XXI ENTAC – Encontro Nacional de Tecnologia do Ambiente Construído
14 a 16 de outubro de 2026 | Goiânia-Brasil
DOI: https://doi.org/10.46421/entac.v21i1.8620

Aplicações da Inteligência Artificial na indústria da construção: Uma revisão sistemática da literatura

Artificial Intelligence Applications in the construction industry: A systematic review of literature

Arlison Oliveira Costa
Universidade Federal do Ceará | Crateús | Brasil | oliveiraarlison980@gmail.com
Guilherme Caldas Carvalho
Universidade Federal do Ceará | Fortaleza | Brasil | gcaldascarvalho@gmail.com
Marcelo Silva Santos Segundo
Universidade Federal do Ceará | Fortaleza | Brasil | secondmarcelo@gmail.com
José de Paula Barros Neto
Universidade Federal do Ceará | Fortaleza | Brasil | jpbarros@ufc.br

Resumo

A indústria da construção civil, impulsionada pelo paradigma da Indústria 4.0, tem gerado volumes massivos de dados (Big Data), cuja complexidade desafia os métodos tradicionais de gestão. O presente artigo tem como objetivo apresentar uma Revisão Sistemática da Literatura (RSL) que analisa a aplicação de inteligência artificial na predição de custos, prazos e desempenho técnico, além de outras possíveis aplicações em obras. A pesquisa foi conduzida nas bases de dados Web of Science e Scopus, cobrindo o período de 2000 a 2025. Os resultados indicam uma predominância do uso de redes neurais artificiais. Conclui-se que, embora as tecnologias apresentem alta acurácia preditiva em ambiente acadêmico, sua implementação prática ainda enfrenta barreiras organizacionais e culturais. O estudo aponta lacunas significativas na aplicação dessas ferramentas para reformas e manutenção de edificações, sugerindo caminhos para pesquisas futuras.

Palavras-chave: Construção civil. Redes neurais artificiais. Gestão de obras. Revisão sistemática. Aprendizado de máquina.

Abstract

The construction industry, driven by the Industry 4.0 paradigm, generates massive volumes of data (Big Data), challenging traditional management methods. This article presents a Systematic Literature Review (SLR) analyzing artificial intelligence applications in predicting costs, schedules, and technical performance, alongside other job-site applications. The research was conducted using the Web of Science and Scopus databases, covering publications from 2000 to 2025. The results indicate a predominance of Artificial Neural Networks (ANN). In conclusion, while these technologies demonstrate high predictive accuracy in academic environments, practical implementation still faces organizational and cultural barriers. Finally, this study highlights significant research gaps in building renovation and maintenance, suggesting pathways for future investigations.

Keywords: Construction industry. Artificial neural networks. Construction management. Systematic review. Machine learning.

Como citar:
COSTA, A. O.; CARVALHO, G. C.; SEGUNDO, M. S. S.; NETO, J. P. B. Aplicações da Inteligência Artificial na indústria da construção: Uma revisão sistemática da literatura. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 21, 2026, Goiânia. **Anais**... Goiânia: ANTAC, 2026.

DOI: https://doi.org/10.46421/entac.v21i1.8620

INTRODUÇÃO

A indústria da construção tem sido impactada pelo avanço da digitalização e automação, fenômeno associado ao conceito de Indústria 4.0 [1]. Com a crescente adoção de tecnologias de monitoramento, sensores (internet das coisas) e softwares de gerenciamento, o setor passou a gerar um volume massivo de dados – o Big Data [2]. No entanto, a mera acumulação desses dados não se traduz automaticamente em eficiência; o desafio contemporâneo reside na capacidade de processar essas informações valiosas que apoiem a tomada de decisão.

Historicamente, o setor enfrenta problemas crônicos de baixa produtividade e alta fragmentação da cadeia produtiva, o que contribui para elevada variabilidade dos processos construtivos e gerenciais [3]. Autores clássicos da gestão de projetos apontam que essas características tornam o planejamento de obras um ambiente de elevada complexidade e incerteza [4]. Estudos indicam que a maioria dos grandes projetos de construção sofre com estouros de orçamento e atrasos de cronograma [5]. Métodos tradicionais de estimativa e controle, baseados em estatística linear ou planilhas manuais, mostram-se cada vez mais insuficientes para lidar com a complexidade das obras modernas. Nesse cenário, a incapacidade de prever com precisão o comportamento de custos, prazos e desempenho de recursos (como materiais, equipamentos e mão de obra) resulta em prejuízos financeiros significativos e desperdício de recursos.

Como resposta a essas limitações, a Inteligência Artificial (IA) e, especificamente, os algoritmos de ***Machine Learning*** (Aprendizado de Máquina), emergem como ferramentas robustas capazes de identificar padrões não lineares e realizar predições de alta acurácia [6]. Embora existam diversos estudos recentes – a exemplo da estimativa de produtividade [7] e da predição de custos laborais [8] - aplicando esses modelos computacionais em problemas práticos da engenharia, a literatura encontra-se fragmentada, dificultando a compreensão global de quais algoritmos são mais eficazes para cada tipo de problema na engenharia civil.

