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.v21i1.8595

# Inteligência Artificial para produtividade na construção civil

## Artificial Intelligence for productivity in the construction industry

**Elder Pita Garcia Padre**
Universidade Estácio de Sá Santo Amaro, Engenharia Civil | São Paulo | Brasil | elderpadre@hotmail.com
**Daniel Nepomuceno Batista**
Universidade Estácio de Sá Santo Amaro, Engenharia Civil | São Paulo | Brasil | danielnepomucenobatista@gmail.com
**Jessie Diogo de Oliveira**
Universidade Estácio de Sá Santo Amaro, Engenharia Civil | São Paulo | Brasil | diogo@aprojeobras.com.br

### Resumo

A construção civil registra estagnação histórica de produtividade, e a Inteligência Artificial (IA) é apontada como vetor de transformação na Arquitetura, Engenharia, Construção e Operação 4.0, ainda sem consolidação prática. Este estudo mapeou o estado da arte da IA aplicada à produtividade na construção entre 2020 e 2026, identificando lacunas e o grau de aplicação real em canteiro. Realizou-se revisão sistemática sob o protocolo PRISMA 2020, com busca em Web of Science, Scopus e SciELO e busca complementar assistida por IA generativa (ChatGPT, Gemini e Perplexity) com validação manual. Scopus e SciELO nada retornaram; dos 538 registros da Web of Science, 50 foram incluídos após a triagem e, com 4 referências verificadas na busca assistida, formam um corpus de 54 estudos. Predomina o aprendizado profundo aplicado à visão computacional (43 estudos; 79,6%), voltado a monitoramento e reconhecimento de atividade; a integração com Lean Construction é rara (4 estudos) e os modelos de linguagem, quase ausentes (1). Nenhum estudo brasileiro compõe o corpus. Documenta-se a alucinação das ferramentas generativas (100% em ChatGPT e Gemini; 0% em Perplexity), reforçando a validação manual.

**Palavras-chave:** Inteligência Artificial. Produtividade. Construção civil. Lean Construction. Alucinações de IA. Revisão sistemática.

### Abstract

*The construction industry records historic productivity stagnation, and Artificial Intelligence (AI) is seen as a driver of transformation within Architecture, Engineering, Construction and Operation 4.0, yet without practical consolidation. This study mapped the state of the art of AI applied to construction productivity between 2020 and 2026, identifying gaps and the extent of on-site application. A systematic review was conducted under the PRISMA 2020 protocol, searching Web of Science, Scopus and SciELO, with a complementary search assisted by*

PADRE, E.P. G.; BATISTA, D.N.; de OLIVEIRA, J. D. Inteligência Artificial para produtividade na construção civil. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 21, 2026, Goiânia. Anais... Goiânia: ANTAC, 2026.

*generative AI (ChatGPT, Gemini and Perplexity) under manual validation. Scopus and SciELO returned nothing; of the 538 Web of Science records, 50 were included after screening and, with 4 references verified in the assisted search, form a corpus of 54 studies. Deep learning applied to computer vision predominates (43 studies; 79.6%), aimed at monitoring and activity recognition; integration with Lean Construction is rare (4 studies) and language models nearly absent (1). No Brazilian study belongs to the corpus. Hallucination of the generative tools is documented (100% for ChatGPT and Gemini; 0% for Perplexity), reinforcing manual validation.*

***Keywords:*** *Artificial Intelligence. Productivity. Construction industry. Lean Construction. AI hallucinations. Systematic review.*

## INTRODUÇÃO

A construção civil é um dos setores com menor crescimento de produtividade do trabalho nas últimas décadas, fenômeno reiteradamente descrito como o *productivity gap* da indústria [1]. Em paralelo, a AECO 4.0 introduz tecnologias digitais como o Building Information Modeling (BIM), Internet das Coisas (IoT), gêmeos digitais e, mais recentemente, Inteligência Artificial (IA) com promessa de reverter essa estagnação por meio de medição contínua, previsão de desempenho e automação de tarefas [2,3].

O avanço da IA, especialmente a partir de 2020, intensificou-se com a maturação de arquiteturas de *Deep Learning* (DL) para visão computacional (CV), com sensores vestíveis (IMU, *smartwatches*) e, mais recentemente, com modelos de linguagem de grande escala (*Large Language Models* — LLMs) e modelos multimodais (MLLMs) [4]. Apesar da proliferação de estudos, persistem dúvidas críticas: as soluções propostas geram ganhos reais em canteiro? São validadas em ambiente operacional ou apenas em *datasets* controlados? Há, de fato, integração com paradigmas consolidados como Lean Construction[5]?

