

Aprendizagem de máquinas aplicada a modelos de informação de construção: BIM2GNN

<https://doi.org/10.21814/uminho.ed.77.8>

**Aydan Aghabayli¹, Ricardo de Matos Camarinha²,
Manuel Esteves Luís³, José Granja⁴, Bruno Figueiredo⁵**

¹ *Universidade de Lisboa, Faculdade de Arquitetura, Lisboa, Portugal, 0000-0001-7420-221X*

² *BIMTEC Consultancy, Doha, Qatar, 0000-0002-3389-8043*

³ *BIMTEC Consultancy, Doha, Qatar*

⁴ *Universidade do Minho, ISE, Escola de Engenharia, Guimarães, Portugal, 0000-0002-0858-4990*

⁵ *Universidade do Minho, Lab2PT, Escola de Arquitetura, Arte e Design, Guimarães, Portugal, 0000-0001-8439-7065*

Resumo

Seguindo o conceito de digitalização, é amplamente aceite que actualmente ocorre uma transformação na indústria AEC impulsionada pela integração de processos eficazes na gestão de dados. Neste contexto, o BIM tem vindo a ganhar cada vez mais relevância ao permitir o acesso a grandes repositórios de dados. Os modelos BIM representam uma oportunidade de explorar grandes conjuntos de dados para melhorar a gestão do conhecimento e desempenho da indústria. No entanto, a conversão de dados em conhecimento requer um processo iterativo de contextualização e interpretação. Este trabalho adota uma perspectiva de aprendizagem para as máquinas aprenderem com os dados armazenados nos modelos BIM. A Aprendizagem Máquina – *Machine Learning* (ML) – é um subdomínio da ciência de dados que abre novos horizontes ao processo de aprendizagem a partir de grandes quantidades de dados, o que poderá desafiar a actual sector da AEC.

Este artigo estrutura-se em duas partes principais: em primeiro, apresenta uma revisão da literatura; em segundo lugar, propõe e testa uma estrutura BIM2GNN para fazer um uso iterativo, totalmente transparente, de dados BIM em algoritmos ML. Neste contexto, recorreu-se a algoritmos de Rede Neural Convolucional – *Convolutional Neural Network* (CNN) – e Redes Neurais Gráficas – *Graph Neural Network* (GNN).

Os autores concluíram que os dados BIM são relevantes para implementar técnicas de aprendizagem na construção, no entanto, existem ainda vários obstáculos a ultrapassar ao nível da indústria. Estes incluem o acesso a dados, formato de dados, tipos de ficheiros, estrutura de dados e interoperabilidade.

1. Introdução

Modelos de Informação para a Construção – *Building Information modelling* (BIM) – são cada vez mais utilizados na indústria AEC, nas suas diversas disciplinas e nos diferentes ciclos de vida do edificado. Apesar da adopção de BIM colocar vários desafios, cria oportunidades para abordagens inovadoras aos processos arquitetónicos e de construção [1]. Com o desenvolvimento de BIM, a indústria de AEC tem lidado com uma maior quantidade de dados gráficos e não gráficos. Técnicas computacionais avançadas e inteligentes da ciência de dados permitem oportunidades no sector através da capacidade de análise de *Big Data* [2]. Não obstante, o processo de recolha, organização, processamento e apresentação de dados continua a estar entre os principais desafios experimentados na indústria de AEC. Talvez, por este motivo, os processos de construção e projeto que beneficiam das actuais tendências da revolução digital, particularmente das abordagens da ciência dos dados, estejam ainda atrasadas se comparadas com outros sectores [3].

Com o desenvolvimento de tecnologias digitais dos últimos anos, verifica-se uma crescente digitalização da indústria AEC. Esta evolução dá-se sobretudo através de projectos de grande dimensão e complexidade, onde se experimenta a integração de dispositivos tecnológicos, que apoiam a normalização, precedentes legais, e a possibilidade de envolver e beneficiar todas as partes interessadas. O BIM tornou-se uma pedra angular do processo de evolução digital, envolvendo os vários softwares e tecnologias a ele ligados [5]. Contudo, importa questionar até que ponto os modelos BIM, um dos mais importantes repositórios de informação na indústria da construção, desempenham um papel central na facilitação da gestão de dados, uma vez que a disponibilidade dos dados por si só não melhora os processos de concepção ou construção.