Portanto, o objetivo deste artigo é analisar o estado da arte da aplicação de inteligência artificial na construção civil. O estudo busca categorizar as principais áreas de aplicação (gestão, construção e sustentabilidade), identificar os algoritmos predominantes, como as Redes Neurais Artificiais (ANN) e modelos híbridos, e apontar as lacunas que ainda limitam a adoção dessas tecnologias no canteiro de obras.

REVISÃO BIBLIOGRÁFICA

A INDÚSTRIA 4.0 E O CONCEITO DE CONSTRUÇÃO 4.0

A Quarta Revolução Industrial, ou Indústria 4.0, caracteriza-se pela fusão de tecnologias físicas, digitais e biológicas, promovendo a automação inteligente e a conectividade dos meios de produção. Quando transposto para a engenharia civil, esse paradigma recebe o nome de "Construção 4.0" (ou *Construction 4.0*). Segundo Forcael *et al.* [9], a Construção 4.0 visa superar o histórico de baixa produtividade do setor por meio da digitalização dos canteiros de obras, integrando o mundo físico ao virtual. Esse ecossistema baseia-se em pilares como a Internet das Coisas (IoT), a robótica, a modelagem da informação da construção (BIM) e, fundamentalmente, a capacidade

de coletar e analisar grandes volumes de dados de projeto e execução, fenômeno conhecido como *Big Data* [2]. É justamente a necessidade de dar utilidade prática a essa vasta geração de dados que impulsiona a adoção de sistemas inteligentes no setor [1].

A INTELIGÊNCIA ARTIFICIAL E MACHINE LEARNING

A Inteligência Artificial (IA) é um campo amplo da ciência da computação dedicado a criar sistemas capazes de realizar tarefas que, historicamente, exigiriam inteligência humana, como raciocínio, percepção e tomada de decisão [10]. Dentro do amplo guarda-chuva da IA, destaca-se o *Machine Learning* (Aprendizado de Máquina). Enquanto a programação tradicional baseia-se em regras estáticas (o programador insere os dados e as regras para obter uma resposta), o *Machine Learning* inverte essa lógica: o sistema recebe grandes volumes de dados históricos e as respostas corretas, utilizando algoritmos para "aprender" as regras e padrões matemáticos de forma autônoma [11]. Na construção civil, isso significa que um algoritmo não precisa de uma fórmula exata para calcular o atraso de uma obra; ele aprende os padrões de atraso analisando centenas de cronogramas passados, tornando-se capaz de realizar predições precisas para projetos futuros.

PRINCIPAIS ALGORITMOS: REDES NEURAIS E VISÃO COMPUTACIONAL

Dentre as diversas técnicas de *Machine Learning* aplicadas à engenharia, duas abordagens ganham destaque contemporâneo: as Redes Neurais Artificiais (ANN) e os modelos de Visão Computacional baseados em *Deep Learning* (Aprendizado Profundo). As Redes Neurais Artificiais, como o modelo BPNN (*Back Propagation Neural Network*), são algoritmos inspirados na estrutura do cérebro humano. Elas são compostas por camadas de "neurônios" artificiais interconectados que ajustam seus pesos sinápticos iterativamente para minimizar o erro de uma predição [12]. Sua principal vantagem na construção é a capacidade de modelar correlações altamente não-lineares, como prever custos ou resistência do concreto a partir de múltiplas variáveis independentes. Por outro lado, o *Deep Learning* representa uma evolução das redes neurais, possuindo múltiplas camadas ocultas capazes de processar dados não-estruturados, como imagens e vídeos. No canteiro de obras, essa tecnologia é a base da Visão Computacional – utilizando arquiteturas como o YOLO (*You Only Look Once*) –, permitindo que computadores "enxerguem" e interpretem o ambiente em tempo real para detectar riscos de segurança, monitorar o uso de EPIs ou rastrear o progresso físico da construção sem intervenção manual [13].

METODOLOGIA

A pesquisa adotou o método de Revisão Sistemática da Literatura (RSL), que consiste em um processo rigoroso para identificar, avaliar e interpretar as evidências disponíveis sobre a aplicação de inteligência artificial na construção civil. Para direcionar a condução do estudo, definiu-se a seguinte pergunta norteadora: *"Quais são as principais áreas de aplicação e os algoritmos predominantes no uso da Inteligência Artificial na construção civil?"*. O procedimento foi estruturado em quatro

etapas principais: definição da estratégia de busca, seleção de bases de dados, aplicação de filtros e critérios de elegibilidade, etapas estas fundamentadas nas diretrizes metodológicas do protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) [14].

