



Indústria 5.0: Oportunidades e Desafios
para Arquitetura e Construção

13º Simpósio Brasileiro de Gestão e
Economia da Construção e 4º Simpósio
Brasileiro de Tecnologia da Informação
e Comunicação na Construção

ARACAJU-SE | 08 a 10 de Novembro

1^o INTELIGÊNCIA ARTIFICIAL PARA AUTOMAÇÃO DE ESTIMATIVA DE CUSTO EM PROJETO ARQUITETÔNICO: UMA REVISÃO SISTEMÁTICA

Artificial Intelligence in Cost Estimation Automation for Architectural Design: a Systematic Literature Review

Ana Beatriz Mourão Ferreira Gomes
UFC | Fortaleza, Ceará | mourao.anabeatriz@gmail.com

Leo Souza de Castro
UFC | Fortaleza, Ceará | leo.scastro42@gmail.com

Letícia Pereira Barcelos Ribeiro
UFC | Fortaleza, Ceará | leticiabarcelosarq@gmail.com

Mariana Monteiro Xavier Lima
UFC | Fortaleza, Ceará | mariana@daud.ufc.br

RESUMO

O custo é um fator importante na definição da viabilidade de projeto. Por isso, compreender o impacto das decisões projetuais no custo auxilia o arquiteto a realizar escolhas melhor embasadas. Analisando o recente avanço das tecnologias envolvendo Inteligência Artificial (IA) na arquitetura, supõe-se a IA como um potencial meio de solução. Neste contexto, foi realizada uma revisão sistemática da literatura (RSL) no repositório do Portal Periódicos CAPES para entender como a inteligência artificial pode ser implementada para automatização da estimativa de custos no processo de projeto. Com isso, foram desenvolvidos o mapeamento dos principais parâmetros de custo e a documentação das capacidades das IAs estudadas na arquitetura, bem como suas limitações. Por fim, realiza-se um comparativo de desempenho e propõe-se direcionamentos para futuras pesquisas. Assim, os resultados apontam que, por meio da IA, é possível obter um mecanismo de predição de custo adequado para o arquiteto, uma vez entendida a relação entre os recursos necessários e o nível de precisão pretendido.

Palavras-chave: Inteligência Artificial; Estimativa de custos; Projeto arquitetônico; Revisão sistemática da literatura.

ABSTRACT

Cost is an important factor in determining project viability. Therefore, understanding the impact of design decisions on cost helps architects make better-informed choices. Considering the recent advancements in Artificial Intelligence (AI) technologies in architecture, AI is seen as a potential solution. In this context, a systematic literature review (SLR) was conducted on the Portal Periódicos CAPES repository to understand how AI can be implemented to automate cost estimation in the design process. The study maps the main cost parameters and documents the capabilities of the AI studied in architecture, as well as their limitations. Finally, a performance comparison is made, and directions for future research are proposed. The results indicate that, through AI, it is possible to obtain a suitable cost prediction mechanism for architects, once the relationship between required resources and the desired level of precision is understood.

Keywords: Artificial Intelligence; Cost estimation; Architecture design; Systematic Literature review.

1 INTRODUÇÃO

A concepção de um projeto é, muitas vezes, restringida e guiada pelo seu orçamento. Essa realidade cria uma problemática esboçada pela Curva de MacLeamy: os custos de mudanças no projeto aumentam conforme seu desenvolvimento, e dessa forma o processo de projeto preferível corresponde a mais decisões estabelecidas antecipadamente. Entretanto, as informações do projeto durante o processo de tomada de decisão são limitadas. Portanto, o planejamento dos custos em sua fase inicial não engloba vários aspectos relevantes em fases posteriores, apesar das escolhas projetuais nesse estágio de concepção terem efeitos consideráveis sobre os custos posteriormente no projeto (Yang et al, 2022).

Nesse contexto, o Modelo de Informação da Construção (*Building Information Modeling - BIM*), apresenta-se como um aliado na gestão da informação. Em termos de estimativa de custos, o BIM é capaz de integrar as informações de materiais de construção, quantidades, propriedades, entre outras que são vinculadas ao banco de dados para estimar o custo geral do projeto (Lee et al., 2022, apud Ramaji et al., 2018). Entretanto, métodos

¹GOMES, A. B. M. F. *et al.* Inteligência artificial para automação de estimativa de custo em projeto arquitetônico. In: SIMPÓSIO BRASILEIRO DE TECNOLOGIA DA INFORMAÇÃO E COMUNICAÇÃO NA CONSTRUÇÃO, 4., 2023, Aracaju. **Anais [...]**. Porto Alegre: ANTAC, 2023.