Uma compreensão mais completa do conceito de digitalização na indústria AEC requer uma discussão sobre o processo de transformação dos dados em informação e, subsequentemente, em conhecimento [6, 7]. Os dados consistem em representações alfanuméricas sem relação ou significado, ou seja, sem contexto; a informação é o resultado de dar significado a esses caracteres. A informação torna-se conhecimento quando esta relação é analisada e compreendida dentro de algum contexto particular [8]. Neste documento, sugerimos um processo em que os dados são sujeitos a um processo semelhante para o desenvolvimento do conhecimento colectivo e, em última análise, do conhecimento.

Este documento investiga como a Aprendizagem Máquina – *Machine Learning* (ML) – pode apoiar e acelerar esta tendência, analisando o estado da arte de um domínio científico que se caracteriza pela rápida evolução de estudos na área da Inteligência Artificial, focando-se na sua aplicabilidade de técnicas específicas aos modelos BIM [4]. A ML lida com uma grande quantidade de dados e inclui técnicas que podem ajudar a identificar padrões, mesmo sem dados estruturados ou um problema especificamente definido. Assim, vemos a ML como o próximo passo necessário na gestão dos modelos BIM e na extracção de resultados vantajosos a partir dos dados

disponíveis. Como tal, este documento discute mais profundamente estratégias de utilização de dados de modelos BIM em técnicas ML.

2. Aprendizagem Máquina aplicada ao domínio da Arquitetura

A recente integração das tecnologias da informação (TI) em diferentes disciplinas facilitou o uso de técnicas da ciência de dados em áreas tão varadas quando a medicina, marketing, e construção. Como exemplo, as tarefas que mais recorrem à implementação de ML incluem a classificação de texto ou documentos, reconhecimento e processamento da fala, reconhecimento de objetos, imagens ou rostos, detecção de fraudes, diagnóstico médico, entre outros [9]. A ML pode ser identificada como um subcampo da Inteligência Artificial (IA), um grande campo que geralmente pode ser descrito como uma abordagem para a adopção de capacidades de pensamento cognitivo humano. É uma técnica para ensinar os computadores a imitar a capacidade de aprendizagem humana seguindo vários algoritmos e aprender com os dados disponíveis. Além disso, a ML pode ser definida "(...) como métodos computacionais utilizando a experiência para melhorar o desempenho ou para fazer previsões precisas" [9].

Aprendizagem profunda – Deep Learning (DL) – é um subcampo da ML que consiste em algoritmos de Rede Neural (NN) que podem simular a actividade cerebral humana, identificando e podendo extrair padrões inesperados dos dados analisados [10]. O DL é utilizado numa vasta gama de aplicações, tais como voz, reconhecimento de imagem e texto, recomendações online, algoritmos de preços, entre outros [11].

As Redes Neurais Gráficas (GNN) são um método DL que trabalha com dados gráficos. A estrutura de dados gráficos é representada por nós – um conjunto de objetos, e por arestas – a relação entre esses objetos. GNN tem ganho popularidade uma vez que tem aplicação em muitas áreas, especialmente áreas que envolvem trabalho com dados visuais (tais como imagens). A aplicação de dados gráficos é adequada para a estruturação de tarefas em ciências sociais, naturais, e outras ciências e disciplinas [12].