Para responder a essas questões, o objetivo geral desta revisão sistemática da literatura (RSL) é mapear o estado da arte da IA aplicada à produtividade na construção civil entre 2020 e 2026, no recorte específico da interseção entre IA, produtividade e construção. Definem-se oito objetivos específicos: (OP1) identificar como a IA tem sido aplicada à produtividade; (OP2) caracterizar as técnicas de IA predominantes; (OP3) verificar quais ganhos são reportados e como são mensurados; (OP4) avaliar o nível de maturidade das soluções; (OP5) identificar estudos com aplicação real em canteiro; (OP6) analisar a integração com o Lean Construction; (OP7) examinar o estágio dos LLMs aplicados à produtividade; e (OP8) diagnosticar lacunas para o contexto brasileiro. A condução adota metodologia híbrida assistida por IA generativa com validação manual integral, alinhada ao protocolo PRISMA 2020 [6].

As contribuições do estudo são um protocolo de busca e classificação reproduzível e auditável, que pode ser replicado por outros pesquisadores; evidência empírica sobre a taxa de alucinação de ferramentas de IA generativa quando empregadas no apoio a revisões sistemáticas; e o diagnóstico das lacunas temáticas, com implicações para uma agenda nacional de pesquisa e implantação.

## MÉTODO

A RSL seguiu o protocolo PRISMA 2020 [6], formalmente registrado antes da execução das buscas. A condução combinou uma busca em bases indexadas e uma busca complementar assistida por IA generativa, ambas submetidas a validação manual integral pelos autores. As subseções seguintes detalham, nessa ordem, a estratégia de busca, os critérios de elegibilidade e o procedimento de extração e classificação dos estudos.

### ESTRATÉGIA DE BUSCA

A busca assistida por IA generativa foi realizada como etapa complementar e paralela à busca nas bases indexadas, com o intuito de ampliar a recuperação de estudos potencialmente não indexados. Aplicou-se o mesmo *prompt* estruturado a três ferramentas de IA generativa (ChatGPT versão Go, Gemini 3.5 Thinking e Perplexity Pro) exigindo *links* verificáveis (DOI ou página do *publisher*) e sinalização explícita de incerteza para mitigar alucinações. Em síntese, o prompt solicitava a recuperação de publicações revisadas por pares (2020–2026) sobre IA aplicada à produtividade na construção, retornando, para cada item, título, autores, ano, veículo, DOI e grau de confiança, conforme apresentado abaixo:

*Você é um assistente de pesquisa acadêmica apoiando uma revisão sistemática da literatura.*
*Objetivo: Identificar artigos acadêmicos reais, revisados por pares, sobre o uso de Inteligência Artificial*
*para melhorar a PRODUTIVIDADE na indústria da construção.*
*Foco em:*
*- Monitoramento e previsão da produtividade da mão de obra*
*- Eficiência de processos e redução de desperdícios*
*- Reconhecimento de atividades dos trabalhadores e acompanhamento de desempenho*
*- Automação de tarefas de construção*
*- Apoio à decisão baseado em IA para melhoria da produtividade*
*- Integração com princípios de Lean Construction*
*- Uso emergente de LLMs para análise de produtividade*

*Requisitos rigorosos:*
*- Incluir apenas publicações acadêmicas existentes (sem referências inventadas ou incertas)*
*- Priorizar artigos de periódicos e trabalhos de conferências*
*- Focar estritamente na construção (apenas contexto AEC/AECO)*
*Para cada artigo: Título | Autores | Ano | Periódico ou Conferência |*
*DOI ou link (obrigatório) | Resumo (2-3 linhas) | Técnica de IA | Aplicação de produtividade*
*Em seguida:*
*1. Agrupar por tipo de aplicação de produtividade*
*2. Destacar estudos com medição empírica de ganhos de produtividade*
*3. Identificar estudos que integram IA com Lean Construction*
*4. Identificar artigos relacionados a LLMs*
*5. Indicar nível de confiança (alto / médio / baixo)*
*6. Sinalizar explicitamente qualquer incerteza*
*Não invente informações ausentes. Em caso de dúvida, indique "incerto".*
*Inclua sempre um link verificável (preferencialmente DOI).*

A Etapa 2 utilizou a *string* booleana: (*machine learning OR deep learning OR computer vision OR NLP OR Large Language Models OR LLMs OR artificial intelligence*) AND (*productivity tracking OR productivity monitoring OR predictive analytics for project performance OR Lean construction practices driven by AI for waste reduction and productivity gains*) AND (*construction industry OR civil engineering OR construction site*), aplicada às bases Scopus, WoS e SciELO.

## CRITÉRIOS DE ELEGIBILIDADE

Os critérios de inclusão (CI1–CI5) e exclusão (CE1–CE6) são apresentados no Quadro 1.

