Barreira, M. L. Simões e V. E. M. Cardoso, “A framework for in-situ geometric data acquisition using laser scanning for BIM modelling”, *Journal of Building Engineering*, vol. 28, 2019.

- [8] M. Bassier e M. Vergauwen, "Unsupervised reconstruction of Building Information Modeling wall objects from point cloud data", *Automation in Construction*, vol. 120, 2020.
- [9] C. Wang, Y. K. Cho e C. Kim, "Automatic BIM component extraction from point clouds of existing buildings for sustainability applications", *Automation in Construction*, vol. 56, 2015.
- [10] F. Hamid-Lakzaeian, "Structural-based point cloud segmentation of highly ornate building façades for computational modelling", *Automation in Construction*, vol. 108, 2019.
- [11] T. Czerniawski, M. Nahangi, C. Haas e S. Walbridge. "Pipe spool recognition in cluttered point clouds using a curvature-based shape descriptor", *Automation in Construction*, vol. 71, 2016.
- [12] H. Son, C. Kim e C. Kim. "3D reconstruction of as-built industrial instrumentation models from laser-scan data and a 3D CAD database based on prior knowledge", *Automation in Construction*, vol. 49, 2015.
- [13] Y. Xie, J. Tian e X. X. Zhu. "Linking Points With Labels in 3D: A Review of Point Cloud Semantic Segmentation", *IEEE Geoscience and Remote Sensing Magazine*, vol. 8, 2020.
- [14] H. Balta, J. Velagic, W. Bosschaerts, G. De Cubber e B. Siciliano, "Fast Statistical Outlier Removal Based Method for Large 3D Point Clouds of Outdoor Environments", *IFAC-PapersOnLine*, vol. 51, 2018.
- [15] R. B. Rusu, N. Blodow e M. Beetz, "Fast Point Feature Histograms (FPFH) for 3D registration", em *IEEE Conference on Robotics and Automation*, Japão, 2009.
- [16] M. A. Fischler e R. C. Bolles, "Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography", *Communications of the ACM*, vol. 24, 1981.
- [17] Y. Chen e G. Medioni, "Object modelling by registration of multiple range images", *Image and Vision Computing*, vol. 10, 1992.
- [18] H. Thomas, C. R. Qi, J.-E. Deschaud, B. Marcotegui, F. Goulette e L. J. Guibas, "KP-Conv: Flexible and deformable convolution for point clouds", em *Proceedings of the 2019 IEEE International Conference on Computer Vision*, Coreia do Sul, 2019.
- [19] M. Ester, H.-P. Kriegel, J. Sander e X. Xu, "A density-based algorithm for discovering clusters in large spatial databases with noise", *Kdd*, vol. 96, 1996.
- [20] L. Yuan, J. Guo e Q. Wang, "Automatic classification of common building materials from 3D terrestrial laser scan data", *Automation in Construction*, vol. 110, 2020.