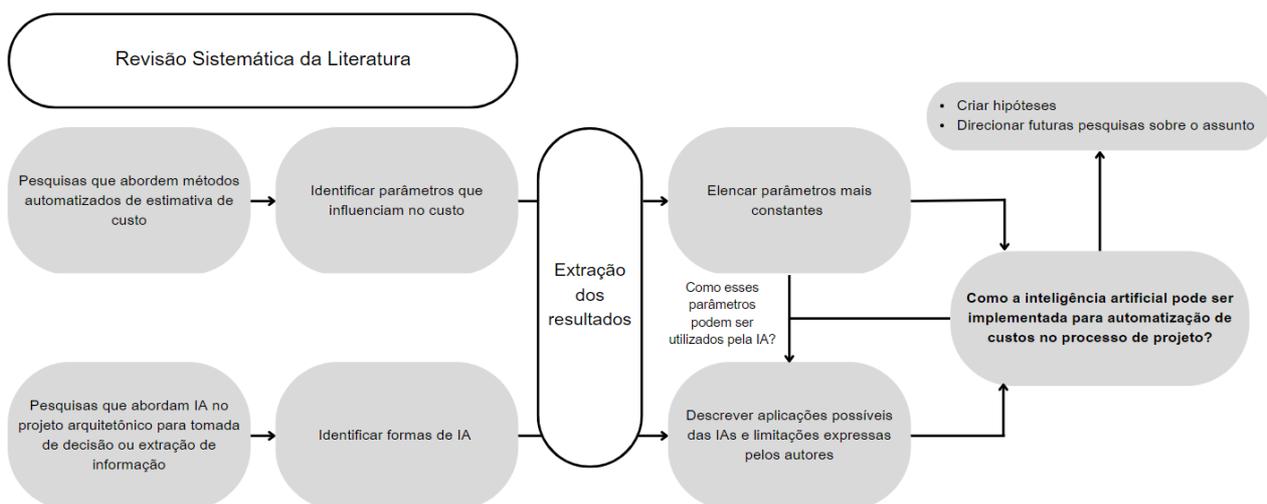
de estimativa de custo baseados em BIM são limitados aos próprios modelos, negando o apoio da informação em fases mais esquemáticas (Lee et al., 2022).

A Inteligência Artificial (IA) e, particularmente, o aprendizado de máquina (AM), é um campo emergente (AS, PAL e BASU; 2018) que tem tido aplicações em diversas áreas, inclusive na arquitetura. A IA já causa impacto no meio arquitetônico, principalmente nos ambientes acadêmicos que usufruem de suas variedades de aplicação (LEACH, 2022). As experimentações na criatividade, síntese e otimização usando essa tecnologia contribuem para um significativo acervo de pesquisas que vem crescendo nos últimos anos. Em vista de seu desenvolvimento significativo recente, demonstrando muitas capacidades potenciais, ela tem sido considerada uma alternativa para resolver problemáticas complexas de maneira eficaz, tal qual a necessidade de compreender o impacto das decisões projetuais no custo. Zhao et al. (2020), por exemplo, argumentam que se a função de visualização e processamento de dados do BIM puder ser combinada com a IA para estimar e prever custos, a eficiência da previsão de custos será aprimorada profundamente. Partindo disso, a presente pesquisa tem como objetivo entender como a IA pode ser implementada para automatização da estimativa de custos no processo de projeto. Para isso, é feita uma Revisão Sistemática da Literatura (RSL) buscando por: (a) pesquisas em automatização de estimativa de custo com o fim de levantar os parâmetros considerados relevantes no custo; e (b) pesquisas que usam IA no auxílio de algum processo em projetos de edificações a fim de compreender e destacar as principais utilidades da IA. Assim, foi possível descrever como utilizar a IA para automatizar estimativas de custos no processo de projeto, propondo direcionamentos no campo de estudo para futuras pesquisas.

2 METODOLOGIA

Esta pesquisa tem caráter exploratório com a finalidade de construir hipóteses e direcionar pesquisas futuras. Para tanto, foi realizada uma RSL. A RSL foi dividida em duas vertentes: (1) identificar métodos automatizados de estimativa de custo, elencando parâmetros de maior influência e (2) identificar diferentes IAs e suas formas de uso em projeto arquitetônico. Realiza-se, em cada uma, a extração dos resultados procurados: o mapeamento dos principais parâmetros de custo (baseado na recorrência nos estudos) e a documentação das funcionalidades (capacidades e limitações) das IAs presentes ao longo da revisão. As proposições seguintes a essa etapa partem da análise dos resultados obtidos na tentativa de explorar sobre como a IA pode ser implementada para automatização de custo no processo de projeto. O delineamento da RSL está ilustrado na Figura 1.

Figura 1: Delineamento da RSL



Fonte: Os autores.

Durante buscas iniciais foram observados termos de busca frequentes e relevantes para o objetivo deste artigo, bem como temáticas comuns da literatura exposta, como 'eficiência energética'. Com isso, conhecendo melhor o universo de resultados da busca, desenvolveu-se este protocolo norteador dos termos de busca, visto no Quadro 1, de forma a filtrar pesquisas relevantes de forma abrangente e não enviesada.