STRING DE BUSCA E BASES DE DADOS

A coleta de dados foi realizada em duas das principais bases científicas mundiais: Web of Science (WoS) e Scopus. A escolha exclusiva desses dois indexadores justifica-se por serem as maiores e mais abrangentes bases de dados multidisciplinares globais, cobrindo os periódicos de maior relevância e fator de impacto na área de engenharia [15].

A busca abrangeu um horizonte temporal consolidado abrangendo os anos de 2000 até 2025. A *string* de busca foi construída utilizando operadores booleanos (*AND* e *OR*), para combinar três eixos temáticos principais: tecnologias de Inteligência Artificial, setor de aplicação e fatores contextuais de aplicação, resultando na seguinte equação:

Tabela 1: String de busca usada nas bases

String de busca utilizada	(“artificial intelligence” OR “machine learning” OR “deep learning” OR “neural networks” OR “AI models” OR “data-driven models”) AND (“construction industry” OR “construction projects” OR “building projects” OR “infrastructure projects” OR “civil engineering” OR “AEC industry” OR “built environment”) AND (“contextual factors” OR “enviromental conditions” OR “organizational factors” OR “project characteristics” OR “decision factors” OR “adoption factors” OR “implementation context” OR “influencing factors”)

Fonte: Autores (2026).

PROTOCOLO DE FILTRAGEM (PRISMA)

A seleção dos artigos foi orientada pelas diretrizes do protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) [14], visando garantir a transparência, a replicabilidade e o rigor metodológico necessários para uma revisão sistemática. A adoção desse padrão permite que o processo de filtragem seja auditável, mitigando vieses de seleção e assegurando que os estudos incluídos possuam aderência direta aos objetivos desta pesquisa, especialmente no que tange às aplicações de Inteligência Artificial na Construção 4.0.

O processo de refinamento foi executado em cinco fases sequenciais. Inicialmente, a busca bruta nas bases Scopus e Web of Science retornou um volume massivo de dados, que foi submetido a filtros de idioma, cronologia (2000-2025) e tipo de documento (artigos e revisões). Em seguida, realizou-se a triagem qualitativa por meio da leitura de títulos e resumos, o que permitiu identificar os trabalhos com maior potencial de contribuição técnica e/ou científica. Após a verificação de duplicatas, procedeu-se à leitura integral dos textos para validar se os modelos de IA apresentados possuíam fundamentação prática ou teórica robusta para o setor de construção civil.

A Tabela 2 apresenta o detalhamento quantitativo de cada etapa do funil de seleção. Observa-se que, embora a fase inicial tenha identificado 563 registros, o rigor dos critérios de elegibilidade resultou em uma amostra final de 37 artigos. Nota-se que na transição entre a fase 4 e a fase 5, foi realizada uma verificação ativa de duplicatas entre as bases utilizadas, não sendo identificado nenhum registro repetido na

amostragem final. Este conjunto final de dados serviu de base para o mapeamento das áreas de gestão, engenharia e sustentabilidade discutidas nos resultados deste estudo.

Tabela 2: Fluxo de seleção dos artigos por base de dados

Fase	Descrição	Scopus	Web of Science	Todos
1	Pesquisa da string	372	191	563
2	Filtros: Idioma (inglês); Cronologia (2000-2025); Tipo (artigos e revisões)	214	164	378
3	Leitura dos títulos	84	56	140
4	Leitura dos resumos	20	24	44
5	Mantidos após leitura de todos os artigos	14	23	37

Fonte: Autores (2026).

CRITÉRIOS DE INCLUSÃO E EXCLUSÃO

Foram incluídos artigos que apresentassem aplicações práticas ou modelos teóricos de IA voltados para a gestão de projetos (custos e prazos), engenharia (materiais e estruturas) ou sustentabilidade. Foram excluídos estudos que não possuíam foco direto na indústria da construção ou que apresentavam metodologias de IA sem validação de dados ou resultados claros.

RESULTADOS E DISCUSSÃO

PANORAMA DAS PUBLICAÇÕES

O uso de inteligência artificial na construção civil tem sido um assunto recorrente, dado o crescimento do potencial de uso dessas ferramentas nos últimos anos. Esse aumento reflete a crescente demanda do setor por processos mais rigorosos de monitoramento digital e gestão baseada em dados, visando otimizar a execução, reduzir incertezas e elevar o desempenho ao longo de todo o ciclo de vida das edificações. A Figura 1 apresenta os gráficos do número de publicações por ano nas duas bases analisadas:

DOI: https://doi.org/10.46421/entac.v21i1.8620

Figura 1: Gráfico do número de publicações por ano (Web of Science e Scopus)