**Quadro 1: Critérios de inclusão e exclusão**

| **Código** | **Critério** |
|---|---|
| CI1 | Estudo aplicado ao setor AECO (construção civil, infraestrutura, edificações). |
| CI2 | Uso explícito de técnica de Inteligência Artificial (ML, DL, CV, NLP/LLM, otimização ou híbridos). |
| CI3 | Foco em produtividade: monitoramento, eficiência operacional, desempenho de equipes/equipamentos, automação de tarefas ou redução de desperdício — critério diferenciador. |
| CI4 | Publicado em periódico científico ou conferência acadêmica indexada. |
| CI5 | Texto completo disponível em inglês ou português; ano ≥ 2020. |

| Código | Critério |
|---|---|
| CE1 | Fora do setor da construção civil. |
| CE2 | Sem técnica de IA identificável (computação simbólica/estatística pura). |
| CE3 | IA em construção sem vínculo com produtividade/eficiência operacional. |
| CE4 | Fontes não científicas (blogs, relatórios, notícias, white papers). |
| CE5 | Referências não verificáveis — alucinações de IA generativa. |
| CE6 | Duplicatas (intra-bases, entre bases ou entre bases e busca assistida). |

Fonte: Os autores (2026), com base no protocolo PRISMA 2020 [6].

### EXTRAÇÃO E CLASSIFICAÇÃO

A seleção partiu de uma exportação da Web of Science no perfil All Databases, o que implicou a triagem prévia de registros não elegíveis por tipo de documento (teses, patentes, registros de fomento e conjuntos de dados). Todas as decisões de exclusão foram registradas item a item, com o critério correspondente, em planilha auditável disponibilizada como material suplementar. Para cada estudo incluído foram extraídos: identificação bibliográfica, técnica de IA, aplicação de produtividade, ano e ambiente de validação. A classificação de técnica e de aplicação foi obtida por regras reproduzíveis de palavras-chave sobre título e resumo, admitindo múltiplos rótulos por estudo. O nível de maturidade e a forma de mensuração dos ganhos (métrica de modelo versus medida direta em campo) foram tratados de modo qualitativo. A integração com o Lean Construction foi sinalizada quando explicitamente mencionada.

## RESULTADOS

### FLUXOGRAMA PRISMA E COMPOSIÇÃO DO CORPUS

O processo de seleção é apresentado na Figura 1. As buscas em Scopus e SciELO não retornaram nenhum registro para a combinação de termos empregada; apenas a Web of Science forneceu resultados, com 538 registros, recuperados no perfil All Databases. Sobre esses registros aplicaram-se filtros reproduzíveis, em sequência: tipo de documento (CI4), com a exclusão de 118 itens não elegíveis (44 teses, 36 registros de fomento, 29 patentes e 9 conjuntos de dados); idioma (CI5), com 3 exclusões de registros em coreano; e janela temporal, com 98 exclusões de publicações anteriores a 2020. Restaram 319 registros da Core Collection, triados por título e resumo, dos quais 269 foram excluídos — 135 por ausência de foco em produtividade (CE3), 70 por estarem fora do setor AECO (CE1), 32 por não empregarem técnica de IA identificável (CE2) e 32 revisões, excluídas do corpus

primário por decisão de escopo e mantidas como referências de contexto. A busca assistida por IA generativa retornou 28 referências (20 únicas após a deduplicação das listas idênticas de ChatGPT e Gemini), das quais 8 eram alucinações (CE5), 5 duplicavam registros já recuperados na WoS (CE6) e 3 foram excluídas por critério. Somadas as 4 referências verificadas e únicas da busca assistida aos 50 estudos incluídos a partir da WoS, o corpus final contém 54 estudos.

