

Avaliando o potencial da integração da Inteligência Artificial ao Building Information Modelling (BIM) na Indústria 4.0

<https://doi.org/10.21814/uminho.ed.142.22>

**Paulo Santos¹, Isabela Ferreira², Breno Cortez³,
Gabriela Nascimento⁴, Michele Tereza Marques Carvalho⁵**

¹ *Universidade de Brasília – UnB, Brasília, 0000-0002-9801-1423*

² *Universidade de Brasília – UnB, Brasília, 0000-0002-3918-5669*

³ *Universidade de Brasília – UnB, Brasília, 0000-0002-1828-7586*

⁴ *Universidade de Brasília – UnB, Brasília, 0009-0003-4678-1068*

⁵ *Universidade de Brasília – UnB, Brasília, 0000-0001-7969-9341*

Resumo

O BIM desempenha um papel crucial na Indústria 4.0, trazendo desafios significativos no gerenciamento e análise de dados. O avanço tecnológico facilita a obtenção de dados, viabilizando práticas de aprendizado profundo, como visão computacional, previsão de defeitos e análise de riscos. Este estudo investigou técnicas de inteligência artificial (IA) no contexto do Building Information Modelling (BIM), visando explorar linhas de conhecimento através de uma revisão sistemática e crítica de produções científicas. Os resultados de 101 publicações destacam a importância da padronização e gestão de dados na integração com plataformas de gerenciamento. Estas estão focadas na etapa de facilities, monitoramento, uso e manutenção de ambientes construídos, utilizando sensoriamento e escaneamento de dados, além de propostas para prevenir erros durante o projeto e construção. Paralelamente são discutidas tendências, como enriquecimento semântico IFC, obtenção de dados por IA e uso de Gêmeos Digitais (DT) na automatização de informações. Este trabalho serve de recurso para pesquisadores, profissionais da construção e tomadores de decisão interessados nos avanços na gestão da informação em BIM com IA. Também propõe fluxos de aprendizagem a partir do mapeamento do estado da arte, análise de cluster e redes de conexão por citações e palavras-chave, fornecendo insights para pesquisas futuras.

1. Introdução

A convergência entre os modelos BIM e tecnologias avançadas tem demonstrado significativa relevância na Indústria 4.0, um setor em transformação substancial impulsionada pelas técnicas IAs que delineiam seu futuro [1], possibilitando auxílios na tomada de decisões para resolução de problemas específicos, desde a gestão de ativos até o gestão ampla de todo o processo de construção.

Este estudo tem o objetivo de identificar as principais aplicações de técnicas de IA para BIM na Indústria 4.0, fornecendo insights para pesquisas futuras. Dessa forma, análise das publicações tem o propósito de responder às seguintes questões:

- Quais são as principais tendências de pesquisa possibilitadas pela integração do BIM e IA?
- Qual é o nível de evolução do ponto de vista científico e tecnológico?
- Quais aplicações, dificuldades e aprendizados adquiridos, que podem ser replicados?

2. Metodologia

O método adotado abordou uma análise bibliométrica e uma revisão sistemática da literatura (SLR), oferecendo uma perspectiva abrangente das técnicas e abordagens de IA aplicadas ao BIM. Os bancos de dados Web of Science e Scopus foram explorados para mapear o panorama das publicações de periódicos, atas de congressos e capítulos de livros. Para a consulta de teses e dissertações, as plataformas OATD.org e Biblioteca Digital Brasileira de Teses e Dissertações (BDTD) foram utilizadas.

Para a preparação da pesquisa, empregamos a *string* de busca (“*machine learning*” OR “*deep learning*” OR “*pattern recognition*” OR “*neural networks*” OR “*real time systems*”) AND “*digital twins*” AND (“BIM” OR “*building information modelling*” OR “*building information model*” OR “*building information management*”) sem delimitação temporal específica, abarcando, assim, a totalidade do período de investigação.

Foram identificados 731 artigos na base Scopus e 140 na Web of Science, totalizando 871 produções. Após a remoção de duplicatas e a revisão dos títulos, resumos e palavras-chave, restaram 93 produções: 88 artigos de periódicos, 3 de conferências e 2 capítulos de livros. As produções excluídas focavam em integração de dados ambientais e geotécnicos e monitoramento de pessoas com COVID, sem associação direta à Indústria 4.0. Posteriormente foram adicionadas 5 teses de doutorado e 3 dissertações de mestrado, resultando em 101 publicações selecionadas para análise, disponibilizados em um repositório Zenodo [2].