Quadro 1: Protocolo de pesquisa

PROTOCOLO DA RSL		
RECORTE ESPACIAL	pesquisas no ramo de arquitetura ou construção civil nacional ou internacional	
RECORTE TEMPORAL	2013 a 2023	
IDIOMAS	Inglês e Português	
CRITÉRIOS DE BUSCA	Critérios de inclusão: pesquisas que apresentem meios computacionais de automatização de custos de projetos de edificação; pesquisas que apliquem IA para tomada de decisão em projeto arquitetônico; pesquisas que apliquem IA para extração de informação em projeto arquitetônico; pesquisas que são RSL sobre aplicação de IA na arquitetura	
CRITÉRIOS DE BUSCA	Critérios de exclusão: pesquisas fora do contexto do projeto arquitetônico; pesquisas que não abordam métodos computacionais para automatização de custos; pesquisas focadas em problemáticas de eficiência energética; pesquisas com problemáticas de design muito particulares	
TERMOS DE BUSCA	Vertente 1	BIM and cost prediction; automatic cost estimation in building; LOD in cost estimation; BIM and cost prediction; building construction cost estimation; cost prediction in building projects.
	Vertente 2	Genetic Algorithm architect*; "Artificial Intelligence" architectural design.
FONTES	Periódicos CAPES.	

Fonte: Os autores.

Referente a isso, destaca-se que:

- (1) O recorte temporal fica restrito em vista da evolução rápida da tecnologia estudada, deixando pesquisas mais antigas num estado defasado para os fins deste artigo.
- (2) Apesar das buscas em inglês e português, não houve resultados selecionados em português.
- (3) É importante destacar que os resultados nos gráficos e quadros deste artigo usam apenas dados extraídos diretamente das pesquisas primárias selecionadas, não considerando pesquisas abordadas nas RSLs estudadas para extração de dados.
- (4) As problemáticas de eficiência energética tiveram a maior aparição nas buscas, entretanto trabalhavam contextos e soluções normalmente semelhantes e sem ligação ao objetivo da pesquisa, logo foram desconsideradas. Por sua vez, o 4º critério refere-se a artigos que envolviam o uso de IA em situações específicas de design, como fachadas ou elementos arquitetônicos formalmente complexos. As soluções propostas frequentemente envolviam uma IA treinada ou modificada especificamente para resolver esses peculiares problemas formais, o que não agrega no objetivo da presente pesquisa e, por isso, pesquisas desse caráter foram desconsideradas.

3 RESULTADOS

No Quadro 2, os resultados da busca são expostos. É revelado quantas pesquisas apareceram no total (resultados), quantas foram selecionadas em uma primeira triagem baseada por título e resumo (pré-selecionados) e quantas foram selecionadas para análise da RSL, após uma leitura de seus conteúdos (selecionados).

Quadro 2: Buscas em inglês no Periódicos Capes

TERMOS DE BUSCA	PERIÓDICOS CAPES	
BIM AND BUILDING COST ESTIMATION	RESULTADOS	165
	PRÉ-SELECIONADOS	7
	SELECIONADOS	3
AUTOMATIC COST ESTIMATION IN BUILDING	RESULTADOS	105
	PRÉ-SELECIONADOS	2
	SELECIONADOS	0
LOD IN COST ESTIMATION	RESULTADOS	112
	PRÉ-SELECIONADOS	1
	SELECIONADOS	1
BIM AND COST PREDICTION	RESULTADOS	67
	PRÉ-SELECIONADOS	3
	SELECIONADOS	2
BUILDING CONSTRUCTION COST ESTIMATION	RESULTADOS	352
	PRÉ-SELECIONADOS	9
	SELECIONADOS	5
COST PREDICTION IN BUILDING PROJECTS	RESULTADOS	163
	PRÉ-SELECIONADOS	5
	SELECIONADOS	2
	RESULTADOS	162

GENETIC ALGORITHM ARCHITECT*	PRÉ-SELECIONADOS	85
	SELECIONADOS	3
"ARTIFICIAL INTELLIGENCE" ARCHITECTURAL DESIGN	RESULTADOS	134
	PRÉ-SELECIONADOS	20
	SELECIONADOS	4
TOTAL DE PESQUISAS SELECIONADAS		20

Fonte: Os autores.

Dos 20 artigos selecionados, 13 foram da vertente 1, de automatização da estimativa de custos, e 7 da vertente 2, IA em projetos. Os resultados da vertente 1 se condensam em forma de quadro enquanto na vertente 2 é realizada uma análise dos casos da literatura selecionada, que ao final geram um quadro.

3.1 AUTOMATIZAÇÃO DA ESTIMATIVA DE CUSTOS

Elmousalami (2021) explica que a modelagem preditiva consiste em dois estágios principais: engenharia de recursos e desenvolvimento do modelo. A engenharia de recursos é selecionar os principais direcionadores de custo como entrada para calcular o custo do projeto, enquanto o desenvolvimento do modelo é aplicar técnicas de aprendizado estatístico para conhecer o padrão entre os principais direcionadores de custo e o custo final do projeto. Assim, entende-se a importância da definição dos parâmetros de custo a serem utilizados como "input" para alimentar o modelo. Com essas considerações, foi elaborado o Quadro 2, em que são mapeados os principais parâmetros identificados em cada texto estudado.

