



UNIVERSIDADE FEDERAL DE OURO PRETO
ESCOLA DE MINAS
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO



Marcos Vinícius da Luz Pinto

**Avaliação de Desempenho de Modelos de Fundação de Séries Temporais na
Estimativa de Indicadores Setoriais e Suporte ao Planejamento e Controle da
Produção**

OURO PRETO - MG
2026

Marcos Vinícius da Luz Pinto

**Avaliação de Desempenho de Modelos de Fundação de Séries Temporais na
Estimativa de Indicadores Setoriais e Suporte ao Planejamento e Controle da
Produção**

Monografia apresentada ao Curso de Graduação em Engenharia de Produção da Universidade Federal de Ouro Preto como requisito final para a obtenção do título de Engenheiro de Produção.

Professor orientador: Jadson Castro Gertrudes
Coorientador: Lucas Moreira Ribeiro

**OURO PRETO – MG
2026**



FOLHA DE APROVAÇÃO

Marcos Vinícius da Luz Pinto

Avaliação de Desempenho de Modelos de Fundação de Séries Temporais na Estimativa de Indicadores Setoriais e Suporte ao Planejamento e Controle da Produção

Monografia apresentada ao Curso de Graduação em Engenharia de Produção da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Engenheiro de Produção.

Aprovada em 24 de março de 2026.

Membros da banca

Dr. Jadson Castro Gertrudes - Orientador - Universidade Federal de Ouro Preto

Dr. Aloisio de Castro Gomes Júnior - Convidado - Universidade Federal de Ouro Preto

Arthur Negrão de Faria Martins da Costa - Convidado - Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Ouro Preto

Jadson Castro Gertrudes, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 25/02/2026.



Documento assinado eletronicamente por **Jadson Castro Gertrudes, PROFESSOR DE MAGISTERIO SUPERIOR**, em 25/02/2026, às 21:35, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1065141** e o código CRC **5D281209**.

Dedico este trabalho aos meus pais, aqueles de quem herdei mais do que o sobrenome: herdei a fé, a coragem e a maneira de continuar. Tudo o que eu vencer, tem um pedaço de vocês.

“Faça com excelência”.

RESUMO

A assertividade nas previsões de indicadores econômicos é um pilar fundamental para o Planejamento e Controle da Produção (PCP) na Construção Civil, setor marcado por alta volatilidade e incerteza orçamentária. Este trabalho tem como objetivo avaliar o desempenho de previsões *zero-shot* de Modelos de Fundação de Séries Temporais (TSFMs), especificamente o Chronos e o Moirai, em comparação ao modelo estatístico tradicional AutoARIMA, no PCP. Utilizou-se uma base de dados histórica composta por indicadores setoriais (CUB e INCC) e macroeconômicos (SELIC), submetidos a diferentes janelas de contexto e horizontes de previsão. A avaliação foi conduzida por meio das métricas MASE (acurácia pontual) e CRPS (acurácia probabilística), com validação estatística via teste de Friedman e, posteriormente, *post-hoc* de Nemenyi. Os resultados demonstram que o modelo Chronos apresentou o melhor desempenho para a projeção de custos de materiais e globais (CUB), superando o AutoARIMA em termos de precisão e confiabilidade. Contudo, o AutoARIMA manteve sua superioridade em variáveis institucionais como a SELIC, enquanto o Moirai exibiu limitações severas e inferioridade estatística. Conclui-se que a adoção de uma abordagem híbrida, combinando modelos de fundação e métodos estatísticos clássicos, potencializa a tomada de decisão estratégica, permitindo uma gestão de riscos orçamentários mais robusta e adaptada às complexidades do mercado brasileiro.

Palavras chaves: Modelos de Fundação de Séries Temporais, Construção Civil, Avaliação de Modelos, Previsão.

ABSTRACT

Forecast prediction of economic indicators is a fundamental pillar for Production Planning and Control (PPC) in the construction industry, a sector characterized by high volatility and budgetary uncertainty. This study aims to evaluate the performance of *zero-shot* forecasts generated by Time Series Foundation Models (TSFMs), specifically Chronos and Moirai, in comparison with the traditional statistical model AutoARIMA, in PPC. The analysis is based on a historical dataset composed of sectoral indicators (CUB and INCC) and macroeconomic variables (SELIC), evaluated under different context window lengths and forecasting horizons. Model performance was assessed using the Mean Absolute Scaled Error (MASE) for point accuracy and the Continuous Ranked Probability Score (CRPS) for probabilistic accuracy, with statistical validation conducted through the Friedman test followed by the Nemenyi *post-hoc* procedure. The results indicate that Chronos achieved superior performance in forecasting material and overall construction cost indices (CUB), outperforming AutoARIMA in terms of both accuracy and reliability. However, AutoARIMA maintained superior performance for institutional variables such as the SELIC rate, while Moirai exhibited severe limitations and statistically inferior results. These findings suggest that a hybrid approach, combining foundation models with classical statistical methods, enhances strategic decision-making and supports more robust budget risk management tailored to the complexities of the Brazilian construction market.