3. Resultados

O método adotado por esta pesquisa compreende em uma análise bibliométrica e uma SLR. Esse processo é fundamental para a compreensão e identificação de padrões, tendências e lacunas na pesquisa.

Neste estudo, utilizamos o visualizador VOSViewer para o levantamento e análise dos dados das publicações. Primeiramente, criamos um mapeamento das redes bibliométricas, apresentado na Figura 1, identificando 3 agrupamentos (clusters). O tamanho do nó baseia-se na frequência de ocorrências de palavras-chave e a espessura entre ligações representa o número de citações entre as publicações.

O *cluster* vermelho (10 termos) trata da **classificação da informação**, focando em visão computacional e aprendizado profundo para coletar e classificar dados. Seu objetivo é o planejamento e monitoramento da produção. Engloba termos como classificação de informações, conjuntos de dados e nuvens de pontos, conectando técnicas de visão computacional e aprendizado profundo a soluções para o planejamento e monitoramento de produção. O *cluster* verde (9 termos), concentra-se na **gestão da informação**, com um enfoque em técnicas para gestão de facilities e gêmeos digitais, visando o monitoramento e avaliação do desempenho dos ativos. Este agrupamento também aborda processos pós-obra, como gestão de facilities, análises estruturais, gêmeos digitais e indicadores-chave de desempenho, utilizando técnicas de suporte à decisão e análise de multicritérios. O terceiro *cluster*, na cor azul (8 termos) é sintetizado na **mineração de dados** para previsão de riscos. As pesquisas estão focadas em aprendizado supervisionado para identificação de possíveis danos ao longo do ciclo de vida dos ativos, cálculo de matriz de riscos. A Tabela 1 traz uma visão ampla do período de publicações.

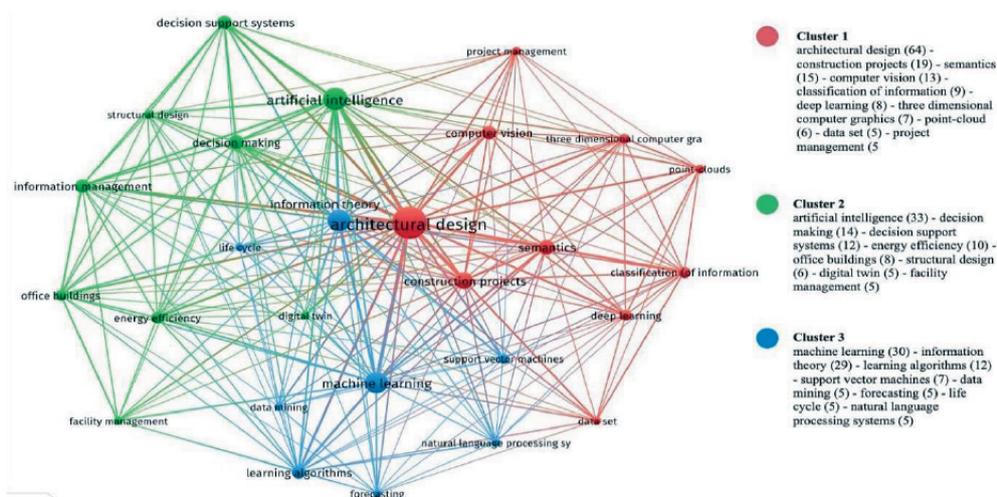
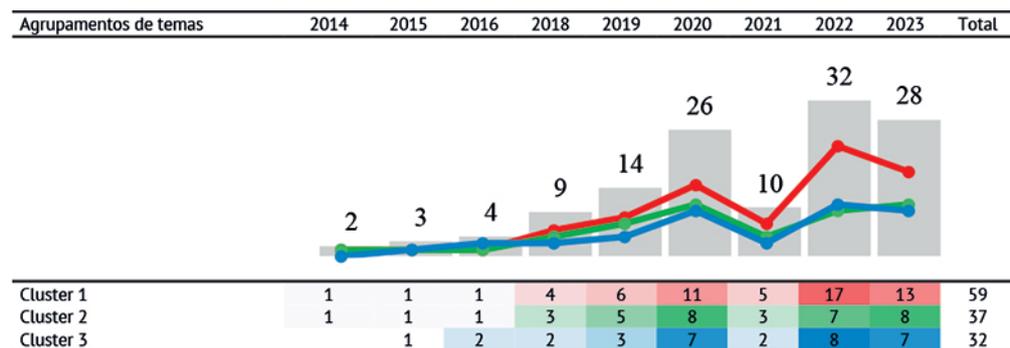


Figura 1
Mapa de co-ocorrência para redes bibliométricas.