3. Aplicações anteriores de Redes Neurais para desenho arquitetónico

Actualmente, os algoritmos NNs estão a tornar-se extensivamente adotados por investigadores na área da Arquitetura. A revisão realizada mostra que os algoritmos de Redes Adversárias Generativas – *Generative Adversarial Network* (GAN) – são os mais adotados em investigações para o desenho de plantas arquitetónicas. As GANs são algoritmos NN propostos por Goodfellow et al. em 2014 [13]. Os GAN são utilizados para estimar modelos generativos, que podem gerar novas instâncias de dados através da criação de dois algoritmos de rede neural concorrentes: o gerador e o discriminador. O primeiro gera dados falsos semelhantes à verdade do terreno. Isola et al. [14] exploraram as Redes Adversárias Condicionais (uma aplicação baseada em

GANs) para tradução de imagem para imagem, tais como imagens de satélite para mapas, gerador de fachadas a partir de etiquetas ou imagens de dia para noite. Este foi identificado como um dos primeiros exemplos de utilização desta metodologia no domínio arquitetónico. No domínio da concepção de plantas arquitetónicas, os algoritmos GAN foram aplicados numa série de aplicações como a geração automática de espaços, tal como apresentado por Nauata et al. [15]. Neste estudo, a máquina gera novas plantas recebendo gráficos de conectividade sob a forma de diagramas de bolhas como entrada. Stanislas Chaillou [16] propôs um procedimento para a geração automática de plantas em que a máquina gera novas plantas baseadas num contorno exterior pré-definido, para além das janelas verticais distribuídas ao longo desse contorno.

A investigação de Cecilia Ferrando [17] analisa as plantas dos edifícios históricos em formato de imagens raster para determinar a sua conectividade espacial e gráficos de visibilidade. Os algoritmos NN processam depois esta informação para determinar automaticamente os rótulos adequados aos espaços de disposição. A discussão sobre a capacidade de reconhecer automaticamente padrões a partir de plantas, mesmo de projetos menos convencionais de alguns arquitetos de renome, é apresentada na pesquisa de As et al. [11]. Neste estudo de caso, DL sob a forma de GANs aprende a partir de gráficos de conectividade para automatizar processos semelhantes na fase de concepção conceptual do projeto. Os autores extraem os gráficos de entrada dos modelos BIM fazendo uso de ferramentas BIM convencionais.

Em resumo, a crescente popularidade do uso de GANs na identificação e criação de plantas é evidente. Enquanto a informação 2D é ainda a fonte de dados mais comum e amplamente disponível na indústria, este artigo sugere que o crescente impulso na representação do ambiente construído em formatos 3D justifica a discussão de abordagens que se baseiam nesta fonte de informação mais completa. David Newton [18] utiliza uma síntese de desenhos 2D e modelos 3D para treinar o algoritmo de criação automática de fachadas representativo de certos estilos arquitetónicos.

Apesar da popularidade das GANs no domínio da arquitetura, algumas aplicações de GNNs foram também revistas. O estudo publicado por Hu et al. [19] apresenta o Graph2Plan que permite a geração automática de plantas com base numa determinada implantação do edifício e introduz a utilização de GNNs nesse contexto. Além disso, o método permite incluir várias restrições ao plantas, tais como contagem de salas e conectividade. O algoritmo foi treinado com base no conjunto de dados de plantas arquitetónicas RPLAN, constituído por um conjunto de imagens *raster*. Os autores introduziram o uso de GNNs para processamento sobre os plantas a partir da abordagem gráfica e Redes Neurais Convolucionais (CNNs) para processamento de imagens *raster*. A otimização foi aplicada para alinhar os resultados obtidos a partir do processamento de GNNs e algoritmos de CNNs [19].

O conceito de utilização de dados gráficos integrados num modelo 3D foi recentemente desenvolvido por Jabi e Alymani [20]. Nesta pesquisa, os autores apresentaram um novo conceito de utilização de modelos conceptuais 3D em vez de imagens

raster 2D para aplicações de ML em projetos arquitetônicas e de desenho urbano. Foi criada uma grande quantidade de dados sintéticos utilizando *software* topológico. Os dados consistiram em diferentes topologias de edifícios (constituídos por células) e a sua área de implantação (uma célula que representa um bloco urbano onde o edifício está localizado).

