



**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
FACULDADE DE ENGENHARIA CIVIL**



**LEANDRO DE SOUSA
GUSTAVO COELHO**

ESTIMATIVA PRELIMINAR DE QUANTITATIVOS E ORÇAMENTOS COM LLMs

Belém - PA
Julho/2026

LEANDRO DE SOUZA
GUSTAVO COELHO

**ESTIMATIVA PRELIMINAR DE QUANTITATIVOS E ORÇAMENTOS
COM LLMs**

Trabalho de Conclusão de Curso apresentado à
Faculdade de Engenharia Civil do Instituto de
Tecnologia da Universidade Federal do Pará,
como parte dos requisitos para obtenção do título
de Bacharel em Engenharia Civil.

Orientador: Prof. Felipe Moreira de Sá

Belém
Julho/2026

LEANDRO DE SOUZA
GUSTAVO COELHO

**ESTIMATIVA PRELIMINAR DE QUANTITATIVOS E ORÇAMENTOS
COM LLMs**

Belém, 17 de Julho de 2026.

Prof. Felipe Moreira de Sá
Dr. pela UFPA
Orientador

BANCA EXAMINADORA

Profa. Luciana de N. P. Cordeiro (UFPA)
Dra. pela UFRGS

Prof. Luiz Maurício F. Maués (UFPA)
Dr. pela UFPA

CONCEITO FINAL: 7,0

ESTIMATIVA PRELIMINAR DE QUANTITATIVOS E ORÇAMENTOS COM LLMs

Faculdade de Engenharia Civil - Universidade Federal do Pará

RESUMO

A estimativa preliminar de quantitativos e custos é relevante para a avaliação de viabilidade de empreendimentos, mas é desenvolvida em contexto de informações técnicas incompletas. Este estudo avaliou a aplicabilidade de uma inteligência artificial generativa baseada em modelo de linguagem de grande porte (LLM) para estimar quantitativos de serviços de um conjunto habitacional de interesse social e verificar sua repercussão no orçamento. A pesquisa, de natureza aplicada, quantitativa e comparativa, foi conduzida como estudo de caso em um empreendimento de 25 casas térreas em Ibiraiaras/RS. A partir de premissas de pré-projeto, foi gerada uma Estrutura Analítica do Projeto (EAP) quantitativa, compatibilizada com o orçamento executivo e valorada com custos unitários equivalentes. Foram comparados os cenários otimista, primário e pessimista ao orçamento executivo de referência. O orçamento executivo totalizou R\$ 3.453.894,98, enquanto os cenários estimados alcançaram R\$ 3.044.185,96, R\$ 3.185.622,90 e R\$ 3.644.414,71, respectivamente. Os resultados indicaram aderência mais favorável em serviços de leitura geométrica direta, mas desvios relevantes em instalações, cobertura, supraestrutura, pintura e itens externos. O orçamento executivo foi enquadrado pela faixa dos três cenários, evidenciando utilidade do método para apoiar decisões de viabilidade no pré-projeto. Conclui-se que o LLM pode estruturar uma estimativa inicial e orientar prioridades de conferência, mas não substitui o levantamento de quantitativos e a orçamentação executiva conduzidos com documentação técnica detalhada.

Palavras-chave: Inteligência artificial generativa; Modelos de linguagem de grande porte; Quantitativos de serviços; Estimativa de custos; Habitação de interesse social.

ABSTRACT

Preliminary quantity and cost estimation is relevant to the feasibility assessment of construction projects, but it is developed under incomplete technical information. This study evaluated the applicability of a generative artificial intelligence tool based on a large language model (LLM) for estimating construction service quantities for a social housing development and assessing their impact on the budget. The applied, quantitative and comparative study was conducted as a case study involving 25 single-storey houses in Ibiraiaras, Rio Grande do Sul, Brazil. Based on pre-design assumptions, a quantitative work breakdown structure was generated, reconciled with the executive budget, and valued using equivalent unit costs. Optimistic, primary, and pessimistic scenarios were compared with the reference executive budget. The executive budget totaled BRL 3,453,894.98, while the estimated scenarios reached BRL 3,044,185.96, BRL 3,185,622.90, and BRL 3,644,414.71, respectively. Results showed better agreement for services with direct geometric interpretation, but relevant deviations for installations, roof work, superstructure, painting, and external items. The executive budget was encompassed by the range formed by the three scenarios, indicating that the method can support early feasibility decisions. It is concluded that LLMs can organize an initial estimate and identify review priorities, but they do not replace detailed quantity takeoff and executive cost estimation based on complete technical documentation.

Keywords: Generative artificial intelligence; Large language models; Construction quantities; Cost estimation; Social housing.

1 INTRODUÇÃO

Na fase de pré-projeto, a estimativa de custos orienta a análise de viabilidade e a decisão de investir, embora as informações técnicas ainda sejam incompletas. Uma previsão inadequada pode comprometer recursos e desempenho financeiro. Por isso, a estimativa inicial deve ser rápida, coerente e transparente (Habib et al., 2025; Chen et al., 2025). Em projetos habitacionais, tipologia, área, localização e sistema construtivo influenciam o resultado. Assim, a precisão esperada deve ser compatível com a incerteza do estudo conceitual, e não com um orçamento executivo detalhado (Alrasheed et al., 2026).

Para responder a essa necessidade, a inteligência artificial vem sendo aplicada à previsão de custos e à organização de materiais, serviços e preços. Essas aplicações reduzem tarefas manuais e tornam o planejamento financeiro mais ágil (Tripathi et al., 2026; Vaisnave; Mythily, 2025). No levantamento de quantitativos, modelos de linguagem convertem descrições técnicas em listas de serviços, unidades e memórias de cálculo. Contudo, a qualidade depende de escopo claro, regras de medição e formato de saída definido (Zhang et al., 2025; Ghasemi; Dai, 2024).

Entre as aplicações de inteligência artificial, os modelos de linguagem de grande porte interpretam solicitações em linguagem natural e produzem respostas estruturadas. Eles são estudados como apoio a tarefas de consulta, planejamento e decisão na construção (Taiwo et al., 2025; Saka et al., 2024). Ainda assim, o uso em processos orçamentários exige limites, critérios de conferência e rastreabilidade. Respostas bem escritas podem não refletir por completo o contexto técnico. Regras, códigos, unidades e bases normativas ajudam a manter a auditabilidade e reforçam a revisão humana (Nguyen et al., 2026; Martin; James; Chadee, 2025).