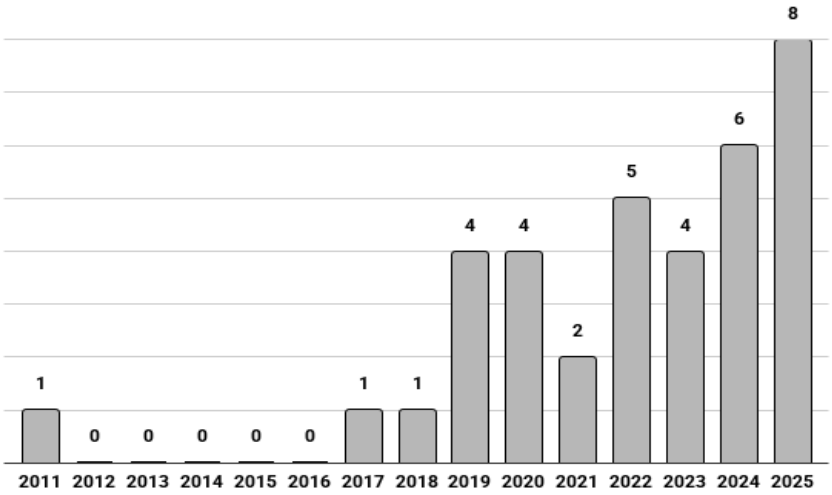

Fonte: Autores (2026).

Assim como evidenciado pela distribuição temporal dos estudos selecionados nesta RSL, o tema mostrava-se pouco abordado há uma década – com raras exceções isoladas, como as pesquisas de predição de produtividade [7]. Contudo, nota-se uma clara tendência de crescimento a partir de 2018. Esse volume de publicações recentes acompanha a urgência global por transformação digital e automação nos últimos anos, impulsionada pela necessidade de mitigar flutuações de mão de obra e otimizar recursos [3]. Dessa forma, o setor construtivo procura absorver estas inovações das mais variadas formas; no entanto, a literatura também faz ressalvas: estudos alertam que, apesar do avanço tecnológico, fatores organizacionais e culturais ainda representam barreiras significativas para a adoção plena dessas ferramentas no canteiro de obras [16].

A Figura 2 mapeia os países de origem desses artigos, sendo considerado o país do autor principal como critério para definição.

Figura 2: Gráfico do número de publicações por país (Web of Science e Scopus)

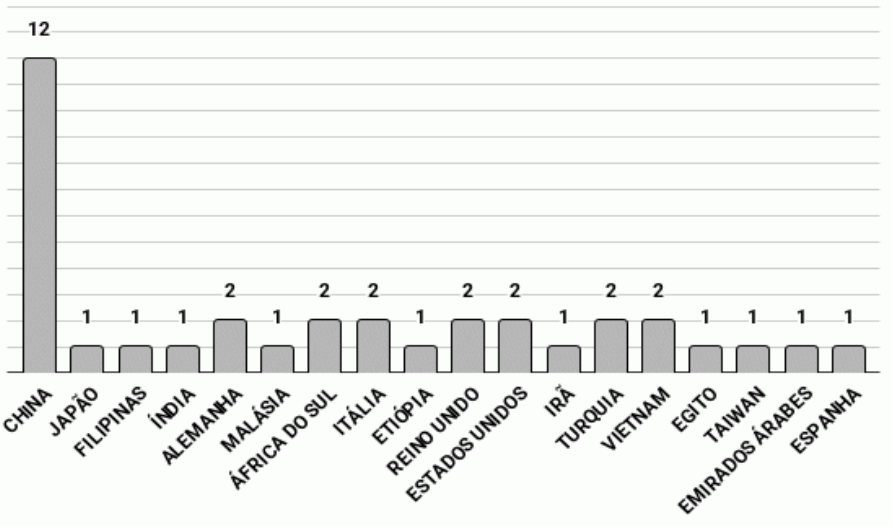

Fonte: Autores (2026).

Percebe-se que o número de publicações apresenta forte liderança da China. Estudos apontam que o acelerado desenvolvimento econômico e social chinês resultou em um aumento expressivo de construções urbanas, tornando o uso de ferramentas preditivas uma necessidade fundamental para o gerenciamento de obras em larga escala no país [6]. Essa liderança é seguida por potências tecnológicas consolidadas, como Estados Unidos e Alemanha, e por um grupo notável de países emergentes, como Malásia, África do Sul e Vietnã.

Por outro lado, a ampla distribuição global contrasta com a ausência de publicações do Brasil neste recorte de vanguarda tecnológica. A pesquisa de Tanaka *et al.* [17] indica que a indústria da construção civil brasileira ainda enfrenta desafios significativos em sua maturidade digital e na adoção de tecnologias emergentes, como a Inteligência Artificial. Esse cenário é influenciado por barreiras estruturais relevantes. Autores como Lordsleem Jr. e Sampaio [18] apontam que o alto custo de implementação de tecnologias, aliado a aspectos culturais organizacionais e à própria estrutura do setor, configuram entraves importantes para a transformação digital da construção civil do país. Como consequência, observa-se um ritmo mais lento de incorporação de inovações tecnológicas quando comparado a outros contextos internacionais."