Embora estas técnicas tenham começado a utilizar dados 3D como *input*, a utilização de modelos BIM ainda foi limitada. Os campos de aplicação ML propostos incluem a detecção de colisões [21], estimativa de custos [22], conversão de nuvem de pontos de varrimento 3D para BIM [23, 24], fabricação digital [25], modelação energética ou sustentabilidade [26]. Não obstante, a revisão bibliográfica realizada para este estudo mostra que, para conhecimento dos autores, não existe um trabalho relevante na gestão do processo de desenho arquitetónico conceptual através da integração de dados ML e BIM. Como os modelos BIM contêm uma estrutura de dados mais rica do que, por exemplo, imagens raster, há uma oportunidade de melhorar a utilização de algoritmos ML, utilizando dados BIM como *input*.

4. Estrutura: BIM2GNN

Esta secção propõe uma estrutura para ligar os dados BIM e um processo de aprendizagem GNN. Dado um grande número de potenciais usos desta aplicação, o BIM2GNN foi especialmente concebido no âmbito da análise e geração de plantas arquitetónicas. Como tal, a estrutura recorre a Sintaxe Espacial – Space Syntax (SS) – como a semântica que liga o BIM e a ML. Uma planta é analisada de acordo com regras SS [17]. A teoria da Sintaxe Espacial estuda as relações entre os espaços e desenvolve técnicas para medir e analisar essas relações. As análises de conectividade com o gráfico de conectividade [27] como resultado foram identificadas como a metodologia primária que pode ser utilizada neste trabalho. Para além da tarefa primária de identificação da planta, os espaços podem ser classificados de acordo com o seu nível de privacidade, para o qual as relações definidas pelas metodologias da Sintaxe Espacial também são úteis [28].

4.1. Metodologia

O trabalho estruturou-se de acordo com um processo iterativo e experimental. Incluiu a criação de um conjunto de dados síntese (como o *input* para o algoritmo ML), preparação de dados (ordem, filtragem, junção, criação de matriz), formação de um modelo NN e a passagem dos dados de teste.

Devido à dificuldade em encontrar dados em modelos de formato BIM, foi decidido utilizar os dados síntese como *input* para o algoritmo. Os dados síntese foram criados utilizando o software Autodesk Revit usando as linguagens Dynamo e Python. O conjunto de dados consiste na construção de plantas aleatórios com três, quatro e cinco divisões.

Para simplificar o processo para a primeira fase de implementação, foi decidido limitar os plantas com paredes, salas e portas. Cada espaço representava uma espaço e foi nomeado de acordo com uma convenção de nomenclatura – "Grupo"_"ID do planta"_"nome do espaço" (por exemplo, Grupo 221 KIT). Os seguintes ID-s foram atribuídos aos espaços: KIT – cozinha; LVR – sala de estar; NB1/NB2 – quartos 1 e 2; e WC para casas de banho. As ligações entre os espaços foram representadas apenas por portas entre eles.

Duas tabelas foram extraídas do Revit para um ficheiro .csv como dados em bruto para posterior execução do algoritmo. Após a extracção, os ficheiros .csv foram inseridos em dois ficheiros diferentes do Google Collab. A biblioteca Pandas de Python foi utilizada para a modificação dos dados. Os conjuntos de dados foram filtrados e as instâncias de dados inúteis (as áreas da sala, parâmetros de portas, etc.) foram apagadas. O conjunto de dados simplificado foi guardado num ficheiro .csv.




Figura 1
Um exemplo da geração de um gráfico a partir da planta do edifício.

Para dar contexto e significado aos dados, estes precisavam de ser convertidos em formato gráfico antes de poderem ser utilizados como entrada para GNNs. A figura 1 ilustra um exemplo de análise manual de Sintaxe Espacial: criação do gráfico a partir do planta. A primeira imagem ilustra um mapa convexo, e a segunda a conectividade. Cores diferentes representam salas diferentes no gráfico. A teoria da Sintaxe Espacial foi introduzida e envolvida no estudo de caso actual como uma ligação entre a interpretação (ou seja, dar sentido) do espaço arquitetónico e a sintaxe da máquina. Para maior legibilidade dos dados, foi criada uma matriz de conectividade.