Quadro 2: Parâmetros identificados nos textos selecionados

TEXTO	PARÂMETROS DE CUSTO								
	HORIZ.	VERT.	VOL.	ÁREA M.	Nº UNI.	ACAB.	INSTAL.	EST.	OUTROS
WOOD, J. et al (2014)	área		volume		quantidade de elementos				localização / orientação / custo unitário
SHIN, Y. (2015)	área bruta de piso	altura do piso / andares / andar do porão	área de construção		número de classes / níveis escolares				orçamento / aquisição de terrenos
WANG, W. C. et al (2017)						acabamentos externos / acabamentos internos / portas e janelas	mecânico/ elétrico/ encanamento	fundação / tipo de estrutura	instalações temporárias / lucro / paisagismo / elevadores
JIANG, Q. (2020)						alvenaria	tubos de drenagem / tubulação elétrica enterrada	concreto / barra de aço	abastecimento interno de água
LEE, J. et al (2020)	área		volume						esboço do projeto /

									informações espaciais
ZHAO, L. et al (2020)		pisos de edifícios	área de construção			taxa de portas e janelas		formulário de fundação	administração da obra / tipo de casa-unidade
DOBRUCALI; DEMIR (2021)	área do piso	área vertical portadora	área total interna	área úmida					área total da parede exterior
FAZELI, A. et al (2021)	área total	comprimento total	volume total						materiais utilizados na construção / custo unitário de cada item
PHAM, T. Q. D. et al (2023)		número de andares / altura do piso		área da cozinha				profundidade do piso	
MIRANDA, S. L. C. et al (2022)	área bruta de piso	número de andares			número de unidades / número de residências por andar	tipo de telhado		tipo de fundação / tipo de estrutura	duração da obra / localização / número de elevadores
YANG, S. W. et al (2022)	área do piso / área do sítio	número máximo de andares / número máximo de pisos subterrâneos	área de construção						área de paisagismo / número de vagas de estacionamento
PARK, U. et al (2022)	área bruta de piso	altura do edifício /	área de construção						número de vagas de [...]
TEXTO	PARÂMETROS DE CUSTO								
	HORIZ.	VERT.	VOL.	ÁREA M.	Nº UNI.	ACAB.	INSTAL.	EST.	OUTROS
PARK, U. et al (2022)	[.]	/ número de andares / número de pisos de base	[.]						[...] estacionamento
WANG, Y. et al (2023)	área total do piso	número de andares / altura							
TOTAL	10	16	8	2	5	6	4	8	

Fonte: Os autores.

Através dessas informações, é possível relatar algumas considerações especiais:

- (1) A organização do Quadro 4 foi feita de modo que os parâmetros levantados foram agrupados nas seguintes categorias: Horizontal; Vertical; Volume; Área Molhada; Quantidade de Unidades; Acabamentos; Instalações; Estruturação; e Outros, para aqueles sem pertencimento a alguma das categorias especificadas.
- (2) Alguns parâmetros podem não se encaixar em uma única categoria porque indicam a relação de múltiplos fatores.
- (3) Como pode-se notar por Shin (2015), que realizou um estudo exclusivamente de edifícios escolares, a tipologia arquitetônica tem impacto direto na definição de parâmetros de custo. Isso se evidencia, por exemplo, pela presença do parâmetro “níveis escolares”, mensurador da quantidade de níveis educacionais existentes (fundamental I, fundamental II e ensino médio), impactando assim no maior número de unidades e no tamanho geral da edificação.

- (4) Alguns parâmetros, apesar de serem nomeados de maneira diferente pelos autores, possuem o mesmo significado. Como é o caso de “altura” definido por Wang et al (2023) e “altura do edifício” definido por Park et al (2022).

Logo, espera-se que o levantamento de parâmetros, bem como sua respectiva categorização, facilite o processo de escolha dos insumos alimentadores de máquina. Miranda et al (2022) explicam que ao seguir métodos de identificação de parâmetros mais rígidos, usando melhores dados e tomando as devidas considerações de poder preditivo, os modelos produzem previsões mais confiáveis.

3.2 INTELIGÊNCIA ARTIFICIAL EM PROJETOS

As, Pal e Basu (2018) uniram grafos e IA para sintetizar novos designs funcionais de residências. Modelos BIM de 15 diferentes casas foram transformados em grafos, que apresentam capacidade de representar relacionamentos entre componentes do sistema superior àquela de uma imagem. Além disso, foram atribuídos manualmente aos modelos os valores de dois parâmetros de medição de conforto. Uma *Convolutional Neural Network* (CNN) foi treinada usando os dados de design rotulados das várias casas em forma de grafos. Com isso, a CNN foi usada para descobrir os subgrafos dos constituintes do design. A partir disso, um outro tipo de IA, *Generative Adversarial Network* (GAN), foi utilizada para gerar novos designs de qualidade satisfatória, com boas pontuações de conforto.

Ekici et al (2019) realizaram uma RSL com pesquisas cujo processo envolvia geração de forma, avaliação da performance e otimização do design. Como parte dos critérios, elas utilizam *Swarm Intelligence* e *Evolutionary Computing*, algoritmos metaheurísticos usados para otimização de performance. Quatro categorias foram atribuídas aos diferentes artigos estudados: Sustentabilidade, Custo, Funcionalidade e Estrutura, cada uma com suas subcategorias. Para os fins desta revisão, apenas os resultados de Custo serão comentados. Em seus resultados, foi constatado que os métodos mais utilizados foram Algoritmos Genéticos (GA) e *Non-dominated Sorting Genetic Algorithm II* (NSGA-II), além do uso de *Particle Swarm Optimization* (PSO), *Multi-objective Genetic Algorithm* (MOGA), *Multi-objective Particle Swarm Optimization* (MOPSO) e *Multiple-criteria Genetic Algorithm* (MCGA), nesta ordem. As otimizações incluíram, principalmente, a minimização de custo de aspectos construtivos e a maximização de aspectos de qualidade de vida. Foram, também, levantados 20 parâmetros formais e 21 parâmetros não formais usados pelas IAs nos artigos, dentre os quais 11 e 16, respectivamente, observados na categoria de Custo.