Tabela 1: Status geral das publicações, separados por agrupamento de temas



Em termos de inovações tecnológicas, as tendências de pesquisa estão relacionadas à gestão de ativos do ambiente construído, por relação direta à Internet das Coisas (IoT), possibilitadas pela integração do BIM e IA. Isso viabiliza a interconexão de tecnologias para todo o ciclo de vida de um ativo de construção. Entre 2018 e 2020 o enfoque em sistemas de suporte à decisão se concentrou em mineração de dados e aprendizado supervisionado, visando prever riscos, antecipar danos e planejar manutenção para prolongar a vida útil dos ativos de construção.

Os periódicos mais publicados destacam inovações em classificação da informação, design arquitetônico, enriquecimento semântico, gestão e monitoramento, modelagem preditiva e gêmeos digitais. As publicações sugerem o uso de técnicas de IAs em DTs e modelagens BIM para facilitar o monitoramento, manutenção preditiva, e melhorar a gestão sustentável de edifícios.

A frequência em que são utilizadas as diversas técnicas de IA nas publicações é apresentada na Figura 2 e discutida nesta seção. O método bayesiano é destacado na operação e manutenção para prever falhas e otimizar a manutenção preditiva na previsão de falhas e otimização da manutenção preditiva, enquanto as Support Vector Machines são usadas para análise de grandes conjuntos de dados e o Processamento de Linguagem Natural para classificação de informações textuais.

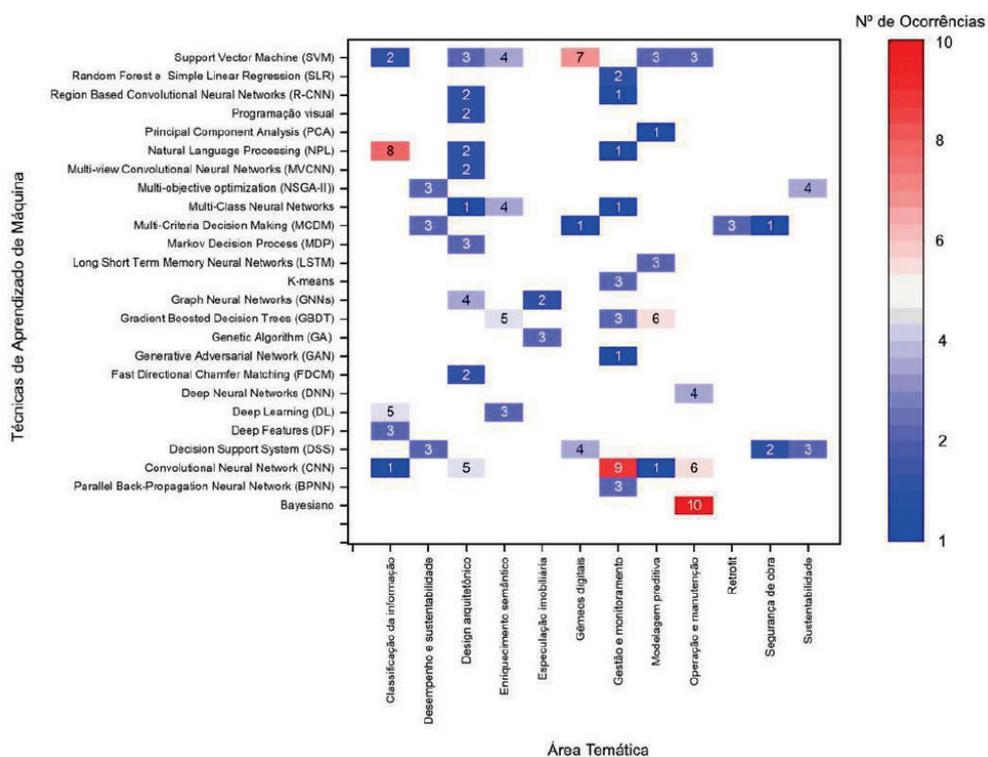


Figura 2
Técnicas de aprendizado de máquina vs tendências científicas.