Foi criada uma matriz adjacente (como uma representação típica dos dados do grupo) com base nos dois conjuntos de dados iniciais. O conjunto de dados dos espaços foi utilizado para ter uma lista completa de plantas disponíveis com os espaços correlacionados; isto foi utilizado como base para a matriz. A informação do conjunto de dados da porta foi extraída para preencher a matriz com valores 1,0 ou 0,0 (sim/não); as margens do gráfico não têm um peso atribuído (todas as relações nos gráficos foram assumidas como as mesmas para esta fase do projeto). Todos os valores da matriz (excepto os índices – nomes de colunas) foram codificados em números,

incluindo a identificação dos espaços. Para maior identificação na matriz, foram criadas colunas `Room_Type` e `Room_Group`; `Room_Type` representa o valor atribuído para cada tipo de espaço (por exemplo, cozinha - KIT - 0) enquanto `Room_Group` representa o índice de diferenciação para cada planta.

Cada planta é avaliada apenas com base nas suas funções de conectividade; não foram atribuídos parâmetros de tamanho ou área. Como tal, várias das variações das amostras detectadas no conjunto de dados foram reduzidas a algumas representações como gráficos. Os dados foram divididos em dados de treino (70%) e em dados do teste (30%). A separação foi realizada com as restrições de que a localização dos espaços a partir da mesma disposição deveria ser o mesmo conjunto de dados (treino ou teste). O conjunto de dados foi testado num algoritmo de redes neuronais. Os modelos CNN e GNN foram treinados com base nos seguintes parâmetros:

```
hidden_units = [32,32]
learning_rate = 0.01
dropout_rate = 0.5
num_epochs = 300
batch_size = 256
```

A máquina foi treinada para reconhecer nomes dos espaços (nomes em bruto na coluna `Room_Name`) com base na conectividade entre os espaços (valores 1,0 ou 0,0 na matriz de conectividade). Como resultado da formação, o resultado global da previsibilidade foi definido como 25%.

4.2. Descobertas

O processo geral da implementação dos dados de BIM é considerado bem sucedido. Permite aceder e extrair dados de modelos BIM e posteriormente executar dados gráficos com algoritmos ML. O tempo de processamento do algoritmo e de recolha de dados é mais rápido do que poderia ser no processamento de imagens *raster* 2D. Isto pode muito provavelmente ser justificado pelo fato da estrutura abordar os dados de uma forma mais estruturada, ou seja, filtra e identifica o tipo de dados e os formatos de valores que podem gerar *insight* para a aplicação em questão. Ao executar conjuntos de dados baseados em imagens, o algoritmo baseia-se em *inputs* gráficos que, ao nível do *pixel* ou do grupo de *pixels*, são, como ponto de partida, menos relevantes para a aplicação. Como tal, os dados estruturados nos modelos BIM são necessariamente mais relevantes no início para a ML, transpondo a aplicação.

Não obstante, verificou-se também que o conjunto de dados síntese poderia ser demasiado simplista, comprometendo a capacidade da máquina de detectar padrões suficientes para prever os resultados desejados. Além disso, a utilização de modelos industriais – ou seja, mais complexos – pode fornecer uma estrutura de dados mais rica que poderia ser benéfica para o algoritmo. No entanto, durante este trabalho, verificou-se que a utilização de dados reais de construção de diferentes fontes em

formato nativo pode criar desafios adicionais devido à falta de padronização da indústria conhecida.

Enquanto a maioria dos trabalhos analisados pela ML que utilizam dados de BIM foram desenvolvidos utilizando a Revit API para extração de dados, este trabalho explorou a utilização de tabelas a serem processados no ambiente do Google Collab. Como este processo reduz substancialmente a complexidade dos dados originais, isto pode minar e limitar o desempenho dos algoritmos da ML. Embora o processo concebido seja semi-automático, poderia ser totalmente automático através de APIs.

A maioria dos estudos de caso analisados na literatura implicaram aplicações de dados 2D em aplicações NN. Apesar da grande popularidade dos GAN, as GNNs são menos implementadas em estudos de caso. O processo aqui proposto não é disruptivo, mas antes inovador nos estudos de arquitetura que utilizam dados BIM, e é, a nosso ver, interessante pela sua transparência. Este trabalho explorou a utilização de dados programados com posterior engenharia de dados no ambiente do Google Collab. No entanto, o utilizador deve estar ciente de que a conversão de objetos tridimensionais em variáveis tabulares pode reduzir drasticamente a complexidade dos dados originais e comprometer e limitar o desempenho dos algoritmos ML.