Keywords: Time Series Foundation Models; Construction Industry; Forecast Evaluation; Demand and Cost Forecasting.

LISTA DE FIGURAS

Figura 1 - Principais elementos da gestão de demanda.....	15
Figura 2 - Série Estacionária	16
Figura 3 - Série Não Estacionária.....	16
Figura 4 - Arquitetura Transformer.....	20
Figura 5 - Processo Metodológico.....	22
Figura 6 - Abordagem por Origem Fixa.....	25
Figura 7 - Abordagem por Origem Móvel	25
Figura 8 - Arquitetura do modelo Chronos	28
Figura 9 - Arquitetura do modelo Moirai.....	28
Figura 10 - Diagrama de Diferença Crítica (MASE)	34
Figura 11 - Diagrama de Diferença Crítica (CRPS).....	35

LISTA DE TABELAS

Tabela 1 - Trabalhos Relacionados	21
Tabela 2 – Estatísticas Descritivas	24
Tabela 3 - Visão Geral dos Modelos TSFMs	27
Tabela 4 - Resultados a curto prazo (MASE).....	30
Tabela 5 - Resultados a longo prazo (MASE).....	31
Tabela 6 - Resultados a curto prazo (CRPS)	32
Tabela 7 - Resultados a longo prazo (CRPS)	33

LISTA DE ABREVIATURAS E SIGLAS

PCP Planejamento e Controle da Produção

INCC Índice Nacional de Custo da Construção

CUB Custo Unitário Básico

SELIC Sistema Especial de Liquidação e Custódia

ARIMA *Autoregressive Integrated Moving Average*

SARIMA *Seasonal AutoRegressive Integrated Moving Average*

TFSM *Time Series Foundation Model*

MASE *Mean Absolute Scaled Error*

CRPS *Continuous Ranked Probability Score*

SUMÁRIO

1	INTRODUÇÃO.....	10
1.1	Objetivos.....	11
1.1.1	Objetivo Geral	11
1.1.2	Objetivos Específicos	11
1.2	Estrutura do Trabalho	11
2	REVISÃO BIBLIOGRÁFICA	13
2.1	Indicadores Macroeconômicos da Construção Civil	13
2.2	Previsão de Demanda	14
2.3	Séries Temporais	15
2.4	Modelos Clássicos de Previsão.....	18
2.5	Modelos de Fundação de Séries Temporais (TSFMs).....	19
2.6	Trabalhos Relacionados.....	20
3	METODOLOGIA.....	22
3.1	Coleta de Dados.....	23
3.2	Tratamento dos Dados	23
3.3	Configuração Experimental	24
3.4	Seleção de Modelos	26
3.5	Avaliação de Performance.....	29
4	RESULTADOS E DISCUSSÃO.....	30
5	CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS	36
	REFERÊNCIAS BIBLIOGRÁFICAS	37
	ANEXOS	40

1 INTRODUÇÃO

A Construção Civil figura como um dos principais pilares econômicos do Brasil. Segundo informações do Ministério do Trabalho e Emprego (MTE, 2025) e do Instituto Brasileiro de Geografia e Estatística (IBGE, 2025), em 2024, o setor gerou cerca de 110.921 novos postos de trabalhos formais e cresceu 4,3%, encerrando o ano com um Produto Interno Bruto (PIB) de R\$359.523 bilhões. No entanto, empresas atuantes no setor da construção civil lidam com diversas incertezas como exposição a variáveis econômicas, regulatórias e de mercado, que impactam diretamente no planejamento de obras e/ou projetos.

Na atualização com dados até abril de 2025 do Painel de Obras Paralisadas do Tribunal de Contas da União (TCU), das 22.621 obras mapeadas, 11.469 encontram-se paralisadas, cerca de 50% do total. Embora as propostas de planejamento tradicionais tenham alcançado sucessos pontuais, elas permanecem como soluções limitadas diante da complexidade do processo produtivo na construção civil. A eficácia no setor é frequentemente comprometida por características intrínsecas, como a geração de produtos únicos, o uso intensivo de mão de obra e a alta volatilidade na alocação de recursos (Machado, 1998).