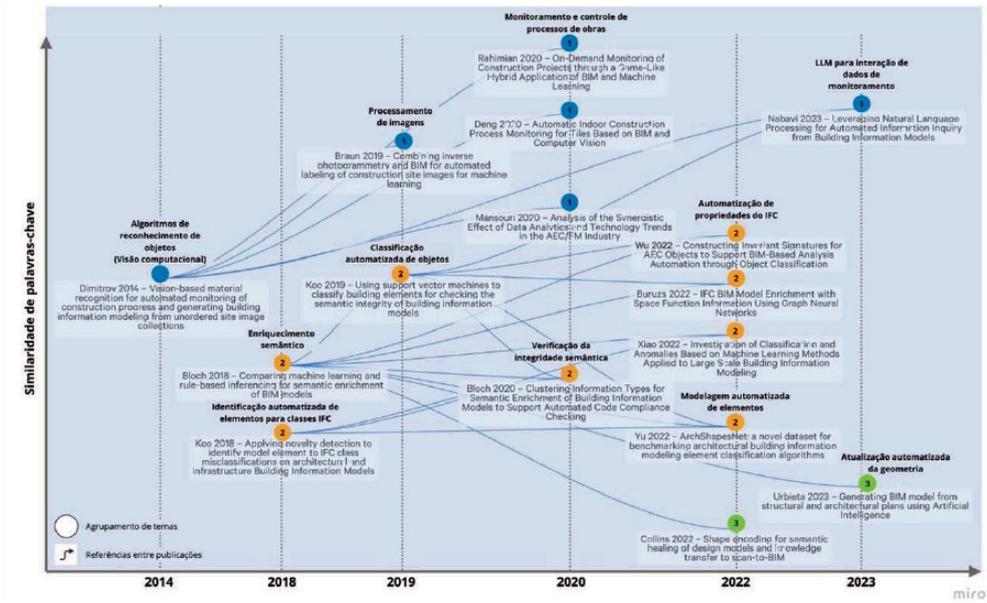
4. Análise qualitativa e discussões

Na presente seção, foi mapeada a progressão das publicações, destacando aplicações, dificuldades e aprendizados adquiridos. As setas representam citações, com início no artigo citante e fim no citado.

4.1. Cluster 1: visão computacional e aprendizado de máquina na indústria 4.0

O Cluster 1 possui 59 artigos, 27 estão interconectados por meio de citações entre publicações do mesmo cluster, formando 3 linhas de pesquisa, demonstradas na Figura 3.

Figura 3
Evolução dos principais artigos do Cluster 1: Classificação da Informação.



4.1.1. Visão Computacional

A visão computacional envolve o desenvolvimento de sistemas capazes de extrair significados de conteúdos e realizar a compreensão avançada[1] de dados visuais, como imagens ou vídeos, buscando a semelhança com a percepção visual humana. No campo da Indústria 4.0, pode ser utilizada em conjunto para inspeção e gestão de pontes[1] e tecnologias de localização e/ou identificação em tempo real [3] por detecção e rotulação de objetos. Com seu desenvolvimento contínuo, essa tecnologia se revela versátil para o monitoramento de processos construtivos [4] e elaboração de planos de prevenção contra riscos [5], mas ainda apresentando limitações de interação em tempo real durante o processo construtivo.

4.1.2. Monitoramento e controle de processos de obras por

A capacidade de identificar pessoas e objetos, coloca a visão computacional numa posição vantajosa em termos de custo-benefício se comparada a sistemas alternativos [6]. Os modelos são capazes de capturar informações geométricas detalhadas por meio de nuvens de pontos e extrair dados semânticos baseados em características visuais [7], permitindo monitorar em tempo real o progresso do canteiro de obra [8]. Entretanto, os avanços ainda estão sujeitos a erros devido à quantidade de informações geradas, como cronogramas e registros visuais.

4.2. Cluster 2: aprendizado supervisionado para gestão de facilities e gêmeos digitais

O Cluster 2 possui 37 artigos, onde 17 estão interconectados por meio de citações entre publicações do mesmo cluster, formando 3 linhas de pesquisa, demonstradas na Figura 4.