Diante dessas possibilidades e limites, as estimativas geradas automaticamente devem ser confrontadas com referências técnicas e financeiras. A organização modular, o uso de bases externas e a análise de desvios permitem avaliar sua consistência e utilidade decisória (Ghimire et al., 2026; Ghasemi; Dai, 2024; Chen et al., 2025). Assim, esta pesquisa tem por objetivo avaliar a aplicabilidade de uma IA generativa baseada em LLM na estimativa preliminar de quantitativos de serviços para um empreendimento habitacional de interesse social e verificar a repercussão desses quantitativos no orçamento. Para tanto, os cenários otimista, primário e pessimista, valorados com custos unitários do SINAPI, são comparados ao orçamento executivo de referência do PNCP, buscando-se verificar a proximidade dos quantitativos e dos valores totais e a utilidade do método para subsidiar decisões de viabilidade no pré-projeto.

2 REFERENCIAL TEÓRICO

A estimativa de custos é decisiva nas primeiras decisões de um empreendimento. Ela orienta estudos de viabilidade, captação de recursos e escolha de alternativas técnicas. Nessa fase, porém, o escopo ainda está incompleto e parte das informações é preliminar. Por isso, a previsão precisa considerar a incerteza e apresentar valores coerentes com o nível de definição do projeto (Habib et al., 2025; Chen et al., 2025). Características como área, tipologia, localização, sistema construtivo e padrão de acabamento influenciam o resultado. A seleção desses fatores é indispensável para que a estimativa tenha utilidade prática e apoie as decisões iniciais (Alrasheed et al., 2026; Vaisnave; Mythily; Kirubakaran, 2025).

Os métodos de estimativa variam conforme o grau de detalhamento do projeto. Nos estudos iniciais, são frequentes as comparações com obras semelhantes, os custos por área e os modelos paramétricos. Essas abordagens ajudam a produzir uma faixa de valor com rapidez, mas dependem de premissas claras e de dados compatíveis (Ghimire et al., 2026; Tripathi et al., 2026). Com o avanço do projeto, a obra pode ser separada em sistemas, pacotes e serviços. Essa decomposição facilita a conferência do escopo e reduz o risco de omitir itens relevantes, sobretudo quando os documentos técnicos apresentam informações dispersas (Ghasemi; Dai, 2024; Zhang et al., 2025).

A transformação digital da construção ampliou a produção e o uso de dados durante todo o ciclo do empreendimento. Projetos, especificações, contratos, planilhas e relatórios concentram informações úteis para o planejamento e o controle. Contudo, esses documentos costumam ter formatos distintos e nem sempre estão organizados para consulta rápida. A integração e a interpretação desse conteúdo permanecem como desafios para o setor (Saka et al., 2024; Taiwo et al., 2025). Nesse contexto, tecnologias de linguagem natural podem apoiar a leitura de descrições técnicas e a organização de informações. Os estudos indicam que os resultados são melhores quando o usuário apresenta um escopo claro e revisa cuidadosamente o material gerado (Prieto; Mengiste; García de Soto, 2023; Sands; Wang; Zhao, 2025).

Para que a automação seja confiável, não basta obter uma resposta rápida. É preciso saber quais dados foram usados, quais regras orientaram a tarefa e quais limites devem ser considerados. Esse cuidado permite comparar estimativas e justificar escolhas técnicas, sobretudo quando os resultados apoiam decisões financeiras ou administrativas (Nobakhtfar; Çakılcı; Zilan, 2026; Nguyen et al., 2026). A governança do uso de IA também exige protocolos de interação e revisão profissional. Em processos de orçamento e licitação, o resultado pode

mudar conforme o contexto fornecido e a forma de estruturar a solicitação (Heo; Park; Ahn, 2025; Martin; James; Chadee, 2025).

Os modelos de aprendizagem de máquina são investigados porque os custos de uma obra resultam de relações complexas entre características físicas, condições de mercado e escolhas de execução. Redes neurais e modelos de ensemble buscam identificar padrões em dados históricos e apoiar previsões em cenários com múltiplas variáveis (Habib et al., 2025; Alrasheed et al., 2026). Entretanto, o desempenho numérico não é o único critério de qualidade. A literatura destaca a necessidade de analisar a incerteza das previsões e de explicar os fatores que influenciam o valor estimado (Chen et al., 2025; Vaisnave; Mythily; Kirubakaran, 2025).

O levantamento de quantitativos é uma etapa central para transformar o escopo técnico em orçamento. Antes de aplicar preços, é necessário identificar serviços, materiais, unidades e medidas presentes no empreendimento. Quando essa tarefa é realizada manualmente, a leitura de plantas, memoriais e especificações pode ser demorada e sujeita a diferenças de interpretação (Zhang et al., 2025; Ghasemi; Dai, 2024). Por isso, pesquisas recentes combinam modelos de linguagem, organização de fluxos e listas de materiais para tornar a extração de dados mais rápida e verificável. Ainda assim, a conferência dos quantitativos continua indispensável para garantir consistência (Tripathi et al., 2026; Ghimire et al., 2026).

A IA generativa ampliou a possibilidade de interagir com documentos técnicos por meio da linguagem natural. No setor da construção, os modelos de linguagem vêm sendo estudados para consultar informações, apoiar o planejamento, selecionar materiais e organizar atividades preliminares (Saka et al., 2024; Taiwo et al., 2025). A tecnologia pode reduzir tarefas repetitivas e acelerar a preparação de informações. Contudo, experiências de uso em planejamento e ensino reforçam que a análise crítica do profissional é necessária para avaliar a clareza, a completude e a coerência das respostas (Prieto; Mengiste; García de Soto, 2023; Sands; Wang; Zhao, 2025).