5. Discussão

A gestão de dados continua a ser um obstáculo no dia-a-dia das operações dos intervenientes na construção. Sendo isto amplamente reconhecido, os desenvolvimentos na implementação e regulamentação dos modelos BIM são vistos como necessários. Isto é particularmente verdade quando se tenta fazer uso de dados à escala para fins de aprendizagem. Embora a ML se tenha tornado amplamente popular em muitas indústrias que exploram aplicações tecnológicas intensivas na construção, parece ser ainda um nicho da investigação académica. No entanto, a utilização mais ampla de técnicas de ML em aplicações da indústria AEC requer a superação de vários desafios.

Captura de dados e Interoperabilidade: a aplicação de técnicas de ML depende fortemente da semântica e da precisão da sintaxe. Como tal, a utilização de normas e tipos de ficheiros de armazenamento de dados de fonte aberta, como o IFC, são considerados essenciais para escalar as aplicações de ML na construção. Além disso, o tipo de ficheiro IFC define uma estrutura de dados pragmática que identifica explicitamente objetos, os seus atributos e semântica, relações entre objetos, conceitos (tais como custos, desempenho, etc.), processos (tais como instalação, demolição, operação, etc.) e intervenientes no projecto [29]. Isto simplifica o processo de conversão de dados em informação.

Semântica: os resultados deste estudo consideram a utilização de análises de Sintaxe Espacial (SS) bem sucedida. Este trabalho sugere a utilização destas análises, especialmente na aplicação de GNNs. As análises SS para posterior utilização poderiam incluir dados mais complexos, tais como os isovistas. No entanto, a utilização de SS está limitada à aplicação conceptual de ML ao espaço arquitetónico. Diferentes

aplicações no domínio da construção e engenharia podem exigir uma semântica intermédia alternativa para converter dados brutos em informação. Isto acrescenta um nível de complexidade na aplicação de ML aos modelos BIM, uma vez que requer fundamentalmente que os técnicos de construção sejam alfabetizados e, ML ou, inversamente, que os técnicos de ciências da computação sejam alfabetizados na construção.

Automatização: para melhorar ainda mais o quadro de implementação de ML, pode ser sugerido um fluxo de trabalho automatizado. Por exemplo, isto pode incluir os softwares *Rhino* e *Grasshopper* para facilitar a extracção de dados de ficheiros IFC, ou através de *plug-ins* para análises avançadas da Sintaxe Espacial. Com as tecnologias digitais AEC em constante evolução, a recepção contínua de dados "em tempo real" para algoritmos ML melhorará o processo de aprendizagem. Nesse sentido, o estabelecimento de um CDE ajuda a superar a fragmentação na indústria ao ter acesso a dados de múltiplas fontes, criando condições estruturadas melhoradas para melhores resultados de ML. Aplicações mais avançadas de ML, baseadas em decisões e *feedback* "em tempo real" dos utilizadores, podem ser alcançadas através, por exemplo, do reforço da aprendizagem – o algoritmo pode melhorar-se a si próprio com base nos contributos ambientais.

Selecionar o algoritmo ML: as GNNs requerem dados gráficos como *input*, o que é uma das representações mais comuns do espaço com base em análises SS. Assim, a escolha dos algoritmos é absolvida em termos de estrutura de dados. No entanto, os algoritmos NN exigem mais dados de entrada do que outros tipos de algoritmos ML; por conseguinte, podem ser considerados diferentes cenários de fluxos de trabalho.

Desde a aprendizagem até ao resultado: embora este trabalho esteja centrado na validação da estrutura do BIM2GNN, vários resultados poderiam ser idealizados. Exemplos são a atenuação de processos repetitivos, tais como a nomeação automática dos espaços e a geração de plantas em busca de soluções ótimas dentro de critérios pré-definidos. Não obstante, o processo de definição e representação do resultado é considerado simétrico de uma perspectiva da estrutura de dados. A segunda parte do processo definiria o processo inverso de modelação de dados BIM a partir dos conhecimentos gerados num formato legível por máquinas. Por exemplo, um planta de um apartamento poderia ser gerado em Revit a partir dos resultados da aprendizagem.