A relevância da utilização de indicadores econômicos para análise setorial a partir de modelos estatísticos tradicionais pode ser evidenciada em estudos como o de Pereira e Lima (2025), que utilizou o modelo ARIMA para investigar o comportamento do valor agregado bruto da construção civil ao longo dos últimos anos a partir do Produto Interno Bruto (PIB). Embora modelos estatísticos como o ARIMA sejam bem estabelecidos e consigam auxiliar em projeções, a complexidade dos dados do setor de construção civil no mundo real pode exigir que modelos de previsão se adequem a padrões não lineares, uma vez que os custos de construção dependem de variáveis como localidade, duração da obra e índices macroeconômicos (Rafiei; Adeli, 2018). Além disso, a criação de modelos de aprendizado de máquina (*machine learning*) exige grandes conjuntos de dados para treinamento e adaptação, limitando sua aplicabilidade em situações onde os mesmos estão espalhados em diferentes empresas e formatos (Succar; Kassem, 2015).

Para superar a limitação de dados escassos, surge como proposta os Modelos de Fundação de Séries Temporais (TSFMs), que permitem a previsão em regime *zero-shot* - ou seja - são capazes de prever dados sem terem sido treinados previamente com os

mesmos. Segundo Das, Abhimanyu *et al.* (2024), esses modelos são capazes de capturar padrões complexos e não lineares sem a necessidade de um grande volume de dados específicos para o treinamento local.

Nessa perspectiva, o presente trabalho foi desenvolvido visando avaliar o desempenho de TSFMs em comparação com um modelo convencional para prever indicadores da Construção Civil, com o objetivo de aprimorar métodos de gestão e controle da produção.

Os resultados obtidos demonstram que a adoção de tecnologias de ponta não garante, por si só, superioridade técnica. No entanto, a equivalência estatística observada entre alguns modelos valida o potencial dos TSFMs.

1.1 Objetivos

1.1.1 Objetivo Geral

Avaliar o desempenho de previsões *zero-shot* de Modelos de Fundação de Séries Temporais (TSFMs) em dados históricos da construção civil para verificar se superam previsões obtidas pelo modelo estatístico ARIMA.

1.1.2 Objetivos Específicos

Os objetivos específicos são:

- Identificar indicadores com relevância para a tomada de decisão em problemas da Construção Civil.
- Modelar a estrutura do modelo estatístico ARIMA para prever os indicadores da construção civil.
- Modelar a estrutura dos TSFMs para prever os indicadores da construção civil.
- Comparar os resultados obtidos a partir de cada modelo, contextualizando-os em estratégias gerenciais.

1.2 Estrutura do Trabalho

O trabalho é dividido em 5 capítulos, sendo apresentado os seguintes tópicos:

- Capítulo 1 - Introdução: Apresenta a importância da Construção Civil a nível nacional, os desafios de empresas que atuam no setor na realização

de um planejamento eficaz devido às complexidades da área e como modelos *zero-shot* podem ser uma saída para esses desafios.

- Capítulo 2 - Referencial bibliográfico: Expõe os principais conceitos que garantem embasamento ao trabalho, sendo esses: indicadores macroeconômicos da Construção Civil, previsão de demanda, séries temporais, modelo estatístico ARIMA, TSFMs, e trabalhos relacionados.
- Capítulo 3 - Metodologia: Demonstra a abordagem realizada em um estudo quantitativo descritivo, que envolveu a coleta de dados, a preparação dos conjuntos e a aplicação dos modelos.
- Capítulo 4 – Resultados e discussão: Descreve e compara os resultados obtidos entre modelos estatísticos convencionais e modelos que utilizam a previsão *zero-shot* como premissa, em dados do setor de construção civil, analisando-os em um contexto de planejamento.
- Capítulo 5 – Considerações finais: Resume as conclusões do estudo, destacando as contribuições para o processo de gestão e sugere melhorias futuras.

2 REVISÃO BIBLIOGRÁFICA

2.1 Indicadores Macroeconômicos da Construção Civil

A Construção Civil é um dos setores de maior relevância para a economia brasileira, gerando empregos, expandindo infraestruturas e promovendo o desenvolvimento produtivo, conforme evidenciado na Introdução, segundo dados do Ministério do Trabalho e Emprego (MTE, 2025) e do Instituto Brasileiro de Geografia e Estatística (IBGE, 2025), em 2024. Por sua grandeza, sua performance reflete diretamente no ciclo econômico do país. Nesse sentido, indicadores macroeconômicos tornam-se essenciais para compreender o comportamento do setor, possibilitando prever tendências e tomar decisões.

Indicadores ligados ao custo de construção e financiamento são decisivos, pois impactam tanto na viabilidade econômica de novos empreendimentos quanto na continuidade de obras em andamento. Sob essa ótica, alguns indicadores podem ser evidenciados pela influência que exercem no setor: o Índice Nacional de Custo da Construção (INCC), a taxa SELIC e o Custo Unitário Básico da Construção Civil (CUB). Apesar de atuarem em frentes diferentes, convergem na capacidade de acelerar ou frear a atividade da Construção Civil.