**Figura 1: Fluxograma PRISMA 2020 adaptado**

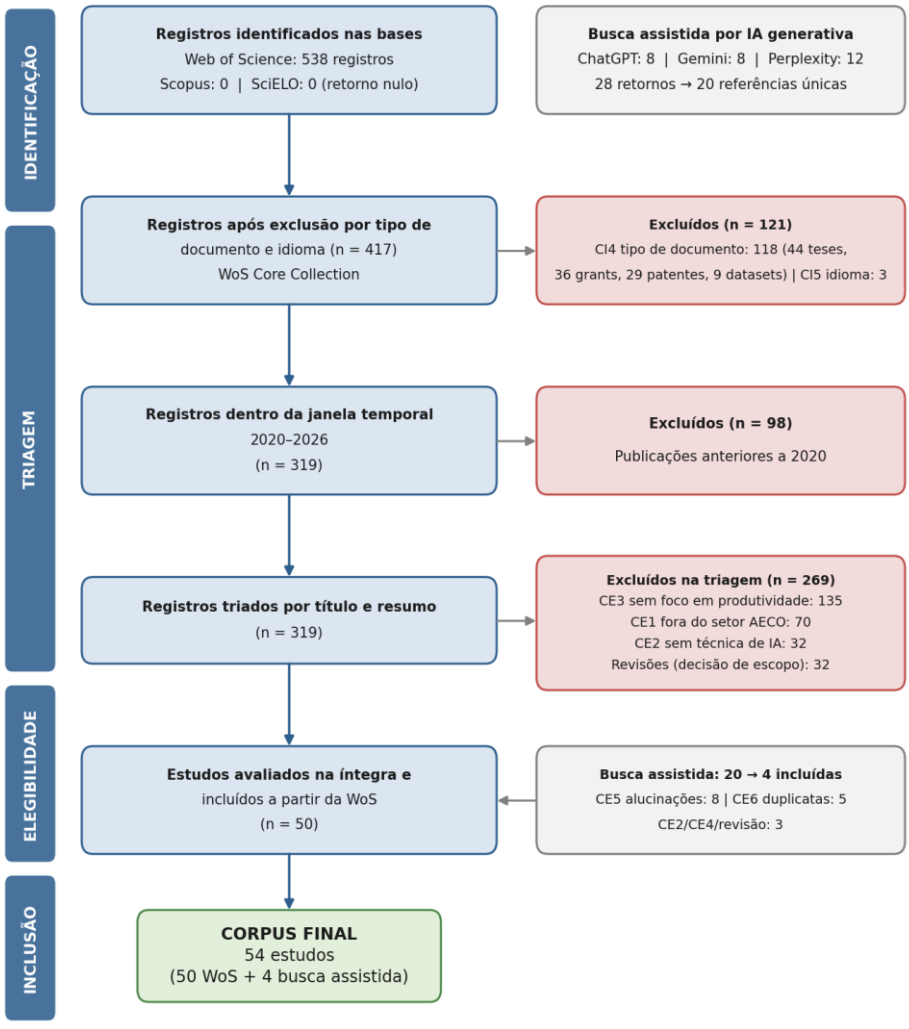


Fonte: Os autores (2026), adaptado de Page et al. [6].

## EVOLUÇÃO TEMPORAL E TÉCNICAS DE IA

A Figura 2 mostra a evolução das publicações por técnica (n = 54, classificação multirrótulo). Observa-se aceleração nítida do campo, com pico em 2025 (13

estudos); os 5 registros de 2026 correspondem a um ano ainda incompleto na data da busca. O aprendizado profundo aplicado à visão computacional (DL/CV) é dominante em todo o período (43 estudos; 79,6% do corpus), seguido de sensores e ML (18), ML clássico (18), otimização/sistemas fuzzy (3) e NLP/LLM (1). O NLP/LLM só aparece em 2026, em um único estudo que emprega modelo visão-linguagem, sinalizando um início de transição ainda não consolidado.

**Figura 2: Evolução temporal das publicações por técnica de IA (2020–2026; n = 54)**

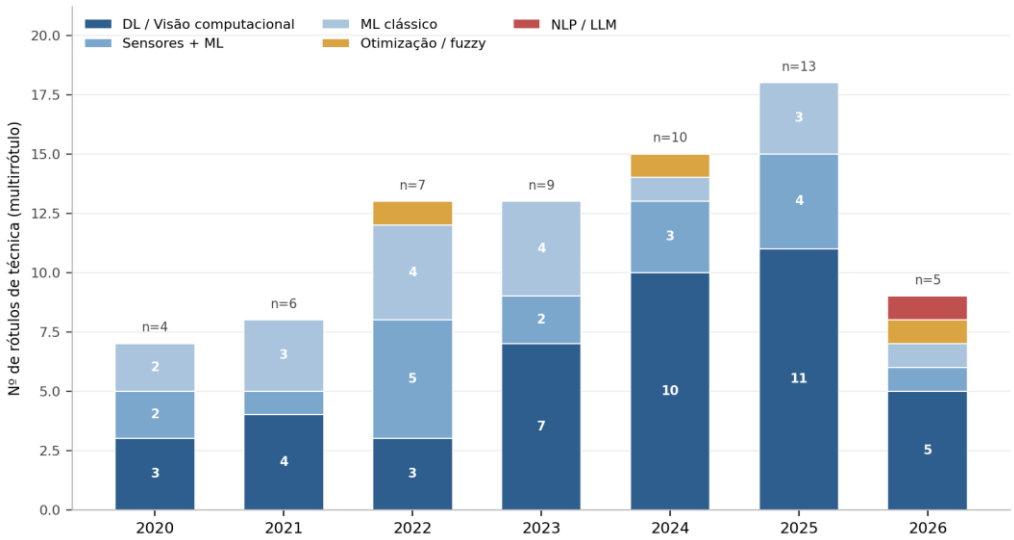


Fonte: Os autores (2026).