PRINCIPAIS ABORDAGENS TEMÁTICAS

Para facilitar o entendimento, este subtópico será dividido em três categorias, facilitando a compreensão dado o vasto setor da construção civil. A primeira categoria é a gestão de projetos, que teve o maior número de publicações, impulsionada pela demanda sempre grande por obras com prazos curtos e baixos custos. A segunda é a engenharia que se volta para o desempenho de materiais (ainda em desenvolvimento ou já usados) e estruturas. Já a última categoria se volta para a uso da sustentabilidade em obras. A figura 3 apresenta um gráfico acerca da distribuição dos artigos nas categorias:

Figura 3: Gráfico do número de publicações por categoria

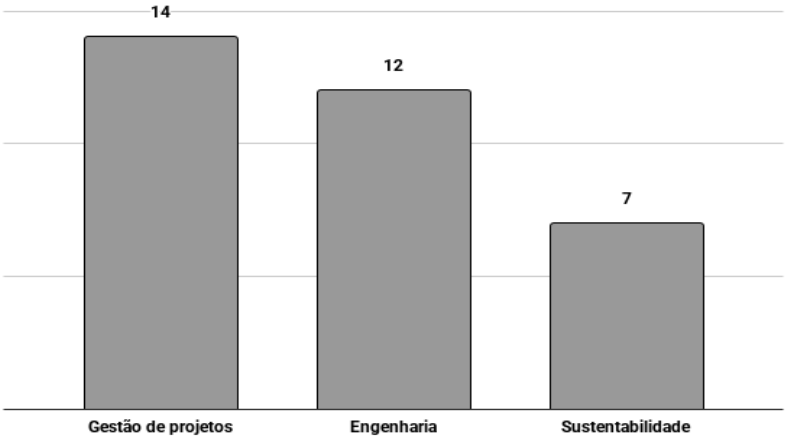

Fonte: Autores (2026).

Com o objetivo de sintetizar as evidências encontradas nos 37 artigos selecionados na RSL e fundamentar a discussão de forma comparativa, foi estruturado o Quadro 1. Esta matriz condensa as três macrocategorias identificadas, cruzando as aplicações práticas

do setor, as abordagens computacionais predominantes, as principais referências mapeadas e as limitações críticas observadas.

Quadro 1: Matriz comparativa sintética dos estudos incluídos na RSL

Categoria (Qtd)	Principais aplicações	Modelos de IA	Referências	Limitações críticas
Gestão (14)	Previsão de custos, prazos, produtividade e EPI's.	BPNN, YOLOv8, Lógica difusa.	[6], [7], [8], [19], [24], [25], [26]	Foco em obras novas; escassez em reformas.
Engenharia (12)	Resistência de concretos e integridade estrutural.	Ensemble, MLP, Inteligência enxame.	[27], [28], [29], [30], [31]	Dados de laboratório; validação em campo restrita.
Sustentabilidade (7)	Créditos LEED, eficiência energética e conforto.	Algoritmos de classificação + IoT.	[32], [33], [34]	Baixa integração prática com BIM.

Fonte: Autores (2026).

GESTÃO DE PROJETOS: PREVISÃO DE CUSTOS, PRAZO E PRODUTIVIDADE

A primeira e principal categoria do estudo está centrada na previsão de custos e prazos de obras, evidenciando que o setor construtivo sofre com essas estimativas em virtude da complexidade e incertezas inerentes ao setor no decorrer da execução da obra. A literatura analisada demonstra uma transição metodológica clara: o abandono de métodos tradicionais em favor de modelos de inteligência artificial híbridos**.**

No âmbito da estimativa de custos, há uma hegemonia de pesquisas chinesas focadas em Redes Neurais. Essa busca por precisão é corroborada por [6] e [19], que aplicam algoritmos BPNN (*Back Propagation Neural Network*) e otimização via Big Data para refinar orçamentos de projetos residenciais, reduzindo margens de erro históricas. Em uma aplicação específica para a fase de operação, [20] expande o uso de redes neurais para prever custos de manutenção, uma área frequentemente negligenciada nas fases iniciais de projeto.

Quanto à produtividade e à mão de obra, a abordagem geográfica se diversifica. Pesquisas desenvolvidas no Vietnã [21] e na Malásia [7] utilizam redes neurais para modelar a produtividade em edifícios altos, identificando fatores ocultos que afetam o rendimento dos operários. Paralelamente, no Reino Unido, [8] utiliza IA para modelar especificamente os custos laborais, sugerindo que a flutuação da mão de obra é uma variável crítica que exige modelagem dedicada.