Interoperabilidade: os ficheiros IFC podem ser utilizados em vez do formato nativo para aumentar a interoperabilidade e receber uma melhor estrutura de dados. A estrutura hierárquica do IFC e a disponibilidade das relações entre objetos (também espaços) apresentam oportunidades a serem exploradas com algoritmos ML. Além disso, é definido um formato de código aberto para melhorar a acessibilidade aos dados no seu formato original, sem a conversão em tabelas, tal como realizado no presente estudo de caso.

Para finalizar, como a ciência de dados aplicada à construção ainda está nos seus primórdios, uma lista de questões pode ser proposta para melhorar ainda mais esta estrutura, ou outras semelhantes, adotando o BIM e ML:

1. Existe um número suficiente de modelos BIM fiáveis e dimensionáveis de armazenamento de dados em toda a indústria?
2. Qual é o formato ideal para conjuntos de dados, e quais são os critérios de qualidade de dados necessários a serem cumpridos?
3. Qual é a relevância da estrutura de dados dos modelos BIM (particularmente o IFC) para racionalizar o processo de aprendizagem que envolve um desafio na indústria?
4. Que algoritmos ML são mais adequados para serem formados por conjuntos de dados como os modelos BIM? Como pode o resultado da aplicação ter impacto na adopção de um algoritmo ML específico?
5. Sendo o DL reconhecido como sendo capaz de detectar padrões frequentemente não percebidos por humanos, poderia a ML gerar percepções disruptivas para além do discurso comum da produtividade da construção?

5. Conclusão

Este documento introduz as técnicas ML como facilitadores da aprendizagem coletiva, fazendo uso dos dados da indústria AEC e visa identificar uma estrutura de fluxo de trabalho para a aplicação das técnicas ML nos modelos BIM. A revisão bibliográfica realizada permitiu concluir que BIM desempenha um papel crucial no processo de gestão de dados na indústria AEC. Observou-se também que as técnicas de ciência de dados são também factores cruciais para facilitar a transição digital da indústria para o conceito de Construção 4.0. Portanto, esta investigação sugere que existe uma oportunidade de aplicar técnicas da ciência de dados para aprender com os modelos BIM que contêm informação extensa.

O processo experimental do BIM2GNN proposto destaca a importância da aquisição e gestão de dados desde o início de qualquer projecto. O estudo de caso baseia-se nos espaços e nos seus dados de conectividade, exportados a partir de dados BIM. Os algoritmos CNN e GNN foram testados para aprender com os dados do grupo. Apesar dos desafios enfrentados, a aplicação abre novas oportunidades para o desenvolvimento de mais investigações. Devido ao actual nível de maturidade de digitalização na indústria, os resultados colocaram naturalmente mais questões para futuras pesquisas sobre este tópico.

A implementação futura de metodologias de aprendizagem utilizando modelos ML com BIM requer a superação de vários desafios a nível da indústria. A abordagem destes obstáculos poderia melhorar o desempenho global do AEC e a gestão geral do conhecimento individual e colectivo, utilizando os já grandes, mas inconsistentes, repositórios digitais de informação.