## APLICAÇÕES DE PRODUTIVIDADE

A Figura 3 consolida a distribuição de aplicações (multirrótulo): o monitoramento domina o corpus (47 estudos), seguido de produtividade de equipamentos (36), reconhecimento de atividade (29), automação de tarefas (27), produtividade de mão de obra (26) e previsão/*forecast* de desempenho (18). Em contraste marcante, apenas 4 estudos (7,4%) mencionam Lean Construction ou redução de desperdício, ainda que em parte no nível terminológico, indicando deslocamento da literatura para problemas de fácil instrumentação visual.

Qualitativamente, predominam trabalhos em estágio experimental ou de validação com dados gravados, sendo escassos os casos de aplicação real em canteiro operacional. Um exemplo verificado de aplicação real é Mahamedi et al. [7], que mediu a produtividade de escavadeira em obra de demolição com 99,78% de acurácia a partir de sensores de smartphone.

**Figura 3: Distribuição por tipo de aplicação de produtividade (n = 54)**

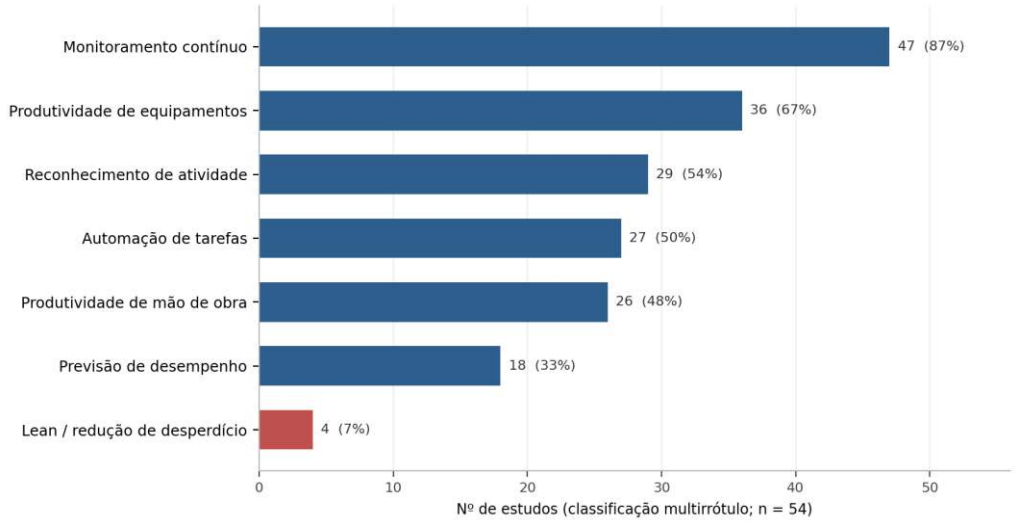


Fonte: Os autores (2026).

## VALIDAÇÃO DA BUSCA ASSISTIDA: ALUCINAÇÕES DE IA

A Figura 4 sintetiza o achado metodológico central da busca assistida. A discrepância entre as ferramentas é acentuada: os modelos conversacionais generalistas (ChatGPT e Gemini) retornaram listas idênticas e inventaram a totalidade das 8 referências sugeridas — títulos plausíveis, autores reconhecidos da área e DOIs sintaticamente válidos que, verificados um a um, não correspondem a nenhuma publicação existente. Já a Perplexity, cuja arquitetura ancora as respostas em mecanismos de busca, não produziu nenhuma referência inexistente: 11 dos 12 itens tiveram o DOI confirmado no site do editor e o restante foi excluído por não se comprovar veículo revisado por pares (CE4). A taxa agregada de 40% sobre as 20 referências únicas demonstra que a validação manual permanece inegociável, sob pena de contaminar a revisão com fontes inexistentes; o aproveitamento final foi de apenas 4 referências únicas incorporadas ao corpus, todas provenientes da Perplexity.

Quanto à integração com o Lean Construction, além da menção rara já reportada (4 estudos; 7,4%), os casos com acoplamento efetivo são escassos. O exemplo mais robusto é Saini & Thomas [8], que combina previsão por regressão com Value Stream Mapping, alcançando aumento de 13,7% na produtividade de armação; Salhab et al. [9] integram visão computacional e sistemas fuzzy a princípios Lean para gestão de workspace, identificando desperdícios em tempo real.