Em aplicações de orçamento, a integração entre IA e fontes técnicas confiáveis é decisiva para evitar respostas genéricas. Códigos de serviços, regras de medição, bases de custos e rotinas de conferência ajudam a manter a ligação entre os dados do projeto e o resultado apresentado. Esse controle é especialmente importante em ambientes regulados e competitivos (Nobakhtfar; Çakılcı; Zilan, 2026; Heo; Park; Ahn, 2025). Assim, o estado da arte aponta para uma abordagem híbrida: a automação apoia a organização e a análise de informações, enquanto a validação humana preserva a rastreabilidade, a responsabilidade e a adequação técnica das decisões (Nguyen et al., 2026; Martin; James; Chadee, 2025).

3 METODOLOGIA

O objeto de estudo foi um conjunto habitacional do Programa Minha Casa, Minha Vida, localizado em Ibiraiaras/RJ e composto por 25 casas térreas unifamiliares em alvenaria. Cada unidade possui 52,72 m², com dois dormitórios, sala e cozinha, banheiro, varanda e área de serviço. As moradias possuem estrutura de concreto armado, cobertura de fibrocimento e forro em PVC. Os projetos, os memoriais e a planilha orçamentária foram utilizados como referência para o orçamento executivo.

A pesquisa é aplicada, quantitativa e comparativa, desenvolvida como estudo de caso. O método foi delineado em seis etapas: (1^a) definição de premissas de viabilidade; (2^a) planejamento de interação; (3^a) geração da EAP quantitativa pelo LLM; (4^a) compatibilização das EAPs e dos custos unitários; (5^a) geração dos cenários; e (6^a) análise comparativa dos resultados.

Figura 1 - Fluxograma metodológico




Fonte: Elaborado pelos autores (2026).

A 1ª etapa consistiu na definição das premissas de viabilidade. Foram estabelecidas as informações básicas para iniciar o estudo, pois a situação analisada representava uma fase de pré-projeto. Consideraram-se o tipo de empreendimento, a área e o número de unidades, os ambientes previstos, o sistema construtivo e os materiais principais. A fundação também foi

adotada como hipótese inicial, uma vez que não havia sondagem do solo nesta etapa. Essas informações serviram de base para estimar os serviços, mas permaneceram registradas como premissas passíveis de revisão com o desenvolvimento de projetos mais detalhados.

Na 2ª etapa, foi realizado o planejamento de interação com o LLM, definindo-se o tipo de moradia, a área, o número de unidades, os materiais previstos, os limites do estudo e o formato esperado da resposta: uma EAP com serviços diretos, unidades de medida e quantitativos por casa e para o conjunto. A Figura 2 registra essa entrada metodológica e a saída inicial do LLM, evidenciando que as premissas foram convertidas em uma organização preliminar de serviços e quantidades, sem substituir o projeto executivo. A área de 50 m² indicada no registro visual correspondeu à premissa arredondada utilizada na etapa inicial de viabilidade; posteriormente, a comparação foi realizada com o orçamento executivo do empreendimento de referência, cujas unidades possuem 52,72 m². A estruturação da interação reduziu respostas genéricas e permitiu registrar o que foi solicitado e o que foi gerado, facilitando a conferência posterior (Zhang et al., 2025).

Figura 2 - Registro visual de interação entre usuário e LLM na entrada do problema



Fonte: Elaborado pelos autores (2026).

Na 3ª etapa, ocorreu a geração da EAP estimada. O LLM foi utilizado para transformar as premissas do estudo em uma EAP quantitativa. A estrutura dividiu a obra em partes mais fáceis de interpretar, como fundação, estrutura, paredes, cobertura, instalações e acabamentos. Para cada serviço, foram indicadas a descrição, a unidade de medida, a quantidade estimada por moradia e a quantidade total para as 25 unidades. Em seguida, a EAP foi revisada para verificar a coerência dos serviços com o tipo de construção e para separar os itens diretos dos indiretos (Ghimire et al., 2026).

Na 4ª etapa, foi realizada a compatibilização das EAPs e dos custos unitários. A EAP estimada foi comparada ao orçamento executivo para que os dois documentos tratassem de serviços equivalentes. Itens com nomes diferentes, mas com a mesma finalidade, foram aproximados; itens repetidos foram retirados; e as unidades de medida foram padronizadas. Depois disso, cada serviço equivalente recebeu o mesmo custo unitário, com base nas composições SINAPI adotadas no estudo. Assim, a comparação passou a evidenciar principalmente as diferenças entre os quantitativos estimados e os quantitativos do orçamento de referência, sem misturar esse efeito a alterações de preço.

Na 5ª etapa, foram gerados os cenários. A EAP já compatibilizada foi utilizada para compor três cenários de custo. O cenário primário manteve as quantidades consideradas mais prováveis para o empreendimento. No cenário otimista, foram reduzidas as quantidades dos serviços com maior incerteza na fase inicial; no pessimista, essas quantidades foram aumentadas. Os custos unitários permaneceram iguais nos três cenários, de modo que qualquer alteração no valor total estivesse vinculada exclusivamente à variação dos quantitativos.

Na 6ª etapa, foi realizada a análise comparativa dos resultados. Os valores totais dos três cenários foram comparados ao orçamento executivo de referência disponível no PNCP. Foram calculadas as diferenças em reais, os percentuais de desvio e o índice de custo de cada cenário, apresentados em tabelas e gráficos. A análise buscou identificar qual cenário ficou mais próximo da referência e se a faixa formada pelos cenários otimista, primário e pessimista seria útil para apoiar uma decisão inicial. Os registros dos prompts, das premissas e das compatibilizações foram mantidos para permitir a conferência e a repetição do procedimento (Ghasemi; Dai, 2024; Martin; James; Chadee, 2025).

4 RESULTADOS E DISCUSSÃO

O orçamento executivo foi adotado como base de comparação para a avaliação dos três cenários estimados - otimista, primário e pessimista - e totalizou R\$ 3.453.894,98, sem BDI. Como os quatro orçamentos utilizaram a mesma base de custos unitários, as diferenças financeiras analisadas decorrem essencialmente das variações dos quantitativos de serviços. Assim, a análise se inicia pela aderência física dos serviços selecionados e, somente depois, examina o desdobramento dessas diferenças no valor global e nas macroetapas do orçamento.