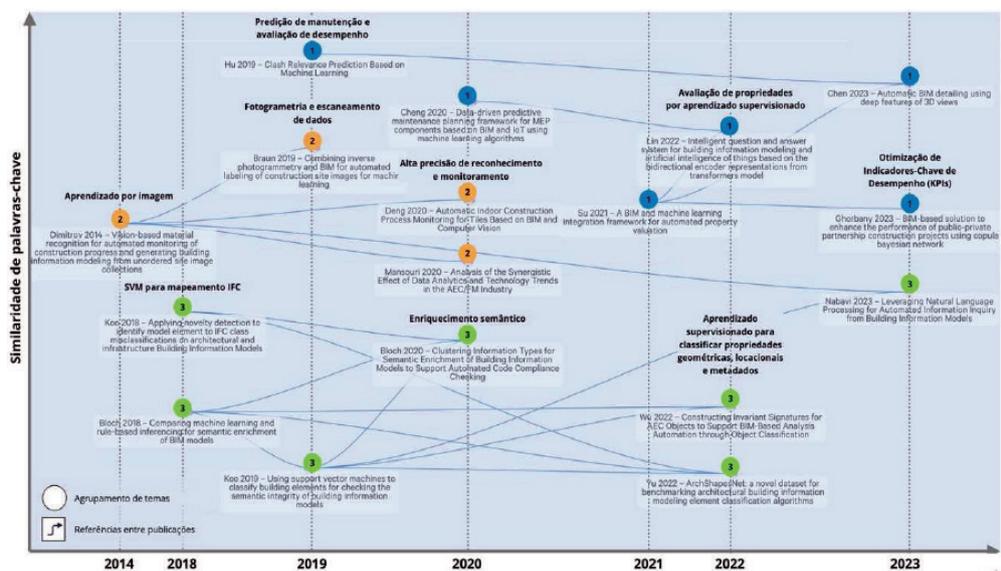


Figura 4
Evolução dos artigos do Cluster 2: Gestão da informação.

4.2.1. Enriquecimento Semântico (SE) e geração automatizada de propriedades do IFC

[9] definem como SE de modelos BIM, todo processo no qual algoritmos enriquecem um elemento com informação específica, compilando dados de arquivos externos. O SE engloba a classificação de objetos de construção e preenchimento de parâmetros [10], sendo uma aposta para adicionar dados e reconstruir modelos geométricos 3D no BIM. [9] propõem intercâmbio IFC através de inferências automatizadas. [10] aplicam a SE a partir de dados de nuvem de pontos. [11] propõem a inferência textual das propriedades de um elementos IFC e [12], por meio de programação visual, detecta danos e estimar a localização e dimensões de um elemento estrutural.

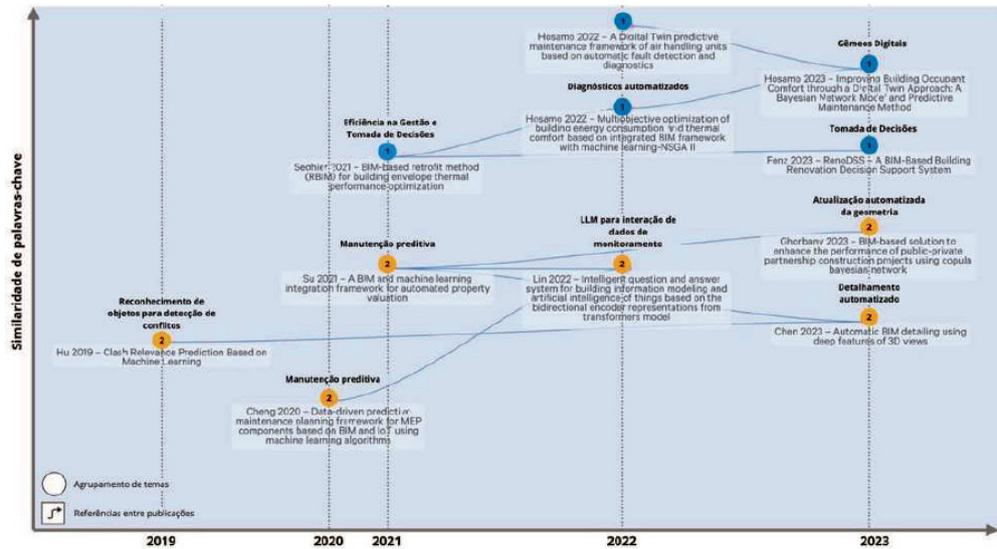
4.2.2. Gêmeos Digitais (DT)

Um gêmeo digital é uma réplica virtual ou modelo digital em tempo real de um objeto físico, processo ou sistema. [1] caracterizam DT como representações digitais de espaços físicos, refletindo as condições do mundo físico, incorporando dados a um modelo de previsões e viabilizando uma análise mais automatizada das condições de um edifício modelado.