Em 2021, Castro Pena et al realizaram uma RSL em que relatam pesquisas sobre IA aplicada no design arquitetônico. Pelos produtos dessa revisão nota-se o crescimento do número de publicações entre 2015 e 2019 de 85%; a predominância de *Evolutionary Computing* (EC) como método de IA (73%), e dessas pesquisas, 89% aplicaram GAs; uma mudança de tendência de exploração de design em anos passados para otimização da forma, melhorando um design já existente. Por fim, concluem que a criação de soluções de *Interactive Evolutionary Computing* (IEC) pode facilitar a customização de design para atender requisitos específicos do usuário. Os autores afirmam acreditar que o uso de *Deep Learning*, em especial em combinação com *Artificial Neural Network* (ANN), bem como a aplicação de novos paradigmas em sistemas criativos podem abrir novos caminhos na área.

Lian, Wang e Hu (2022) experimentaram a criação de um problema com ANN. Buscando melhorar a performance de ventilação de um conjunto residencial, trabalham na transformação de um problema real para um problema matemático adequado para uma rede neural. É afirmado que através do treinamento de um determinado número de amostras, uma rede neural usando *backpropagation* pode obter a relação linear e não linear entre alguns atributos ou características. Para formar a amostra de treinamento da inteligência, articulam possíveis parâmetros que possam traduzir esse problema, tomando como objetivo a otimização da ventilação interna. Selecionando as variações com exemplos extremos e outros randômicos, é criada uma tabela de 9 grupos distintos de parâmetros que são, então, treinados pela rede neural, retornando com os valores otimizados de performance.

Zhang e Zhang (2022) propuseram o uso de um algoritmo multi-objetivo *Harmony Search* (HS) para o design de estruturas de concreto de baixa emissão de carbono e com eficiência de custo. Foi feita uma análise para determinar os componentes que mais contribuem nesses quesitos em custo e emissão de CO₂. Com isso, foi possível elencar os processos principais e a contribuição de cada subprojeto. A estrutura se torna o foco principal de otimização, sendo estudados seus elementos estruturais. A maior relevância foi dada aos pilares,

logo, foi o elemento otimizado. Após a otimização pelo algoritmo, reavaliou-se o novo esquema a partir dos componentes otimizados ciclicamente, até chegarem a uma solução satisfatória.

Shishehgarkhaneh et al (2022) pesquisaram sobre a aplicação de um algoritmo metaheurístico chamado Fire Hawk Optimizer (FHO) na otimização da relação tempo-custo-qualidade-risco-emissão de CO2 em um projeto. Realiza-se um estudo de caso para comparação e avaliação de desempenho do FHO e outros 5 algoritmos (*Firefly Algorithm (FA)*, *Multi-Verse Optimizer (MVO)*, PSO, *Symbiotic Organisms Search algorithm (SOS)* e *Teaching-learn Based Optimization (TLBO)*). Apesar do maior tempo computacional entre todos os algoritmos, o FHO obteve as melhores otimizações em todos os quesitos, exceto qualidade.

Lu et al (2022) propuseram uma integração de design paramétrico e métodos de otimização. Uma GAN é utilizada para simular a performance de luz e temperatura de uma fachada de diagrama de Voronoi, paralelamente ao método tradicional de modelagem paramétrica. Para o método tradicional estimou-se 1500 horas para gerar as amostras necessárias, enquanto a GAN concluiu todas em 105 horas. Com as diversas amostras de diferentes performances, usou-se GA para encontrar a solução mais otimizada.

A partir da análise das publicações vistas, o Quadro 3 explicita as principais capacidades e limitações extraídas. Ressalta-se, ainda, que os métodos levantados são apenas os utilizados nos trabalhos avaliados. A subcategoria “Genérico” diz respeito ao método de forma geral, no que foi observado em comum entre as outras subcategorias.