Tabela 1 – Comparação dos quantitativos dos serviços seleccionados entre o orçamento executivo e os cenários estimados

Serviço seleccionado	Unid.	Exec.	Otimista Qtd.	Otimista Desv.	Primário Qtd.	Primário Desv.	Pessimista Qtd.	Pessimista Desv.
Locação convencional de obra com gabarito	m	795	712,5	-10,38%	750	-5,66%	825	+3,77%
Escavação de vala para viga baldrame	m³	150,75	214,2	+42,09%	252	+67,16%	327,6	+117,31%
Fôrma para viga baldrame em madeira	m²	835,75	756	-9,54%	840	+0,51%	1.176	+40,71%
Reaterro de valas com compactação	m³	117,75	133,88	+13,69%	157,5	+33,76%	204,75	+73,89%
Impermeabilização com emulsão asfáltica	m²	942,25	945	+0,29%	1.050	+11,44%	1.470	+56,01%
Alvenaria de vedação em bloco cerâmico	m²	3.260,75	3.492	+7,09%	3.600	+10,40%	4.032	+23,65%
Chapisco em paredes internas e externas	m²	6.434,75	6.840	+6,30%	7.200	+11,89%	8.280	+28,68%
Revestimento cerâmico de paredes	m²	739,75	570	-22,95%	600	-18,89%	690	-6,73%
Contrapiso em argamassa	m²	1.167,25	1.187,5	+1,73%	1.250	+7,09%	1.437,5	+23,15%
Revestimento cerâmico de piso	m²	1.167,25	1.187,5	+1,73%	1.250	+7,09%	1.437,5	+23,15%
Pintura látex acrílica em paredes externas	m²	2.929,5	1.805	-38,39%	1.900	-35,14%	2.185	-25,41%
Forro em régua de PVC	m²	1.423,25	1.104,38	-22,40%	1.162,5	-18,32%	1.336,88	-6,07%
Tubo PVC para esgoto DN 100 mm	m	1.050	285	-72,86%	300	-71,43%	360	-65,71%

Fonte: Elaborado pelos autores (2026)


A Tabela 1 evidencia que os quantitativos estimados apresentaram maior aderência nos serviços associados diretamente à geometria da edificação. No cenário primário, a fôrma para viga baldrame apresentou variação de apenas +0,51%, enquanto impermeabilização, alvenaria, chapisco, contrapiso e revestimento cerâmico de piso ficaram entre +7,09% e +11,89%. Para calcular a aderência dos serviços estritamente equivalentes, a escavação foi analisada separadamente, pois, embora cumpra a mesma função construtiva de abertura de vala para a viga baldrame, sua quantidade depende do critério de medição, da geometria adotada para a vala e do método executivo considerado em cada orçamento. Com essa ressalva, sete dos doze serviços comparáveis do cenário primário permaneceram dentro de uma faixa de $\pm 15\%$ em relação ao executivo. Esse desempenho é favorável para uma estimativa preliminar, pois demonstra capacidade de reproduzir quantidades de serviços recorrentes e fornece base inicial para o orçamento; contudo, não permite caracterizar o método como substituto de um levantamento executivo detalhado. Estudos sobre quantificação automatizada indicam que bons resultados dependem de parâmetros estruturados, identificação de itens e vinculação explícita das regras de medição aos dados de projeto (Zhang et al., 2025; Jafary et al., 2026).

Entretanto, a mesma Tabela 1 revela limites relevantes. O tubo de esgoto DN 100 mm permaneceu subestimado em todos os cenários, alcançando -71,43% no primário, e a pintura externa registrou -35,14%; por sua vez, reaterro e escavação apresentaram superestimações importantes. No caso da escavação, a diferença reforça justamente a necessidade de separar a equivalência funcional da equivalência quantitativa: o serviço possui finalidade semelhante nos orçamentos, mas o volume resultante varia conforme dimensões de vala, profundidade, largura e critérios de apropriação. Assim, os resultados são bons para itens de leitura geométrica mais direta, mas insuficientes para serviços cuja quantidade depende de detalhamento de instalações, método executivo, interfaces entre disciplinas e especificações técnicas. Tal comportamento é

coerente com pesquisas que observaram melhoria da consistência quando a tarefa de estimativa é decomposta em módulos e o modelo recebe instruções específicas, dados de apoio e etapas de validação; ainda assim, os resultados de LLMs podem variar em contextos novos (Ghimire et al., 2026; Ghasemi; Dai, 2024).

Em termos de avaliação, portanto, os quantitativos do cenário primário são promissores para a leitura preliminar de itens recorrentes, mas a dispersão observada em instalações e em serviços dependentes do método executivo impede qualificá-los como quantitativos executivos. A necessidade de verificar unidades, descrições, códigos e regras de cálculo é particularmente relevante porque pequenas inconsistências nesses atributos podem se propagar para o valor do serviço e para o total do orçamento. Isso reforça que a contribuição do método está em antecipar uma estrutura inicial de serviços e prioridades de conferência, e não em dispensar a checagem técnica dos itens críticos (Katooziani et al., 2025; Nguyen et al., 2026).

Figura 3 - Comparação entre os orçamentos estimados e o orçamento executivo



Fonte: Elaborado pelos autores (2026).

A conversão dessas diferenças físicas para o valor global é apresentada na Figura 3. Em valores absolutos, o orçamento executivo totalizou R\$ 3.453.894,98; os cenários otimista, primário e pessimista totalizaram, respectivamente, R\$ 3.044.185,96, R\$ 3.185.622,90 e R\$ 3.644.414,71. Entre os cenários, o pessimista foi o mais próximo do orçamento executivo no total global, com desvio de +5,52%, embora o cenário otimista tenha apresentado menor dispersão média no conjunto de quantitativos selecionados da Tabela 1. Essa diferença confirma que a proximidade do valor total pode resultar de compensações entre serviços subestimados e

superestimados. Portanto, a Figura 3 deve ser interpretada como evidência de que a faixa de cenários é útil para a viabilidade, e não como demonstração de equivalência física integral entre as EAPs. Estudos de modelos supervisionados, como os de Habib, Abouhamad e Bayoumi (2025) e Alrasheed et al. (2026), também alertam que resultados financeiros dependem da qualidade e abrangência dos dados de entrada, da calibração e do processo de validação adotado.