Referências

- [1] Sackey E, Tuuli M, Dainty A (2015) Sociotechnical Systems Approach to BIM Implementation in a Multidisciplinary Construction Context. *J Manag Eng* 31:1-11.
- [2] Bilal M, Oyedele LO, Qadir J, et al (2016) Big Data in the construction industry: A review of present status, opportunities, and future trends. *Adv. Eng. Informatics* 30:500-521.
- [3] Mansouri S, Akhavian R (2018) The Status Quo and Future Potentials of Data Analytics in AEC/FM: A Quantitative Analysis of Academic Research and Industry Outlook. *Constr Res Congr 2018 Infrastruct Facil Manag – Sel Pap from Constr Res Congr 2018* 2018-April:90-100.
- [4] Geron A (2019) *Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow*
- [5] Wyman O (2018) *Digitalization of the Construction Industry : the Revolution is Underway the Time is Right to Set Up a Real Digital Strategy*
- [6] Clark D (2004) *The Continuum of Understanding*. <http://www.nwlink.com/~donclark/performance/understanding.html>. Accessed 3 Sep 2021
- [7] Pohl J, Agent C, Poly C, Luis S (2014) *Transition from Data to Information*
- [8] Engin Z, van Dijk J, Lan T, et al (2020) Data-driven urban management: Mapping the landscape. *J Urban Manag* 9:140-150.
- [9] Mehryar M, Rostamizadeh A, Talwalkar A (2018) *Foundations of Machine Learning*, second ed. Massachusetts Institute of Technology All
- [10] Goodfellow I, Bengio Y, Courville A (2000) *Deep Learning*
- [11] As I, Pal S, Basu P (2018) Artificial intelligence in architecture: Generating conceptual design via deep learning. *Int J Archit Comput* 16:306-327.
- [12] Zhou J, Cui G, Hu S, et al (2020) Graph neural networks: A review of methods and applications. *AI Open* 1:57-81.
- [13] Goodfellow I, Pouget-Abadie J, Mirza M, et al (2014) Generative adversarial networks. *Commun ACM* 63:139-144.
- [14] Isola P, Efros AA, Ai B, Berkeley UC (2016) *Image-to-Image Translation with Conditional Adversarial Networks*
- [15] Nauata N, Chang KH, Cheng CY, et al (2020) House-GAN: Relational Generative Adversarial Networks for Graph-Constrained House Planta Generation. *Lect*

- Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics) 12346 LNCS:162-177.
- [16] Chaillou S (2019) AI + Architecture. Harvard GSD
- [17] Ferrando C (2018) Towards a Machine Learning Framework in Spatial Analysis. Sch Archit Carnegie Mellon Univ Work Pap 1:89
- [18] Newton D (2019) Generative Deep Learning in Architectural Design. Technol Archit Des 3:176-189.
- [19] Hu R, Huang Z, Tang Y, et al (2020) Graph2Plan : Learning Floorplan Generation from Planta Graphs. 39:1-14
- [20] Jabi W, Alymani A (2020) Graph Machine Learning Using 3D Topological Models. SimAUD 427-434.
- [21] Hu Y, Castro-Lacouture D (2019) Clash Relevance Prediction Based on Machine Learning. J Comput Civ Eng 33:04018060.
- [22] Fiske J (2019) Towards Automated Cost Analysis , Benchmarking And Estimating In Construction : A Machine Learning Approach. <https://doi.org/10.33965/bigdaci2019>
- [23] Keshavarzi M, Afolabi O, Caldas L, et al (2020) GENSCAN: A generative method for populating parametric 3D scan datasets. arXiv 1:91-100.
- [24] Babacan K, Chen L, Sohn G (2017) Semantic Segmentation Of Indoor Point Clouds Using Convolutional Neural Network. ISPRS, Sci 4:101-108.
- [25] Ramsgaard Thomsen M, Nicholas P, Tamke M, et al (2020) Towards machine learning for architectural fabrication in the age of industry 4.0. Int J Archit Comput 18:335-352.
- [26] Ma G, Liu Y, Shang S (2019) A building information model (BIM) and artificial neural network (ANN) based system for personal thermal comfort evaluation and energy efficient design of interior space. Sustain 11
- [27] Space Syntax Laboratory UCL, Space Syntax Limited (2021) Space Syntax Online Training Platform. <https://www.spacesyntax.online/>
- [28] Mustafa FA, Baper SY, Hassan AS (2010) Using space syntax analysis in detecting privacy: a comparative study of traditional and modern house plantas in Erbil city, Iraq. Asian Soc Sci 6
- [29] BuildingSMART (2021) BuildingSMART official website. <https://technical.buildingsmart.org/standards/ifc/>. Accessed 23 Aug 2021