Quadro 3: Funcionalidades dos métodos de IA estudados

MÉTODOS DE IA ESTUDADOS			FUNCIONALIDADES	
			CAPACIDADES PRINCIPAIS	LIMITAÇÕES PRINCIPAIS
ARTIFICIAL NEURAL NETWORK	DEEP NEURAL NETWORK	GENÉRICO	As DNNs têm habilidades de aprendizado e memória e têm sido usadas com sucesso na análise e modelagem de vários tipos de problemas.	Necessitam de muitos dados iniciais e de qualidade para operarem.
MÉTODOS DE IA ESTUDADOS			FUNCIONALIDADES	
			CAPACIDADES PRINCIPAIS	LIMITAÇÕES PRINCIPAIS
ARTIFICIAL NEURAL NETWORK	DEEP NEURAL NETWORK	CNN	Uma CNN realiza a extração de recursos dos dados de entrada, é aplicada sobretudo no processamento, análise e classificação de imagens digitais.	Pode detectar, reconhecer e classificar informações existentes, mas não é capaz de sintetizar novos modelos a partir delas.
		GAN	Ambos aprendizado e geração de imagens podem ser conduzidos; Utilizada no aprendizado e previsão de imagens, com aplicações em síntese de imagens, edição de imagens, transferência de estilo, super-resolução de imagens, transformação de imagens, aprimoramento de dados, etc.	O processo de treinamento é muito mais complexo e difícil, sendo mais capaz de gerar problemas (colapsos, falhas nos resultados, etc.)
ALGORITMOS META-	BASEADO EM EVOLUÇÃO	GA	Algoritmo de otimização mais recorrente em pesquisas.	Gera só uma nova solução usando as informações de duas soluções-pai; Não sucede com frequência em problemas com muitos elementos; não otimiza mais de um aspecto simultaneamente.
		MOGA	Soluções de melhor qualidade ao longo das gerações (comparado a GA); Capaz de otimizar mais de um aspecto simultaneamente.	Complexidade computacional alta.

HEURÍSTICOS		NSGA-II	Soluções de melhor qualidade ao longo das gerações (comparado a GA); Capaz de otimizar mais de um aspecto simultaneamente.	Tempo de processamento maior; Menos eficiente com problemas complexos;
	BASEADO EM ENXAMES	PSO	Gera maior diversidade de resultados	(não apresentado)
		MOPSO	Gera maior diversidade de resultados	Complexidade computacional alta.
ALGORITMOS META-HEURÍSTICOS	BASEADO NA FÍSICA	HS	Algoritmo simples e de implementação fácil; novas soluções geradas a partir de todas as soluções no espaço.	(não apresentado)
	BASEADO NA NATUREZA	FHO	Apresentou as melhores otimizações em 4 de 5 categorias estudadas em comparação a 5 outros algoritmos.	Tempo computacional muito maior; Complexidade computacional alta.

Fonte: Os autores.

Admite-se, também, que características não citadas de diferentes IAs não fazem parte do quadro, cujas lacunas são preenchidas apenas com informações ou conclusões advindas diretamente da RSL. Logo, mais limitações e capacidades relevantes podem estar ocultas, somente sendo levantadas em experimentações práticas não executadas por este presente artigo.

3.3 DISCUSSÕES

Para o bom funcionamento de uma IA, as amostras para treinamento precisam de certa coesão entre si para o entendimento da IA sobre relações subjetivas na construção. Um bom modelo de classificação depende de um conjunto de recursos com alta correlação. Remover recursos irrelevantes pode não apenas melhorar a precisão do modelo, mas também reduzir o tempo de execução (LIAN, WANG e HU; 2022). Isso indica, entretanto, que um algoritmo treinado absorve características da arquitetura pertencentes a um tempo, local, cultura, classe, tipologia, entre outros aspectos, e portanto tem melhor capacidade de analisar e avaliar casos semelhantes. Torna-se inviável, em vista disso, conceber uma forma de universalizar a estimativa de custos e de analisar e avaliar precisamente inovações arquitetônicas.

Outra consideração ao utilizar essa tecnologia é a relação custo-benefício entre a precisão de estimativa e o custo e o tempo computacional necessários. Wang et al (2023) explica que muitas condições no modelo de previsão de custos não apenas aumentam o custo, o tempo e a complexidade computacional, mas também aumentam a necessidade de amostras no treinamento. Um valor elevado de custo computacional na implementação da IA para predição de custos pode não ser um investimento viável. O tempo computacional de todo o processo da IA pode ser mais eficiente em comparação a outros métodos, como demonstrado por Lu et al. (2022). Entretanto, fatores diversos o influenciam, como adição de funções, uso de modelos mistos, quantidade de parâmetros e a precisão desejada. É necessário, dessa forma, avaliar se o tempo necessário para alcançar os objetivos desejados é compensatório.

Em adição, o conhecimento em programação e arquitetura, simultaneamente, é requerido para desenvolver os algoritmos. Para além dos códigos, a transformação do problema prático em problemas matemáticos, capazes de serem processados pela IA, exige uma grande compreensão e examinação do problema em si (LIAN, WANG e HU; 2022). Isso inclui características qualitativas, que, de acordo com As, Pal e Basu (2018), também são parâmetros usáveis. No mais, mesmo com o conhecimento necessário, a extração de amostras de treinamento pode requerer muitos dados, ou seja, a carência de informações compartilhadas na arquitetura devido à competitividade do mercado pode criar a necessidade de ter um banco de dados próprio.