DOI: https://doi.org/10.46421/entac.v21i1.8595

**Figura 4: (a) Referências verificadas vs. alucinações; (b) Taxa de alucinação por modelo de IA generativa**

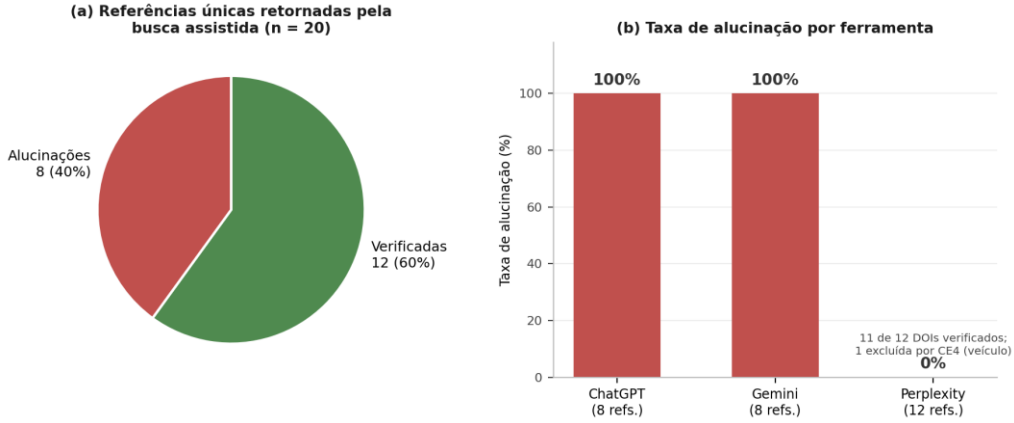


Fonte: Os autores (2026).

## ESTUDOS VERIFICADOS REPRESENTATIVOS

O Quadro 2 detalha estudos verificados representativos do corpus, com técnica de IA, aplicação, métrica reportada e ambiente de validação, selecionados pelo vínculo direto com produtividade e pela diversidade (mão de obra, equipamento, modular).

**Quadro 2: Estudos verificados representativos e métricas reportadas**

| Estudo (Autores) | Técnica de IA | Aplicação | Ganho mensurado | Ambiente |
|---|---|---|---|---|
| Cheng et al. [10] | Visão computacional (DL) sobre vídeo | Reconhecimento de atividade e produtividade de escavadeiras | Supervisão de operações e medição de produtividade de terraplanagem em tempo real por visão computacional | Canteiro de terraplanagem |
| Mahamedi et al. [7] | DL com sensores de smartphone (cinemática + áudio) | Monitoramento de produtividade de escavadeira em demolição | 99,78% de acurácia na medição automática da produtividade em projeto real | Obra de demolição real |
| Saini & Thomas [8] | Regressão multivariada (ML) integrada a Value Stream Mapping | Previsão de produtividade em armação + redesenho Lean | $R^2$ = 0,91-0,95; aumento de 13,7% na produtividade e eficiência de processo de 68,9% | Edifício alto (obra real) |

| Estudo (Autores) | Técnica de IA | Aplicação | Ganho mensurado | Ambiente |
|---|---|---|---|---|
| | | | para 82,6% | |
| Jeong et al. [11] | DL sintético + ontologia para grua-torre | Monitoramento de produtividade de operações de grua em fachada | 93,58% de acurácia na análise de atividade; 300 mil imagens em 1 h vs. dias de rotulação manual | Obra ativa |
| Wang et al. [12] | Multi-Object Tracking (YOLO+DeepSORT) | Análise de produtividade de transporte por cabos em barragem | IDF1 = 95,9%; MOTA = 92,1% em três vídeos longos de obra real | Barragem (obra real) |
| Baek, Kim & Choi [13] | CNN + transformer dual-stream | Monitoramento de produtividade de instalação modular off-site | Acurácia média de 89% em cinco atividades; medição automática da produtividade de instalação modular | Obra modular |
| Salhab et al. [9] | CV + sistemas fuzzy para Lean workspace | Detecção de desperdícios de fluxo e congestionamento em workspace | Cinco métricas espaciais e Índice Espaço-Temporal (STI) para gestão de espaço; estudo de caso real | Obra real |

Fonte: Os autores (2026), com base nas referências citadas.

O Quadro 2 evidencia um padrão recorrente: os estudos verificados reportam métricas técnicas de altíssima qualidade (acurácia de 89% em Baek, Kim & Choi [13]; MOTA = 92,1% em Wang et al. [12]), mas o vínculo com ganho real de produtividade é rigorosamente demonstrado apenas em Saini & Thomas [8]. Isto sugere que a indústria possui hoje a capacidade de medir, mas não necessariamente de melhorar, a produtividade.

## SÍNTESE DAS QUESTÕES DE PESQUISA

O Quadro 3 sintetiza as respostas obtidas para cada questão de pesquisa.