Tabela 2 – Comparação global entre o orçamento executivo e os cenários estimados

Cenário	Total sem BDI	Diferença em relação ao executivo	Desvio	Índice do executivo
Executivo	R\$ 3.453.894,98	-	0,00%	100,00%
Otimista	R\$ 3.044.185,96	-R\$ 409.709,02	-11,86%	88,14%
Primário	R\$ 3.185.622,90	-R\$ 268.272,08	-7,77%	92,23%
Pessimista	R\$ 3.644.414,71	+R\$ 190.519,73	+5,52%	105,52%

Fonte: Elaborado pelos autores (2026).

Essa leitura agregada é confirmada pela Tabela 2, na qual o orçamento executivo ficou contido no intervalo produzido pelos três cenários. O otimista ficou 11,86% abaixo da referência, o primário 7,77% abaixo e o pessimista 5,52% acima, formando uma amplitude de R\$ 600.228,75. Para a finalidade de estudo preliminar de viabilidade, o enquadramento do valor executivo pela faixa de cenários é um resultado favorável. Todavia, ele não deve ser comparado diretamente aos índices de acurácia de estudos baseados em treinamento de modelos com bases históricas de custos, como os trabalhos de Shamim et al. (2025) e Wang et al. (2022), pois esses estudos empregam variáveis econômicas, amostras de treinamento e procedimentos estatísticos distintos do procedimento comparativo adotado nesta pesquisa. A literatura também demonstra que variáveis macroeconômicas e de mercado podem alterar a previsão de custo de forma relevante, mesmo quando as características físicas do projeto permanecem estáveis.

Sob essa perspectiva, a principal evidência fornecida pela Tabela 2 não é a obtenção de um “valor exato”, mas a capacidade de produzir uma faixa de decisão compatível com o orçamento de referência. A abordagem ainda pode ser aprimorada pela incorporação de bases de preços atualizadas, dados de fornecedores, fatores regionais e retroalimentação oriunda de orçamentos efetivamente executados. Esses elementos diminuem o risco de que a proximidade global decorra apenas de compensações entre erros físicos de sinais opostos (Tripathi et al., 2026; Vaisnave; Mythily; Kirubakaran, 2025).

Tabela 3 – Comparação das macroetapas com maiores desvios entre o orçamento executivo e os cenários estimados (valores em R\$ arredondados)

Macroetapa	Exec.	Otimista Valor	Otimista Desv.	Primário Valor	Primário Desv.	Pessimista Valor	Pessimista Desv.
Cobertura	649.411	282.570	-56,49%	297.443	-54,20%	342.059	-47,33%
Supraestrutura	242.945	76.690	-68,43%	83.359	-65,69%	104.198	-57,11%
Pintura	105.904	209.970	+98,27%	221.021	+108,70%	254.174	+140,01%
Instalações sanitárias e pluviais	267.401	167.730	-37,27%	169.553	-36,59%	176.845	-33,87%
Fundações	283.650	310.432	+9,44%	347.902	+22,65%	481.703	+69,82%
Esquadrias	360.676	412.570	+14,39%	413.000	+14,51%	416.823	+15,57%
Calçada externa	15.472	49.148	+217,65%	54.609	+252,94%	65.530	+323,53%

Fonte: Elaborado pelos autores (2026).

A Tabela 3 não reproduz a sequência das macroetapas do orçamento executivo, pois foi estruturada em ordem analítica para evidenciar os contrastes mais relevantes entre os cenários e a referência. A disposição inicia pelas subestimações expressivas de cobertura e supraestrutura; em seguida, coloca em contraste pintura, instalações sanitárias e pluviais e fundações, por elevada relevância técnica; e finaliza com esquadrias e calçada externa, esta última por concentrar elevada variação percentual. Logo, a sequência da tabela não corresponde à execução física nem à EAP do orçamento executivo; ela serve exclusivamente à discussão dos desvios mais críticos.

Nessa leitura, a visão por macroetapa demonstra que a aderência financeira global não se repete em todos os pacotes de serviço. Cobertura e supraestrutura permaneceram subestimadas em todos os cenários, com o primário apresentando -54,20% e -65,69%, respectivamente. Em sentido oposto, pintura, fundações e calçada externa foram superestimadas, chegando a +108,70%, +22,65% e +252,94% no cenário primário. Esses resultados são desfavoráveis para um uso executivo ou para uma contratação, porque apontam fragilidades na distribuição dos custos entre pacotes de serviço. Para a etapa de viabilidade, entretanto, eles são informativos: localizam objetivamente as macroetapas que devem receber maior detalhamento, verificação de unidades e revisão das premissas de execução (Martin; James; Chadee, 2025; Taiwo et al., 2025).

A Tabela 3 também evidencia que o resultado total favorável não é suficiente para classificar o método como apto ao orçamento executivo. Aplicações de LLM na construção vêm mostrando bom potencial para organizar informações e apoiar decisões, mas as revisões mais recentes ressaltam desafios de adaptação ao domínio, controle de alucinações, privacidade de dados e integração com os fluxos digitais existentes. Assim, a interpretação tecnicamente mais adequada é que o método apresenta utilidade diagnóstica: ele produz uma primeira estrutura de quantitativos e chama atenção para pacotes de maior incerteza, os quais precisam ser revisados com documentação e julgamento profissional (Saka et al., 2024; Gao et al., 2026).

O contraste entre o bom enquadramento do total global e os desvios por macroetapa reforça a prioridade metodológica deste estudo: primeiro validar as quantidades físicas e, depois, avaliar sua repercussão no orçamento. Pesquisas em planejamento e em aplicações de GPT na construção mostram que a IA pode acelerar a organização de tarefas e informações, porém sua utilidade aumenta quando os resultados passam por refinamento humano e por conferência contra fontes técnicas. Da mesma forma, a explicabilidade e a quantificação da incerteza são necessárias para identificar se uma aproximação financeira decorre de um processo consistente ou de compensações ocasionais (Prieto; Mengiste; García de Soto, 2023; Chen et al., 2025).

5 CONCLUSÃO

Este estudo avaliou a aplicabilidade de uma IA generativa baseada em LLM na estimativa preliminar de quantitativos de serviços para um empreendimento habitacional de interesse social e examinou a repercussão desses quantitativos no orçamento. O procedimento foi aplicado a 25 unidades habitacionais e comparou os cenários otimista, primário e pessimista ao orçamento executivo de referência, mantendo os custos unitários equivalentes para que a análise refletisse predominantemente as variações físicas dos serviços.