Consideradas as restrições atuais da tecnologia e as funcionalidades levantadas na RSL, é possível construir uma hipótese sobre a possibilidade de utilizar a IA para visualizar o impacto no custo gerado pelas escolhas do arquiteto. As categorias de parâmetros mais relevantes levantadas foram: Vertical (16), Horizontal (10), Estrutura (8) e Volume (8). Assim, parâmetros básicos referentes a essas categorias podem ser extraídos, permitindo a estimativa ser usada mesmo durante fases de baixo nível de desenvolvimento. Nisso, supõe-se que uma DNN seria mais adequada para a hipótese, a exemplo do uso de CNN na pesquisa de As, Pal e Basu (2018), cuja capacidade de prever as pontuações de conforto dos edifícios é paralela à capacidade de prever uma pontuação de custo. A máquina seria treinada com modelos BIM associados ao custo final, seja ele de forma qualitativa (em níveis de custo, exigindo menos precisão), preferencialmente, ou quantitativa (valores finais reais, exigindo mais treinamento e mais amostras iniciais de treinamento). Idealmente, ao final do treinamento seria possível entregar à IA um modelo BIM, ao passo em que ela devolveria o nível do custo ou valor de custo final estimado com precisão satisfatória. Logo, à medida que decisões projetuais são tomadas, seria possível obter respostas rápidas ao efeito delas no custo e, conseqüentemente, o arquiteto teria um melhor embasamento para manejar suas escolhas.

4 CONCLUSÃO

Neste artigo foi realizada uma RSL com duas vertentes, (1) métodos automatizados de estimativa de custo e (2) diferentes IAs e suas formas de uso em projeto arquitetônico. As contribuições corroboram para a elaboração de novas pesquisas, uma vez que constituem os princípios-base da engenharia de recursos e do desenvolvimento de modelo, citados por Elmousalami (2021), como parte da modelagem preditiva. Exposto isso, é levantada uma hipótese sobre como a inteligência artificial pode ser implementada para automatização da estimativa de custos no processo de projeto. Essa hipótese se constitui no uso de DNNs para prever o custo de modelos arquitetônicos em fases iniciais de projeto, embasando melhor as escolhas do arquiteto.

AGRADECIMENTOS

Agradecemos ao apoio e financiamento da Funcap e do CNPQ através da concessão de bolsas de Iniciação Científica para a realização deste trabalho.

REFERÊNCIAS

- AS, Imdat; PAL, Siddharth; BASU, Prithwish. Artificial intelligence in architecture: Generating conceptual design via deep learning. **International Journal of Architectural Computing**, 2018, v. 16 (4), p. 306–327. Disponível em: <<https://journals.sagepub.com/doi/full/10.1177/1478077118800982>>. ISSN: 1478-0771. DOI:<<https://doi.org/10.1177/1478077118800982>>.
- DOBRUCALI, Esra; DEMIR, Ismail Hakki. A simple formulation for early-stage cost estimation of building construction projects. **Gradevinar (Zagreb)**, 2021, v. 73 (8), p. 819-832. Disponível em: <<http://www.casopis-gradjevinar.hr/archive/article/3013>>. ISSN: 0350-2465. DOI: <<https://doi.org/10.14256/JCE.3013.2020>>.
- EKICI, Berk et al. Performative computational architecture using swarm and evolutionary optimisation: A review. **Building and environment**, 2019, v.147, p.356-371. Disponível em: <https://pure.tudelft.nl/ws/portalfiles/portal/84485303/1_s2.0_S0360132318306413_main.pdf>. ISSN: 0360-1323. DOI: 10.1016/j.buildenv.2018.10.023.
- ELMOUSALAMI, Haytham H. Comparison of Artificial Intelligence Techniques for Project Conceptual Cost Prediction: A Case Study and Comparative Analysis. **IEEE transactions on engineering management**, 2021, v. 68 (1), p. 183-196. Disponível em: <<https://ieeexplore.ieee.org/document/9007411>>. ISSN: 0018-9391. DOI: 10.1109/TEM.2020.2972078.
- FAZELI, Abdulwahed et al. An integrated BIM-based approach for cost estimation in construction projects. **Engineering, construction, and architectural management**, 2021, v. .28 (9), p. 2828-2854. Disponível em: <<https://www.emerald.com/insight/content/doi/10.1108/ECAM-01-2020-0027/full/html>>. ISSN: 0969-9988. DOI: <<https://doi.org/10.1108/ECAM-01-2020-0027>>.
- JIANG, Qinghua. Estimation of construction project building cost by back-propagation neural network. **Journal of engineering, design and technology**, 2020, v. 18 (3), p. 601-609. Disponível em: <<https://www.emerald.com/insight/content/doi/10.1108/JEDT-08-2019-0195/full/html>>. ISSN: 1726-0531. DOI: <<https://doi.org/10.1108/JEDT-08-2019-0195>>.
- LEACH, Neil. **Architecture in the Age of Artificial Intelligence: An Introduction to AI for Architects**. London: Bloomsbury Visual Arts, 2022. ISBN: 9781350165519