**Quadro 3: Síntese das respostas às questões de pesquisa**

| OP | Síntese da evidência |
|---|---|
| OP1 | Aplicação dominante foi sobre o monitoramento contínuo (work sampling automatizado, 47 estudos) e o reconhecimento de atividade (29), seguidos da automação de tarefas (27) e da previsão de desempenho (18). |
| OP2 | DL/visão computacional é majoritário com 43 estudos (79,6%), seguido de sensores e ML (18) e ML clássico (18). Estudos sobre otimização/fuzzy (3) e NLP/LLM (1) são marginais. |
| OP3 | A maioria dos estudos reporta métricas de modelo (acurácia, F1, MOTA), enquanto a medição direta de ganho de produtividade em campo é rara. |
| OP4 | A maturidade não foi quantificada, qualitativamente predominam estudos experimentais e de validação em dados gravados, com poucos casos de aplicação real documentada. |
| OP5 | Aplicações em canteiro real são escassas: Mahamedi et al. [7] (escavadeira em demolição real) e Cheng et al. [10] (terraplanagem). A maioria valida-se em conjuntos de dados pré-gravados. |
| OP6 | Integração com Lean é rara, apenas 4 estudos (7,4%) a mencionam. O caso mais robusto é Saini & Thomas [8], com ganho empírico de 13,7% via Value Stream Mapping. |
| OP7 | LLMs aplicados à produtividade são tendência ainda não consolidada: um único estudo do corpus (2026) emprega modelo visão-linguagem, e a evidência restante vem de revisões mantidas como contexto [4]. Não há aplicação validada de LLM com ganho de produtividade mensurado em canteiro. |
| OP8 | A produção brasileira é quase ausente: apenas 6 dos 417 registros da Core Collection têm afiliação no Brasil, contra China (111), EUA (100) e Coreia do Sul (65) — e nenhum deles chegou ao corpus final. |

Fonte: Os autores (2026).

## SATURAÇÃO, LACUNAS E LIMITAÇÕES RECORRENTES

O corpus revela área com saturação parcial em monitoramento de equipamentos por visão (escavadeiras, gruas, caminhões) e lacuna severa em três frentes: (i) integração efetiva com Lean Construction; (ii) reconhecimento de atividade de mão de obra em canteiro real, ainda dominado por estudos de laboratório e *datasets* sintéticos [14]; e (iii) uso de LLMs/MLLMs para análise de produtividade, em estágio embrionário [4].

As limitações metodológicas mais recorrentes são: (a) *datasets* restritos ao *site* específico, com baixa generalização [2]; (b) infraestrutura digital exigida raramente disponível em obras de pequeno e médio porte; (c) reporte de métricas de modelo sem tradução em indicadores de produção; e (d) ausência de análises custo-benefício

de implantação. Esses fatores explicam, em larga medida, a escassez de aplicações reais em canteiro.

## DISCUSSÃO

À luz dos objetivos específicos e das lacunas apontadas na introdução, os resultados indicam um campo concentrado na captura e classificação de dados por visão computacional, com fragilidades persistentes na tradução desses dados em ganho de produtividade, na integração com o Lean Construction e na consolidação dos LLMs. As subseções a seguir discutem essas frentes e o contexto brasileiro.

O único estudo do corpus classificado como NLP/LLM emprega um modelo visão-linguagem para reconhecimento de ações em vídeo, e não o processamento de linguagem como fim; a evidência disponível sobre o potencial dos MLLMs vem de revisões mantidas como referência de contexto [4], excluídas do corpus primário por decisão de escopo. Não foi identificado nenhum estudo em que um LLM produza, por si, ganho de produtividade mensurado em canteiro. A oportunidade mais promissora aponta para arquiteturas Retrieval-Augmented Generation (RAG) acopladas a sistemas Last Planner, com diagnóstico em linguagem natural sobre dados de produção, ainda inexploradas empiricamente.

## CONSIDERAÇÕES FINAIS

Esta RSL, conduzida sob o protocolo PRISMA 2020 com base verificável na Web of Science e validação manual da busca assistida, mapeou 54 estudos sobre IA aplicada à produtividade na construção civil entre 2020 e 2026, respondendo aos oito objetivos específicos. Retomando as lacunas apontadas, observa-se que a literatura concentra-se em monitoramento por visão computacional (79,6% dos estudos), com prevalência da captura e classificação de dados sobre a melhoria efetiva de processos, sendo escassa a aplicação validada em canteiro real (OP4–OP5). Segundo, persistem lacunas relevantes como a baixa integração com o Lean Construction com 4 estudos e os LLMs com 1 estudo, sem ganho de produtividade mensurado em canteiro (OP6-OP7). Ademais, a produção brasileira é quase inexistente, com apenas 6 registros indexados e nenhum estudo no corpus final. Como contribuição metodológica transversal, o estudo documenta empiricamente os riscos do uso de IA generativa em pesquisa, com taxas de alucinação de até 100%, reforçando a validação manual como etapa inegociável.

Para a agenda de pesquisa no Brasil, recomenda-se priorizar estudos de aplicação real em canteiros brasileiros, com mensuração direta de ganhos, desenvolver soluções de baixo custo adequadas à realidade nacional e explorar o acoplamento

entre LLMs e o Last Planner System. As limitações desta revisão incluem o recorte temporal restrito a 2020–2026, a dependência de uma única base com retorno efetivo (Web of Science), uma vez que Scopus e SciELO não retornaram registros, e o uso de classificação por palavras-chave.