4.3. Cluster 3: o aprendizado profundo para predição de eventos na construção

O Cluster 3 possui 32 artigos, 11 estão interconectados por meio de citações entre publicações do mesmo cluster, formando 2 linhas de pesquisa, identificadas na Figura 5.

Figura 5
Evolução dos artigos do Cluster 3: Mineração de Dados e Previsão de Riscos.



4.3.1. Redes Neurais Convolucionais (CNN)

As CNNs são algoritmos de aprendizado profundo usados para processar conjuntos de dados sequenciais e imagens digitais aplicando filtros e análises específicas para análise detalhada. Os autores relatam melhores voltados à gestão de indicadores de desempenho em tempo real para tomadas de decisões estratégicas [24][25] e monitoramento das relações de causa-efeito [15]; Além de reengenharia de processos: como conhecimento da variabilidade de padrões comportamentais e níveis de satisfação dos usuários [16], gestão de conflitos projetuais [17], avaliação predial pós-ocupacional [18] e ergonomia e acessibilidade de projetos [19].

4.3.2. Eficiência na gestão e tomadas de decisão estratégicas para cenários sustentáveis

Os métodos automatizados apoiam a tomada de decisão estratégica, gerando alternativas destinadas a simulação de cenários e planos diretores sustentáveis [20]. A confiabilidade e gestão orçamentária técnicas MCDM são resultados apontados por [21], ao se incluir indicadores de desempenho nesse processo decisório. [22] propõem estruturas de análises automatizadas e [23] propõem um sistema automatizado de apoio à decisão acerca do planejamento de segurança de estruturas temporárias considerando aspectos críticos de custo e produtividade.

4.3.3. Manutenção preditiva

Destaca-se a aplicação de métodos de aprendizagem profunda de algoritmos baseados em dados destinados ao gerenciamento e manutenção de instalações para aquecimento, ventilação e ar-condicionado [24], previsão de condição estrutural de elementos estruturais [25], avaliação de imóveis e manutenção preditiva. Na prática atual, a eficiência da gestão de ativos e tomada de decisão estratégica em tempo

hábil para empreendimentos de engenharia vêm sendo potencialmente utilizados para simulação ágil de cenários e criação alternativas flexíveis.

5. Discussão

As linhas de pesquisa focam na gestão de ativos, incluindo classificação, padronização da informação e mineração de dados. O *cluster* vermelho neste estudo, busca aprimorar o reconhecimento de objetos para facilitar decisões no planejamento e monitoramento da produção. Entretanto a falta de padronização dos dados dificulta o intercâmbio de informações e a precisão dos algoritmos é notadamente prejudicada pela escassez de dados históricos durante o treinamento. Algumas pesquisas sugerem resolver isso com o enriquecimento semântico dos dados, permitindo atualização e treinamento contínuos em tempo real. Entretanto identifica-se a ausência de procedimentos prévios nos casos de estudo, revelando lacunas na validação desses métodos e no investimento de sistemas automatizados de monitoramento.

Adicionalmente, a implementação de sensores é indicada para reduzir custos de prevenção de danos e manutenção. O desenvolvimento desses algoritmos permite a integração com sensores IoT e viabilizam a implementação de DT. Essa abordagem destaca-se pelo *cluster* verde, mitigando desvantagens do monitoramento de ativos, com a inclusão de modelos históricos para acessar e combinar informações. No entanto, o treinamento de uma IA com informações específicas, como medição de degradação e condições atuais, é identificado como um desafio, pois são unicamente baseados em contextos controlados ou recortes de uma única fase do projeto. Portanto, as previsões baseadas em dados podem conter imprecisões ou implicações errôneas, que ainda não foram adequadamente treinadas nos algoritmos. Abordagens alternativas são apresentadas no *cluster* azul, como integração de IAs para medições indiretas e analíticas, ganham aceitação devido à redução de custos e à eficácia nos processos. Alguns autores adotam estratégias de mineração de dados para entender e padronizar os dados primários, visando a eficácia dos algoritmos de IA e a compreensão semântica dos dados para integração futura com big data e DTs.