A segurança do trabalho apresenta uma grande evolução tecnológica recente. Nota-se um salto qualitativo: de modelos probabilísticos de previsão de acidentes [22] e análise de riscos em pisos [23], para sistemas de monitoramento em tempo real. O destaque reside no estudo sul-africano [24], que implementa o algoritmo de Deep Learning

YOLOv8 para detecção de sonolência e uso de EPIs a partir da utilização de vídeo, introduzindo assim a visão computacional no canteiro de obras.

Por fim, no que tange ao controle de prazos, a literatura apresenta soluções para o planejamento de obras. Enquanto na Etiópia [25] aplica-se Machine Learning para prever o tempo total de construção em obras públicas, na Índia [26] observa-se uma abordagem matemática distinta, com a melhoria de algoritmos para determinação de caminhos críticos (CPM). Isso demonstra que, para cronogramas, a incerteza é tratada não apenas com aprendizado de máquina, mas com lógica difusa para absorver imprevistos.

ENGENHARIA: MATERIAIS E ESTRUTURAS

Esta categoria ilustra a aplicação da IA em problemas físicos (*Hard Engineering*), focando em uma subárea: a predição de desempenho de estruturas e materiais.

No campo dos materiais, o uso de Machine Learning atua como uma ferramenta não destrutiva de baixo custo. A Alemanha [27] e a China [28] lideram pesquisas na predição da resistência à compressão de concretos sustentáveis e com agregados reciclados, respectivamente. Nesses casos, os algoritmos aprendem a correlação complexa entre a mistura (traço) e a resistência final, poupando tempo de laboratório. Similarmente, no Vietnã, um estudo geotécnico [29] provou-se eficaz para determinar coeficientes de compressão do solo, oferecendo uma alternativa rápida aos ensaios geotécnicos tradicionais.

Complementarmente, a integridade estrutural (*Structural Health Monitoring*) é abordada no Irã [30] e na China [31], onde métodos de Ensemble e redes neurais avaliam danos e aderência do concreto sob condições extremas, como variações severas de temperatura e corrosão.

SUSTENTABILIDADE

O terceiro eixo agrupa estudos que utilizam o Machine Learning não para cálculos físicos, mas como suporte à decisão estratégica, ambiental e organizacional (*Decision Support Systems*).

A sustentabilidade e o desempenho ambiental são temas recorrentes onde a IA atua na complexidade de variáveis. Nos Estados Unidos [32], algoritmos foram capazes de categorizar atributos de projetos para prever a obtenção de créditos na certificação LEED, otimizando o design sustentável antes mesmo do início da obra.

Essa linha conecta-se com estudos na Espanha [33] e Emirados Árabes [34], que utilizam IoT (Internet das Coisas) e ML para monitorar eficiência energética e conforto dos ocupantes em tempo real, fechando o ciclo entre construção e operação (*Facility Management*).

PRINCIPAIS ALGORITMOS IDENTIFICADOS

A análise dos estudos selecionados revela a predominância das Redes Neurais Artificiais (ANN) como o modelo mais adotado na construção civil. Especificamente, o algoritmo BPNN (*Back Propagation Neural Network*) consolida-se como o padrão-ouro para problemas de regressão (predição de custos e prazos), aparecendo com frequência nos estudos devido à sua capacidade iterativa de ajuste de pesos e minimização de erros.

Contudo, observa-se uma tendência tecnológica clara em direção aos modelos híbridos. Pesquisadores têm combinado redes neurais clássicas com algoritmos de otimização bio-inspirados (como *Swarm Intelligence* e Algoritmos Genéticos) ou técnicas de redução de dimensionalidade, a exemplo da Análise de Componentes Principais (PCA - *Principal Component Analysis*). A aplicação do PCA permite agrupar e simplificar o excesso de variáveis de um projeto construtivo, o que ajuda a superar problemas de *overfitting* (sobreajuste) e aumentar a precisão preditiva mesmo com bases de dados limitadas. Paralelamente, para tarefas que envolvem dados não estruturados, como imagens e vídeos capturados em canteiros, emergem técnicas de *Deep Learning* e Visão Computacional (ex: YOLOv8), demonstrando que a complexidade do algoritmo acompanha a natureza do dado processado.

LIMITAÇÕES DA LITERATURA

Apesar da grande capacidade dos modelos preditivos apresentados, esta revisão sistemática identificou lacunas críticas que direcionam futuras investigações. Primeiramente, nota-se uma concentração excessiva de estudos nas fases de planejamento e execução de novas obras. Há uma escassez de pesquisas aplicadas à reforma e atualização tecnológica e à manutenção de longo prazo de edificações existentes, setores onde a predição de custos e patologias seria de grande valia.

Além disso, identificou-se uma barreira na transição da teoria para a prática. Enquanto os algoritmos demonstram alta precisão matemática ("acurácia de laboratório"), os estudos focados em fatores organizacionais indicam que a resistência cultural e a falta de capacitação digital das equipes de obra impedem a adoção massiva dessas tecnologias.