Os resultados mostram que o método apresentou desempenho mais favorável em serviços relacionados diretamente à geometria da edificação. No cenário primário, a fôrma para viga baldrame teve desvio de +0,51%, e sete dos doze serviços comparáveis permaneceram em uma faixa de $\pm 15\%$ em relação ao orçamento executivo, com a escavação analisada separadamente por não apresentar equivalência estritamente quantitativa. Entretanto, os desvios observados em instalações, cobertura, supraestrutura, pintura e itens externos evidenciam que o método ainda não reproduz com confiabilidade suficiente a distribuição dos quantitativos necessária a um orçamento executivo.

No plano financeiro, o orçamento executivo totalizou R\$ 3.453.894,98. Os cenários otimista, primário e pessimista alcançaram, respectivamente, R\$ 3.044.185,96, R\$ 3.185.622,90 e R\$ 3.644.414,71. O cenário pessimista foi o mais próximo do valor global de referência, com desvio de +5,52%, enquanto o cenário primário permaneceu 7,77% abaixo. Como o orçamento executivo foi enquadrado pela faixa dos três cenários, o método demonstrou utilidade para subsidiar decisões iniciais de viabilidade. Contudo, a proximidade do valor total não deve ser interpretada como equivalência integral entre os quantitativos, pois parte dela pode decorrer de compensações entre serviços superestimados e subestimados.

Conclui-se que o uso do LLM é aplicável como apoio à organização inicial do escopo, à geração de uma EAP preliminar e à definição de faixas orçamentárias no pré-projeto. Dessa forma, considera-se que o método foi parcialmente validado para a finalidade de viabilidade preliminar, desde que associado à revisão técnica e à conferência dos serviços críticos. Sua utilização deve permanecer associada à compatibilização com documentos técnicos, à aplicação de regras de medição, à verificação de unidades e à revisão de um profissional habilitado. Para pesquisas futuras, recomenda-se integrar projetos mais detalhados, regras de quantificação por serviço, dados de sondagem e instalações, bases históricas de obras e rotinas de validação contínua, de modo a reduzir os desvios por macroetapa e ampliar a robustez do método.

REFERÊNCIAS

ABIOYE, Sofiat O.; OYEDELE, Lukumon O.; AKANBI, Lukman; AJAYI, Anuoluwapo; DAVILA DELGADO, Juan Manuel; BILAL, Muhammad; AKINADE, Olugbenga O.; AHMED, Ashraf. Artificial intelligence in the construction industry: a review of present status, opportunities and future challenges. *Journal of Building Engineering*, [S. l.], v. 44, art. 103299, 2021. DOI: <https://doi.org/10.1016/j.jobbe.2021.103299>.

AKANBI, Temitope; ZHANG, Jian. Design information extraction from construction specifications to support cost estimation. *Automation in Construction*, [S. l.], v. 131, art. 103835, 2021. DOI: <https://doi.org/10.1016/j.autcon.2021.103835>.

AKANBI, Temitope; ZHANG, Jian. Ifc-based algorithms for automated quantity takeoff from architectural model: case study on residential development project. *Journal of Architectural Engineering*, [S. l.], v. 29, n. 4, art. 05023007, 2023. DOI: <https://doi.org/10.1061/JAEIED.AEENG-1447>.

AKANBI, Temitope; ZHANG, Jian; LEE, Yu-Cheng. Data-driven reverse engineering algorithm development method for developing interoperable quantity takeoff algorithms using IFC-based BIM. *Journal of Computing in Civil Engineering*, [S. l.], v. 34, n. 5, art. 04020036, 2020. DOI: [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000909](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000909).

ALRASHEED, Khaled; AL BALLAT, Mohy; SOLIMAN, Ehab; ALBADER, Haya. Artificial neural network-based cost estimation for public construction projects in Kuwait. *Journal of Engineering Research*, [S. l.], v. 14, p. 150-159, 2026. DOI: <https://doi.org/10.1016/j.jer.2025.09.001>.

BADUGE, Shanaka Kristombu; THILAKARATHNA, Sadeep; PERERA, Jude Shalitha; ARASHPOUR, Mehrdad; SHARAFI, Pejman; TEODOSIO, Bertrand; SHRINGI, Ankit; MENDIS, Priyan. Artificial intelligence and smart vision for building and construction 4.0: machine and deep learning methods and applications. *Automation in Construction*, [S. l.], v. 141, art. 104440, 2022. DOI: <https://doi.org/10.1016/j.autcon.2022.104440>.

CHEN, Lifei; XU, Changyong; LIM, Wei Hong; SHARMA, Abhishek; TIANG, Sew Sun; CHONG, Kim Soon; EL-KENAWY, El-Sayed M.; ALHUSSAN, Amel Ali; EID, Marwa M.; KHAFAGA, Doaa Sami. Transparent and reliable construction cost prediction using advanced machine learning and explainable AI. *Engineering Science and Technology, an International Journal*, [S. l.], v. 70, art. 102159, 2025. DOI: <https://doi.org/10.1016/j.jestch.2025.102159>.

EGWIM, Christian Nnaemeka; ALAKA, Hafiz; DEMIR, Eren; BALOGUN, Habeeb; OLU-AJAYI, Razak; SULAIMON, Ismail; WUSU, Godoyon; YUSUF, Wasiu; MUIDEEN, Adegoke A. Artificial intelligence in the construction industry: a systematic review of the entire construction value chain lifecycle. *Energies*, [S. l.], v. 17, art. 182, 2024. DOI: <https://doi.org/10.3390/en17010182>.

GARCÍA DE SOTO, Borja; ADEY, Bryan T. Preliminary resource-based estimates combining artificial intelligence approaches and traditional techniques. *Procedia Engineering*, [S. l.], v. 164, p. 261-268, 2016. DOI: <https://doi.org/10.1016/j.proeng.2016.11.618>.

GAO, Yu; YIU, Tak Wing; SHEN, Xuesong; TAM, Vivian W. Y. Large language models in smart construction: a systematic review of implementation strategies, applications and future directions. *Engineering, Construction and Architectural Management*, [S. l.], v. 33, n. 15, p. 159-181, 2026. DOI: <https://doi.org/10.1108/ECAM-10-2025-1668>.