## DECLARAÇÃO

Durante a preparação deste artigo, os autores utilizaram a ferramenta Perplexity para revisão do texto. 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]** BÜHLER, M. M.; NÜBEL, K.; JELINEK, T. Bridging the Construction Productivity Gap: a Hierarchical Framework for the Age of Automation. **Buildings**, v. 15, n. 16, art. 2899, 2025. DOI: https://doi.org/10.3390/buildings15162899.

**[2]** LIM, Y. T.; YI, W.; WANG, H. Application of machine learning in construction productivity at activity level: a critical review. **Applied Sciences**, v. 14, n. 22, art. 10605, 2024. DOI: https://doi.org/10.3390/app142210605.

**[3]** FONSECA, M. P. C. da; WEBER, A. de O. S.; WEBER, I.; PHILIPPSEN JR., L.; BARBOSA, C. A. S. Utilização da filosofia Lean Construction em pequena empresa da construção civil por meio da gestão visual do canteiro de obra. *In*: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 20., 2024, Maceió. **Anais [...]** Porto Alegre: ANTAC, 2024. p. 1-11. DOI: https://doi.org/10.46421/entac.v20i1.6383.

**[4]** ERFANI, A.; MANSOURI, A. Applications of multimodal large language models in construction industry. **Advanced Engineering Informatics**, v. 69, parte A, 2026. DOI: https://doi.org/10.1016/j.aei.2025.103909.

**[5]** LANDIM, G. L.; PAIVA JÚNIOR, F. A. A.; BARROS NETO, J. de P.; LIMA, M. M. X. Implementação conjunta de Lean Construction e BIM: revisão sistemática de literatura. *In*: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 19., 2022, Canela. **Anais [...]** Porto Alegre: ANTAC, 2022.

**[6]** PAGE, M. J.; McKENZIE, J. E.; BOSSUYT, P. M. *et al.* The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. **BMJ**, v. 372, n. 71, 2021. DOI: https://doi.org/10.1136/bmj.n71.

**[7]** MAHAMEDI, E.; ROGAGE, K.; DOUKARI, O.; KASSEM, M. Automating excavator productivity measurement using deep learning. **Proceedings of the Institution of Civil Engineers — Smart Infrastructure and Construction**, v. 174, n. 4, p. 121-133, 2022. DOI: https://doi.org/10.1680/jsmic.21.00031.

**[8]** SAINI, A.; THOMAS, A. Development of a machine learning-based labour productivity prediction tool to practice lean construction. *In*: ANNUAL CONFERENCE OF THE INTERNATIONAL GROUP FOR LEAN CONSTRUCTION, 31., 2023, Lille. **Proceedings [...]** Lille: IGLC, 2023. DOI: https://doi.org/10.24928/2023/0209.

**[9]** SALHAB, D.; SABEK, M.; POURRAHIMIAN, E. *et al.* Integrated framework of computer vision and fuzzy systems for lean workspace management in construction. **Automation in Construction**, 2026. DOI: https://doi.org/10.1016/j.autcon.2025.106618.

**[10]** CHENG, M.-Y.; CAO, M.-T.; NURALIM, C. K. Computer vision-based deep learning for supervising excavator operations and measuring real-time earthwork productivity. **The Journal of Supercomputing**, v. 79, 2023. DOI: https://doi.org/10.1007/s11227-022-04803-x.

**[11]** JEONG, I.; HWANG, J.; KIM, J.; CHI, S.; HWANG, B.-G.; KIM, J. Vision-based productivity monitoring of tower crane operations during curtain wall installation using a database-free approach. **Journal of Computing in Civil Engineering**, v. 37, n. 4, art. 04023015, 2023. DOI: https://doi.org/10.1061/JCCEE5.CPENG-5105.

**[12]** WANG, H.; YANG, Q.; LIU, Q.; ZHAO, C.; ZHOU, W.; ZHANG, H.; LIU, J. Automated productivity analysis of cable crane transportation using deep learning-based multi-object tracking. **Automation in Construction**, v. 166, art. 105644, 2024. DOI: https://doi.org/10.1016/j.autcon.2024.105644.

**[13]** BAEK, J.; KIM, D.; CHOI, B. Deep learning-based automated productivity monitoring for on-site module installation in off-site construction. **Developments in the Built Environment**, v. 18, art. 100382, 2024. DOI: https://doi.org/10.1016/j.dibe.2024.100382.

**[14]** BAN, J.; KIM, D.; KIM, T. W.; CHOI, B. Feasibility of VR-generated synthetic data for automated productivity monitoring in modular construction. **Automation in Construction**, 2025. DOI: https://doi.org/10.1016/j.autcon.2025.106432.