- LEE, Jaewook et al. BIM-based preliminary estimation method considering the life cycle cost for decision-making in the early design phase. **Journal of Asian architecture and building engineering**, 2020, vl.19 (4), p.384-399. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/13467581.2020.1748635>>. ISSN: 1346-7581. DOI: 10.1080/13467581.2020.1748635.
- LEE, Minghui et al. Technology acceptance model for Building Information Modelling Based Virtual Reality (BIM-VR) in cost estimation. **Journal of information technology in construction**, 2022, v. 27, p. 914-92. Disponível em: <<https://www.itcon.org/paper/2022/44>>. ISSN: 1874-4753. DOI: 10.36680/j.itcon.2022.044.
- LIANG, Rui; WANG, Po-Hsun; HU, Linhui. Application of Visual Recognition Based on BP Neural Network in Architectural Design Optimization. **Computational intelligence and neuroscience**, 2022, v. 2022, p.1-9. Disponível em: <<https://www.hindawi.com/journals/cin/2022/3351196/>>. ISSN: 1687-5265. DOI: 10.1155/2022/3351196.
- LU, Yijun et al. Multi-Objective Optimization of Building Environmental Performance: An Integrated Parametric Design Method Based on Machine Learning Approaches. **Energies (Basel)**, 2022, Vol.15 (19), p.7031. Disponível em: <<https://www.mdpi.com/1996-1073/15/19/7031>>. ISSN: 1996-1073. DOI: <https://doi.org/10.3390/en15197031>.
- MIRANDA, Sergio Lautaro Castro et al. Predictive Analytics for Early-Stage Construction Costs Estimation. **Buildings (Basel)**, 2022, v.12 (7), p. 1043. Disponível em: <<https://www.mdpi.com/2075-5309/12/7/1043>>. ISSN: 2075-5309. DOI: <https://doi.org/10.3390/buildings12071043>.
- PARK, Uyeol et al. A Stacking Heterogeneous Ensemble Learning Method for the Prediction of Building Construction Project Costs. **Applied sciences**, 2022, v. 12 (19), p. 9729. Disponível em: <<https://www.mdpi.com/2076-3417/12/19/9729>>. ISSN: 2076-3417. DOI: <https://doi.org/10.3390/app12199729>.
- PHAM, T. Q. D. et al. Efficient estimation and optimization of building costs using machine learning. **International journal of construction management**, 2023, v. 23 (5), p. 909-921. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/15623599.2021.1943630?journalCode=tjcm20>>. ISSN: 1562-3599. DOI: <https://doi.org/10.1080/15623599.2021.1943630>.
- PENA, Castro et al. Artificial intelligence applied to conceptual design. A review of its use in architecture. **Automation in Construction**, 2021, v. 124. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0926580521000017?via%3Dihub>>. DOI: <https://doi.org/10.1016/j.autcon.2021.103550>.
- SHIN, Yoonseok. Application of Boosting Regression Trees to Preliminary Cost Estimation in Building Construction Projects. **Computational intelligence and neuroscience**, 2015, v. 2015, p. 149702-9. Disponível em: <<https://www.hindawi.com/journals/cin/2015/149702/>>. ISSN: 1687-5265. DOI: 10.1155/2015/149702.
- SHISHEHGARKHANEH, Milad Baghalzadeh et al. BIM-Based Resource Tradeoff in Project Scheduling Using Fire Hawk Optimizer (FHO). **Buildings (Basel)**, 2022, v.12 (9), p.1472. Disponível em: <<https://www.mdpi.com/2075-5309/12/9/1472>>. ISSN: 2075-5309. DOI: <https://doi.org/10.3390/buildings12091472>.
- WANG, Wei-Chih et al. Conceptual cost estimations using neuro-fuzzy and multi-factor evaluation methods for building projects. **Journal of Civil Engineering and Management**, 2017, v. 23 (1), p. 1-14. Disponível em: <https://www.researchgate.net/publication/312558888_Conceptual_cost_estimations_using_neuro-fuzzy_and_multi-factor_evaluation_methods_for_building_projects> DOI:10.3846/13923730.2014.948908.
- WANG, Yali et al. Cost prediction of building projects using the novel hybrid RA-ANN model. **Engineering, construction, and architectural management**, 2023. Disponível em: <<https://www.emerald.com/insight/content/doi/10.1108/ECAM-07-2022-0666/full/html>>. ISSN: 0969-9988. DOI: <https://doi.org/10.1108/ECAM-07-2022-0666>.
- WOOD, Jamin et al. Using LOD in Structural Cost Estimation during Building Design Stage: Pilot Study. **Procedia Engineering**, 2014, v. 85, p. 543-552. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877705814019481>>. ISSN 1877-7058. DOI: <https://doi.org/10.1016/j.proeng.2014.10.582>.
- YANG, Seung-Won et al. Parametric Method and Building Information Modeling-Based Cost Estimation Model for Construction Cost Prediction in Architectural Planning. **Applied sciences**, 2022, v.12 (19), p. 9553. Disponível em: <<https://www.mdpi.com/2076-3417/12/19/9553>>. ISSN: 2076-3417. DOI: 10.3390/app12199553
- ZHANG, Xiaocun; ZHANG, Xueqi. Design of low-carbon and cost-efficient concrete frame buildings: a hybrid optimization approach based on harmony search. **Journal of Asian architecture and building engineering**, 2022, p.1-14. Disponível em: <<https://www.tandfonline.com/doi/full/10.1080/13467581.2022.2145202>>. DOI: <https://doi.org/10.1080/13467581.2022.2145202>

ZHAO, Liang et al. Construction Cost Prediction Based on Genetic Algorithm and BIM. **International journal of pattern recognition and artificial intelligence**, 2020, v. 34 (7), p.2059026. Disponível em: <<https://www.worldscientific.com/doi/10.1142/S0218001420590260>>. ISSN: 0218-0014. DOI: 10.1142/S0218001420590260.