Por fim, a hegemonia de estudos na China sugere a necessidade de validação desses modelos em contextos distintos, como o cenário brasileiro, onde as variáveis econômicas e métodos construtivos possuem particularidades não captadas pelos dados internacionais.

CONCLUSÃO

Por fim, a análise dos estudos selecionados confirma que o setor atravessa uma fase de transição tecnológica irreversível, movendo-se de métodos empíricos e manuais para abordagens preditivas baseadas em dados.

Conclui-se que as Redes Neurais Artificiais (ANN) consolidaram-se como as ferramentas mais eficazes para a resolução de problemas de regressão complexos, oferecendo precisão superior na estimativa de custos e prazos. Adicionalmente, identificou-se uma evolução qualitativa nas pesquisas recentes, que expandem o uso da IA para além da gestão financeira.

Entretanto, o estudo revelou lacunas significativas, observou-se uma saturação de estudos focados em "novas construções", em detrimento de aplicações voltadas à reforma, manutenção de edificações existentes e validação de modelos em países em desenvolvimento, como o Brasil. Além disso, a literatura indica que a maturidade dos algoritmos já superou a maturidade organizacional das empresas, sendo as barreiras culturais e de implementação os atuais gargalos do setor.

Portanto, recomenda-se que trabalhos futuros não se limitem apenas ao aperfeiçoamento matemático dos algoritmos, mas que investiguem a integração dessas ferramentas aos fluxos de trabalho reais das construtoras, como a Modelagem da Informação da Construção (BIM) e a Internet das Coisas (IoT). Essa recomendação justifica-se, pois, a utilidade prática da Inteligência Artificial no canteiro de obras depende de sua alimentação com dados em tempo real (providos pela IoT) e de sua incorporação à rotina visual e de projeto dos engenheiros (através do BIM), transformando o modelo preditivo de um mero experimento acadêmico isolado em uma ferramenta efetiva de apoio à decisão.

AGRADECIMENTOS

A realização dessa pesquisa só foi possível com o apoio da Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP).

DECLARAÇÃO DE USO DE IA

Durante a preparação deste artigo, o primeiro autor utilizou o modelo de inteligência artificial Gemini (versão de julho de 2026) para a revisão gramatical e melhoria de coesão. Após a utilização da ferramenta, os autores revisaram e editaram o conteúdo conforme necessário e assumem total responsabilidade pelo conteúdo do artigo publicado.

REFERÊNCIAS

[1] OESTERREICH, T. D.; TEUTEBERG, F. Understanding the implications of digitisation and automation in the context of Industry 4.0: A triangulation approach and elements of a research agenda for the construction industry. **Computers in Industry**, v. 83, p. 121-139, 2016.

[2] BILAL, M. *et al*. Big Data in the construction industry: A review of present status, opportunities, and future trends. **Advanced Engineering Informatics**, v. 30, n. 3, p. 500-521, 2016.

[3] MCKINSEY GLOBAL INSTITUTE. **Reinventing construction through a productivity revolution**. Nova Iorque: McKinsey & Company, 2017.

[4] PROJECT MANAGEMENT INSTITUTE (PMI). **Um Guia do Conhecimento em Gerenciamento de Projetos (Guia PMBOK)**. 7. ed. Pensilvânia: Project Management Institute, 2021.

[5] FLYVBJERG, B. What you should know about megaprojects and why: An overview. **Project Management Journal**, v. 45, n. 2, p. 6-19, 2014.

[6] WANG, D. Research on the Prediction of Construction Cost Based on BPNN. *In*: IEEE INTERNATIONAL CONFERENCE ON ELECTRICAL ENGINEERING, BIG DATA AND ALGORITHMS (EEBDA), 3., 2024. **Anais [...]** IEEE, 2024. p. 1-5.

[7] MUQEEM, S.; KHAMIDI, M. F. Development of construction labor productivity estimation model using artificial neural network. *In*: NATIONAL POSTGRADUATE CONFERENCE (NPC), 2011. **Anais [...]** IEEE, 2011. p. 1-5.

[8] MOMADE, M. H. *et al*. Modeling labor costs using artificial intelligence tools. **International Journal of Building Pathology and Adaptation**, v. ahead-of-print, n. ahead-of-print, 2022. Disponível em: https://doi.org/10.1108/IJBPA-03-2022-0048. Acesso em: 30 jun. 2026.

[9] FORCAEL, E. *et al*. Construction 4.0: A literature review. **Sustainability**, v. 12, n. 22, p. 9755, 2020.

[10] RUSSELL, S.; NORVIG, P. **Inteligência Artificial: uma abordagem moderna**. 3. ed. Rio de Janeiro: Elsevier, 2013.

[11] JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. **Science**, v. 349, n. 6245, p. 255-260, 2015.