6. Conclusão

De modo geral, a variedade de pesquisas proporcionou uma visão ampla do cenário atual, permitindo uma compreensão mais aproximada do estado da arte das produções científicas e tecnológicas. As tendências de pesquisa focam na gestão de ativos para gestão para monitoramento de processos de construção, impulsionadas pela necessidade de economia e pela falta de gerenciamento preciso de ativos em tempo real. Os avanços recentes enfatizam inovações na categorização e padronização de ativos ou informações, especialmente em sistemas de facilities, sustentabilidade e gêmeos digitais.

Do ponto de vista científico e tecnológico, houve avanços no desenvolvimento de algoritmos como SVM, CNN e Bayesianos, aplicados a gêmeos digitais, gestão e

monitoramento de produção, e operação e manutenção preditiva. As abordagens evidenciam o enfoque nas fases de construção, projeto e operação, concentrando-se em design arquitetônicos, modelagem preditiva e gêmeos digitais. Esta pesquisa oferece orientações e insights para novos estudos na área, limitando-se à disponibilização das fontes de dados on-line, sem delimitação temporal.

Financiamento

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

Referências

- [1] X. Zhou *et al.*, “Computer Vision Enabled Building Digital Twin Using Building Information Model”, *IEEE Trans. Ind. Inf.*, vol. 19, n.º 3, pp. 2684-2692, 2023, doi: 10.1109/TII.2022.3190366.
- [2] P. Santos, I. Ferreira, B. Cortez, G. Nascimento, e M. T. M. Carvalho, “Pacote de revisão sistemática da literatura - Artigo: ‘Avaliando o Potencial da Integração da Inteligência Artificial ao Building Information Modelling (BIM) na Indústria 4.0’”, fev. 2024, doi: 10.5281/ZENODO.10674728.
- [3] F. Pour Rahimian, S. Seyedzadeh, S. Oliver, S. Rodriguez, e N. Dawood, “On-demand monitoring of construction projects through a game-like hybrid application of BIM and machine learning”, *Autom Constr*, vol. 110, 2020, doi: 10.1016/j.autcon.2019.103012.
- [4] H. Deng, H. Hong, D. Luo, Y. Deng, e C. Su, “Automatic Indoor Construction Process Monitoring for Tiles Based on BIM and Computer Vision”, *J Constr Eng Manage*, vol. 146, n.º 1, 2020, doi: 10.1061/(ASCE)CO.1943-7862.0001744.
- [5] B. Yang, B. Zhang, Q. Zhang, Z. Wang, M. Dong, e T. Fang, “Automatic detection of falling hazard from surveillance videos based on computer vision and building information modeling”, *Struct. Infrastructure Eng.*, vol. 18, n.º 7, pp. 1049-1063, 2022, doi: 10.1080/15732479.2022.2039217.
- [6] W. Xu e T.-K. Wang, “Dynamic safety prewarning mechanism of human-machine-environment using computer vision”, *ECAM*, vol. 27, n.º 8, pp. 1813-1833, jul. 2020, doi: 10.1108/ECAM-12-2019-0732.
- [7] A. Dimitrov e M. Golparvar-Fard, “Vision-based material recognition for automated monitoring of construction progress and generating building information modeling from unordered site image collections”, *Advanced Engineering Informatics*, vol. 28, n.º 1, pp. 37-49, jan. 2014, doi: 10.1016/j.aei.2013.11.002.