GHASEMI, Alireza; DAI, Fei. Can ChatGPT assist in cost analysis and bid pricing in construction estimating? A pilot study using a bridge rehabilitation project. *Smart Construction*, [S. l.], v. 1, n. 2, art. e0009, 2024. DOI: <https://doi.org/10.55092/sc20240009>.

GHIMIRE, Prashnna; KIM, Kyungki; STENTZ, Terry; ROY, Tirthankar. Modular Chain-of-Thought (CoT) for LLM-based conceptual construction cost estimation. *Buildings*, Basel, v. 16, n. 2, art. 396, 2026. DOI: <https://doi.org/10.3390/buildings16020396>.

GUNARANI, G. I.; RAJKUMAR, Shreevatsh; THENNALEESWARAN, Dharshana; VENATESWARAN, Abi Shriya; RATHINAKUMAR, V. A machine learning-driven framework for sector-specific construction cost overrun prediction and mitigation. *EPJ Web of Conferences*, [S. l.], v. 354, art. 02002, 2026. DOI: <https://doi.org/10.1051/epjconf/202635402002>.

HABIB, Omar; ABOUHAMAD, Mona; BAYOUMI, AbdelMoniem. Ensemble learning framework for forecasting construction costs. *Automation in Construction*, [S. l.], v. 170, art. 105903, 2025. DOI: <https://doi.org/10.1016/j.autcon.2024.105903>.

HEO, Chan; PARK, Moonseo; AHN, Changbum R. Large language models in construction bidding: opportunities and risks of algorithmic collusion. In: *INTERNATIONAL SYMPOSIUM ON AUTOMATION AND ROBOTICS IN CONSTRUCTION*, 42., 2025. *Proceedings [...]*. [S. l.]: IAARC, 2025. p. 1332-1339.

ISLAMI, Rizky Citra; HATMOKO, Jati Utomo Dwi; HERMAWAN, Ferry; SULAIMAN, Lusman; WULANDARI, Mariana. Issues on implementation of artificial intelligence (AI) in Indonesia construction projects. *Planning Malaysia*, [S. l.], v. 23, n. 4, p. 97-111, 2025.

JAFARY, Peyman; SHOJAEI, Davood; RAJABIFARD, Abbas; NGO, Tuan. Artificial intelligence (AI) and machine learning in building information modeling (BIM)-based construction cost estimation: a systematic review. *Geo-spatial Information Science*, [S. l.], 2026. DOI: <https://doi.org/10.1080/10095020.2026.2651578>.

KATOOZIANI, Ali; JEELANI, Idris; GHEISARI, Masoud. GPT applications for construction safety: a use case analysis. *Buildings*, [S. l.], v. 15, art. 2410, 2025. DOI: <https://doi.org/10.3390/buildings15142410>.

KEDIYA, Shailesh; BHORKAR, M. P.; DESHPANDE, Prasanna; JAIN, Ritesh; PURI, Chetan; GUDADHE, Amit Anil. Review on the significance of artificial intelligence in construction engineering and management. In: *INTERNATIONAL CONFERENCE ON COMMUNICATION, SECURITY AND ARTIFICIAL INTELLIGENCE, 2023. Proceedings [...]*. [S. l.]: IEEE, 2023. p. 511-514. DOI: <https://doi.org/10.1109/ICCSAI59793.2023.10420911>.

KORKE, Pavankumar; GOBINATH, R.; SHEWALE, Manisha; KHARTODE, Bhagyashree. Role of artificial intelligence in construction project management. *E3S Web of Conferences*, [S. l.], v. 405, art. 04012, 2023. DOI: <https://doi.org/10.1051/e3sconf/202340504012>.

KUMAR, Dimpal; RAWAT, Aman Singh; JHA, Satyam; YADAV, Dileep. Machine learning-based prediction of home prices. In: *INTERNATIONAL CONFERENCE ON ADVANCES IN COMPUTING, COMMUNICATION CONTROL AND NETWORKING, 5., 2023. Proceedings [...]*. [S. l.]: IEEE, 2023. DOI: <https://doi.org/10.1109/ICAC3N60023.2023.10541614>.

LIU, H.; CHENG, Jack C. P.; GAN, Vivian J. L.; ZHOU, S. A knowledge model-based BIM framework for automatic code-compliant quantity take-off. *Automation in Construction*, [S. l.], v. 133, art. 104024, 2022.

MARTIN, Hector; JAMES, Jennifer; CHADEE, Aaron. Exploring large language model AI tools in construction project risk assessment: ChatGPT limitations in risk identification, mitigation strategies, and user experience. *Journal of Construction Engineering*

and Management, Reston, v. 151, n. 9, art. 04025119, 2025. DOI: <https://doi.org/10.1061/JCEMD4.COENG-16658>.

MONTEIRO, Andre; MARTINS, Joao Pocas. A survey on modeling guidelines for quantity takeoff-oriented BIM-based design. Automation in Construction, [S. l.], v. 35, p. 238-253, 2013. DOI: <https://doi.org/10.1016/j.autcon.2013.05.005>.

NGUYEN, Quan T.; PHAM, Thuy-Binh; BUI, Hai Phong; CHEN, Po-Han. Applying Action Research to developing a GPT-based assistant for construction cost code verification in state-funded projects in Vietnam. Buildings, Basel, v. 16, n. 3, art. 499, 2026. DOI: <https://doi.org/10.3390/buildings16030499>.

NOBAKHTFAR, Koorosh; ÇAKILCI, Kenan; ZILAN, Ruken. Chain-of-Thought vs. Few-Shot: a comparative study of prompting strategies for code generation. In: INTERNATIONAL CONFERENCE ON INFORMATICS AND SOFTWARE ENGINEERING, 5., 2026. Proceedings [...]. [S. l.]: IEEE, 2026. DOI: <https://doi.org/10.1109/IISEC69317.2026.11418478>.

OLSEN, David; TAYLOR, John M. Quantity take-off using building information modeling (BIM), and its limiting factors. Procedia Engineering, [S. l.], v. 196, p. 1098-1105, 2017. DOI: <https://doi.org/10.1016/j.proeng.2017.08.067>.