[12] ABIODUN, O. I. *et al*. State-of-the-art in artificial neural network applications: A survey. **Heliyon**, v. 4, n. 11, e00938, 2018.

[13] GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

[14] PAGE, M. J. *et al*. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, v. 372, n. 71, 2021.

[15] MONGEON, P.; PAUL-HUS, A. The journal coverage of Web of Science and Scopus: a comparative analysis. **Scientometrics**, v. 106, n. 1, p. 213-228, 2016.

[16] ABIOYE, S. O. *et al*. Organisational Factors of Artificial Intelligence Adoption in the South African Construction Industry. **Computers in Industry**, v. 128, p. 103423, 2022.

[17] TANAKA, C. A.; MATSUDA, P. M.; MACLENNAN, M. L. F. Transformação digital na construção civil no Brasil: estratégias adotadas de desenvolvimento. **Gestão & Regionalidade**, v. 40, e20248242, 2024.

[18] LORDSLEEM JR., A. C.; SAMPAIO, G. M. Technologies Innovations for the Brazilian Construction Companies Digital Transformation. **Purdue e-Pubs (CIB Conferences)**, v. 1, n. 1, p. 45-55, 2022.

[19] JIANG, Q. Estimation of construction project building cost by back-propagation neural network. **Journal of Engineering, Design and Technology**, v. ahead-of-print, n. ahead-of-print, 2020. Disponível em: https://doi.org/10.1108/JEDT-03-2020-0082. Acesso em: 30 jun. 2026.

[20] EL-BASYOUNY, K. *et al*. Revolutionizing semantic integration of maintenance cost prediction for building systems using artificial neural networks. **Journal of Building Engineering**, v. 82, p. 108210, 2024.

[21] LY, H. *et al*. Modeling labor productivity in high-rise building construction projects using neural networks. **Journal of Asian Architecture and Building Engineering**, v. 22, n. 4, p. 2145-2158, 2023.

[22] KOC, K. Determining the Short-term Susceptibility of Construction Workers to Occupational Accidents Using Stochastic Gradient Boosting. **Safety Science**, v. 165, p. 106120, 2023.

[23] SARIISIK, G.; ÇOŞKUN, G. Safer Floors in Public Service Buildings Based on Machine Learning. **Journal of Tribology**, v. 147, n. 2, p. 021201, 2025.

[24] ONOSOSEN, A. O. *et al*. Drowsiness Detection of Construction Workers: Accident Prevention Leveraging Yolov8 Deep Learning and Computer Vision Techniques. **Journal of Construction Engineering and Management**, v. 151, n. 1, p. 04024180, 2025.

[25] DEBERO, D. W. *et al*. Machine Learning Model for Construction Time Prediction: A Case of Selected Public Building Projects in Hosanna, Ethiopia. **Cogent Engineering**, v. 11, n. 1, p. 2351230, 2024.

[26] SIRIPURAPU, A. *et al*. Improving Dijkstra's algorithm for Estimating Project Characteristics and Critical Path. **International Journal of Construction Management**, v. 22, n. 15, p. 2945-2955, 2022.

[27] PHAM, A.-D. *et al*. Hybrid machine learning for predicting strength of sustainable concrete. **Structural Concrete**, v. 21, n. 6, p. 2435-2447, 2020.

[28] LI, S. *et al*. A compressive strength prediction model for precast recycled aggregate concrete based on machine learning. **Construction and Building Materials**, v. 450, p. 138510, 2025.

[29] BUI, D. T. *et al*. Prediction of soil compression coefficient for urban housing project using novel integration machine learning approach of swarm intelligence and Multi-layer Perceptron Neural Network. **Catena**, v. 165, p. 112-124, 2018.

[30] FALLAHIAN, M. *et al*. Ensemble classification method for structural damage assessment under varying temperature. **Structural Health Monitoring**, v. 17, n. 4, p. 850-862, 2018.

[31] ZHANG, K.; ZHANG, K. Machine learning prediction and interpretability of bond strength in corroded reinforced concrete under high temperatures. **Materials Today Communications**, v. 42, p. 101150, 2025.

[32] MANSOURI, A. *et al*. Machine Learning for Leadership in Energy and Environmental Design Credit Targeting: Project Attributes and Climate Analysis Toward Sustainability. **Journal of Cleaner Production**, v. 435, p. 140210, 2025.

[33] CANO-SUÑÉN, E. *et al*. Internet of Things (IoT) in Buildings: A Learning Factory. **Sustainability**, v. 15, n. 8, p. 6543, 2023.

[34] LIN, M. *et al*. Multidomain Drivers of Occupant Comfort, Productivity, and Well-Being in Buildings: Insights from an Exploratory and Explanatory Analysis. **Journal of Architectural Engineering**, v. 27, n. 3, p. 04021015, 2021.