- [8] S. Bhokare, L. Goyal, R. Ren, e J. Zhang, “Smart construction scheduling monitoring using YOLOv3-based activity detection and classification”, *ITcon*, vol. 27, pp. 240-252, mar. 2022, doi: 10.36680/j.itcon.2022.012.
- [9] M. Belsky, R. Sacks, e I. Brilakis, “Semantic Enrichment for Building Information Modeling: Semantic enrichment for building information modeling”, *Computer-Aided Civil and Infrastructure Engineering*, vol. 31, n.º 4, pp. 261-274, abr. 2016, doi: 10.1111/mice.12128.
- [10] T. Bloch e R. Sacks, “Comparing machine learning and rule-based inferencing for semantic enrichment of BIM models”, *Automation in Construction*, vol. 91, pp. 256-272, jul. 2018, doi: 10.1016/j.autcon.2018.03.018.
- [11] J. Zhang e N. M. El-Gohary, “Extending Building Information Models Semiautomatically Using Semantic Natural Language Processing Techniques”, *J. Comput. Civ. Eng.*, vol. 30, n.º 5, p. C4016004, set. 2016, doi: 10.1061/(ASCE)CP.1943-5487.0000536.
- [12] B. McGuire, R. Atadero, C. Clevenger, e M. Ozbek, “Bridge Information Modeling for Inspection and Evaluation”, *J. Bridge Eng.*, vol. 21, n.º 4, p. 04015076, abr. 2016, doi: 10.1061/(ASCE)BE.1943-5592.0000850.
- [13] C. Quinn, A. Z. Shabestari, T. Mistic, S. Gilani, M. Litoiu, e J. J. McArthur, “Building automation system – BIM integration using a linked data structure”, *Automation in Construction*, vol. 118, p. 103257, out. 2020, doi: 10.1016/j.autcon.2020.103257.
- [14] S. Ghorbany, E. Noorzai, e S. Yousefi, “BIM-based solution to enhance the performance of public-private partnership construction projects using copula bayesian network”, *Expert Systems with Applications*, vol. 216, p. 119501, abr. 2023, doi: 10.1016/j.eswa.2023.119501.
- [15] Y. Pan e L. Zhang, “BIM log mining: Learning and predicting design commands”, *Automation in Construction*, vol. 112, p. 103107, abr. 2020, doi: 10.1016/j.autcon.2020.103107.
- [16] W.-B. Chiu e L.-M. Chang, “Machine learning multilayer perceptron method for building information modeling application in engineering performance prediction”, *Journal of the Chinese Institute of Engineers*, vol. 46, n.º 7, pp. 713-725, out. 2023, doi: 10.1080/02533839.2023.2238765.
- [17] Y. Hu e D. Castro-Lacouture, “Clash Relevance Prediction Based on Machine Learning”, *J. Comput. Civ. Eng.*, vol. 33, n.º 2, p. 04018060, mar. 2019, doi: 10.1061/(ASCE)CP.1943-5487.0000810.
- [18] H. H. Hosamo, H. K. Nielsen, D. Kraniotis, P. R. Svennevig, e K. Svidt, “Improving building occupant comfort through a digital twin approach: A Bayesian

- network model and predictive maintenance method”, *Energy Build.*, vol. 288, 2023, doi: 10.1016/j.enbuild.2023.112992.
- [19] A. Buruzs, M. Šipetić, B. Blank-Landeshammer, e G. Zucker, “IFC BIM Model Enrichment with Space Function Information Using Graph Neural Networks”, *Energies*, vol. 15, n.º 8, p. 2937, abr. 2022, doi: 10.3390/en15082937.
- [20] J. I. Kim, J. Kim, M. Fischer, e R. Orr, “BIM-based decision-support method for master planning of sustainable large-scale developments”, *Autom Constr.*, vol. 58, pp. 95-108, 2015, doi: 10.1016/j.autcon.2015.07.003.
- [21] M. Mohammadi, M. Rashidi, Y. Yu, e B. Samali, “Integration of TLS-derived Bridge Information Modeling (BrIM) with a Decision Support System (DSS) for digital twinning and asset management of bridge infrastructures”, *Computers in Industry*, vol. 147, p. 103881, maio 2023, doi: 10.1016/j.compind.2023.103881.
- [22] L. Chen e W. Pan, “BIM-aided variable fuzzy multi-criteria decision making of low-carbon building measures selection”, *Sustainable Cities Soc.*, vol. 27, pp. 222-232, 2016, doi: 10.1016/j.scs.2016.04.008.
- [23] K. Kim, Y. Cho, e K. Kim, “BIM-Driven Automated Decision Support System for Safety Planning of Temporary Structures”, *J. Constr. Eng. Manage.*, vol. 144, n.º 8, p. 04018072, ago. 2018, doi: 10.1061/(ASCE)CO.1943-7862.0001519.
- [24] Y. Achour, A. Ouammi, e D. Zejli, “Model Predictive Control Based Demand Response Scheme for Peak Demand Reduction in a Smart Campus Integrated Microgrid”, *IEEE Access*, vol. 9, pp. 162765-162778, 2021, doi: 10.1109/ACCESS.2021.3132895.
- [25] H. H. Hosamo e M. H. Hosamo, “Digital Twin Technology for Bridge Maintenance using 3D Laser Scanning: A Review”, *Advances in Civil Engineering*, vol. 2022, pp. 1-15, jul. 2022, doi: 10.1155/2022/2194949.