PAN, Y.; ZHANG, L. Integrating BIM and AI for smart construction management: current status and future directions. Archives of Computational Methods in Engineering, [S. l.], v. 30, n. 2, p. 1081-1110, 2023. DOI: <https://doi.org/10.1007/s11831-022-09830-8>.

PARK, D.; YUN, S. Construction cost prediction using deep learning with BIM properties in the schematic design phase. Applied Sciences, [S. l.], v. 13, n. 12, art. 7207, 2023. DOI: <https://doi.org/10.3390/app13127207>.

PHAM, T. Q. D.; LE-HONG, T.; TRAN, X. V. Efficient estimation and optimization of building costs using machine learning. International Journal of Construction Management, [S. l.], v. 23, n. 5, p. 909-921, 2023. DOI: <https://doi.org/10.1080/15623599.2021.1943630>.

PRIETO, Samuel A.; MENGISTE, Eyob T.; GARCÍA DE SOTO, Borja. Investigating the use of ChatGPT for the scheduling of construction projects. Buildings, Basel, v. 13, n. 4, art. 857, 2023. DOI: <https://doi.org/10.3390/buildings13040857>.

REGONA, Massimo; YIGITCANLAR, Tan; XIA, Bo; LI, Rita Yi Man. Artificial intelligent technologies for the construction industry: how are they perceived and utilized in

Australia? Journal of Open Innovation: Technology, Market, and Complexity, [S. l.], v. 8, n. 1, art. 16, 2022. DOI: <https://doi.org/10.3390/joitmc8010016>.

SAKA, Abdullahi; TAIWO, Ridwan; SAKA, Nurudeen; SALAMI, Babatunde Abiodun; AJAYI, Saheed; AKANDE, Kabiru; KAZEMI, Hadi. GPT models in the construction industry: opportunities, limitations and a use case validation. *Developments in the Built Environment*, [S. l.], v. 17, art. 100300, 2024. DOI: <https://doi.org/10.1016/j.dibe.2023.100300>.

SANDS, Kenneth Stafford; WANG, Xi; ZHAO, Tianjiao. Use of AI in a graduate construction estimating course. In: *ASEE ANNUAL CONFERENCE AND EXPOSITION*, 2025. Proceedings [...]. [S. l.]: American Society for Engineering Education, 2025. Paper 45361.

SHAABAN, Khaled. Practical solutions for integrating generative AI into modern engineering education. In: *IEEE ENGINEERING EDUCATION WORLD CONFERENCE*, 2026. Proceedings [...]. [S. l.]: IEEE, 2026. DOI: <https://doi.org/10.1109/EDUNINE62390.2026.11546886>.

SHAMIM, Md. Mahfuzul Islam; HAMID, Abu Bakar bin Abdul; NYAMASVISVA, Tadiwa Elisha; RAFI, Najmus Saqib Bin. Advancement of artificial intelligence in cost estimation for project management success: a systematic review of machine learning, deep learning, regression, and hybrid models. *Modelling*, [S. l.], v. 6, art. 35, 2025. DOI: <https://doi.org/10.3390/modelling6020035>.

TAIWO, Ridwan; BELLO, Idris Temitope; ABDULAI, Sulemana Fatoama; YUSIF, Abdul-Mugis; SALAMI, Babatunde Abiodun; SAKA, Abdullahi; BEN SEGHIER, Mohamed El Amine; ZAYED, Tarek. Generative artificial intelligence in construction: a Delphi approach, framework, and case study. *Alexandria Engineering Journal*, [S. l.], v. 116, p. 672-698, 2025. DOI: <https://doi.org/10.1016/j.aej.2024.12.079>.

TRIPATHI, Abhishek; MORANKAR, Gauri; MANOHAR, Chirukuri; DASHARATH, Suryavamshi; ABHISHEK, Manchala; HEMANTH, Robba. Automated Bill-of-Materials and cost forecasting using AI and real-time market data. In: *INTERNATIONAL CONFERENCE ON EMERGING TRENDS IN ENGINEERING AND MEDICAL SCIENCES*, 3., 2026. Proceedings [...]. [S. l.]: IEEE, 2026. DOI: <https://doi.org/10.1109/ICETEMS66917.2026.11469485>.

VAISNAVE, I. M.; MYTHILY, M.; KIRUBAKARAN, Stewart. Automated construction cost estimation framework with AI-driven reinforcement learning. In:

INTERNATIONAL CONFERENCE ON AUTOMATION, COMPUTING AND RENEWABLE SYSTEMS, 4., 2025. Proceedings [...]. [S. l.]: IEEE, 2025. p. 1755-1761. DOI: <https://doi.org/10.1109/ICACRS67045.2025.11324155>.

WAQAR, Ahsan. Intelligent decision support systems in construction engineering: an artificial intelligence and machine learning approaches. *Expert Systems with Applications*, [S. l.], v. 249, art. 123503, 2024. DOI: <https://doi.org/10.1016/j.eswa.2024.123503>.

WANG, Ran; ASGHARI, Vahid; CHEUNG, Clara Man; HSU, Shu-Chien; LEE, Chia-Jung. Assessing effects of economic factors on construction cost estimation using deep neural networks. *Automation in Construction*, [S. l.], v. 134, art. 104080, 2022. DOI: <https://doi.org/10.1016/j.autcon.2021.104080>.

WIJERATHNE, U. P.; KULATUNGA, U.; FERNANDO, M. L. S. S. A study assessing the application of artificial neural network for preliminary estimation in Sri Lankan building projects. In: *WORLD CONSTRUCTION SYMPOSIUM*, 13., 2025. Proceedings [...]. Sri Lanka: [s. n.], 2025. p. 83-97. DOI: <https://doi.org/10.31705/WCS.2025.7>.

ZHANG, Li; ZHOU, Shiheng; GUO, Jing; LI, Zhousong; LV, Xiaomin; WANG, Ningning. An LLM-empowered technical approach and practical study for engineering quantity calculation. In: *INTERNATIONAL CONFERENCE ON INFORMATION SCIENCE, PARALLEL AND DISTRIBUTED SYSTEMS*, 6., 2025. Proceedings [...]. [S. l.]: IEEE, 2025. p. 48-58. DOI: <https://doi.org/10.1109/ISPDS67367.2025.11391137>.