O INCC é calculado pela Fundação Getúlio Vargas (FGV), sendo um dos componentes do Índice Geral dos Preços (IGP), responsável pelo reajuste de aluguéis. O INCC é a medida padrão para reajuste de parcelas de imóveis na planta. O índice reflete a evolução dos custos do primeiro ao último dia do mês de referência, o que o torna mais adequado para modelagens de séries temporais que empregam outras variáveis mensais (Fundação Getulio Vargas, 2024).

A taxa SELIC (Sistema Especial de Liquidação e de Custódia) é a taxa básica de juros da economia brasileira. A SELIC impacta diretamente o custo de financiamento para as construtoras. Há uma forte correlação inversa entre a taxa e a demanda imobiliária, pois juros altos encarecem financiamentos habitacionais, reduzindo o poder de compra das famílias e a velocidade de vendas (Banco Central do Brasil, 2024).

O CUB é calculado pelo Sinduscon (Sindicatos da Indústria da Construção Civil), e é o principal indicador de custos diretos da construção por metro quadrado, servindo

como base para a incorporação imobiliária (Câmara Brasileira da Indústria da Construção, 2024), sendo dividido em:

- CUB Global: incorpora todas as segmentações a seguir, indicando o custo total por metro quadrado;
- CUB Material: influenciada por preços de *commodities* (e.g. aço, cimento) e variações cambiais, refere-se aos insumos físicos necessários para execução da obra;
- CUB Mão de Obra: corresponde ao valor por metro quadrado referente aos salários e encargos dos profissionais envolvidos na execução da obra;
- CUB Despesas Administrativas: reflete os custos da equipe técnica que atua na obra;
- CUB Equipamento: captura a variação dos custos de locação de maquinários e demais equipamentos, sensível às oscilações de oferta e demanda no mercado.

Quando modelados em conjunto, estes índices configuram-se como agentes essenciais para compreender os ciclos econômicos do setor e mitigar riscos de planejamento.

2.2 Previsão de Demanda

A eficiência de um sistema de administração da produção pode ser medida através da precisão de suas previsões (demanda, custos, capacidade produtiva, etc.). Segundo Corrêa, Giansesi e Caon (2018), a previsão de demanda é uma das cinco áreas que compõem os esforços voltados para a gestão de demanda, sendo que a habilidade de antecipar o que será solicitado com alguma precisão consiste em formar e manter uma base de dados históricos que explique comportamentos e variações passados, associada ao emprego de modelos matemáticos destinados à análise desses dados. A Figura 1 apresenta os elementos que constituem a gestão de demanda:

Figura 1 - Principais elementos da gestão de demanda



Fonte: Adaptado de Corrêa, Gianesi e Caon (2018, p. 252).

Nesse sentido, uma empresa que visa se manter competitiva deve ir além da simples estimativa de vendas, prevendo também os custos envolvidos na operação. Essa abordagem preditiva é vital para o PCP e para a gestão financeira. A capacidade de reagir adequadamente depende de um entendimento profundo do setor em que a empresa atua, o que é adquirido por meio da análise detalhada de históricos de mercado. O diferencial consiste em tornar as saídas geradas pela ferramenta de previsão em informações estratégicas que gerem *insights* para tomadas de decisão, o qual só será possível com um modelo capaz de processar os dados com performance significativa.

2.3 Séries Temporais


Uma série temporal é um conjunto de observações ordenadas ao longo do tempo. No contexto de previsão de demanda, representam o histórico do evento a ser observado em ordem cronológica. Morettin (2018) define duas abordagens fundamentais acerca das séries temporais para construir modelos preditivos: modelos paramétricos assumem uma estrutura matemática predefinida para a série e consistem em estimar um número finito de parâmetros que definem a estrutura, pois os parâmetros indicam a influência direta de observações passadas na série. Já os modelos não paramétricos permitem que a estrutura da previsão se ajuste de maneira mais livre aos dados observados.

Em resumo, os modelos paramétricos utilizam o passado para prever o futuro através de uma estrutura matemática rígida e finita de parâmetros (e.g. modelo ARIMA),

enquanto modelos não paramétricos geram previsões de forma mais flexível, permitindo que a relação funcional seja aprendida diretamente e dinamicamente a partir dos dados (e.g. Redes Neurais que expandem seus números de camadas e neurônios, de forma adaptativa, para acomodar novos volumes de informações).

Além disso, o autor também define como estacionariedade quando a série flutua em torno de uma média constante, sendo - de certa forma - estável, conforme exemplificado na Figura 2.

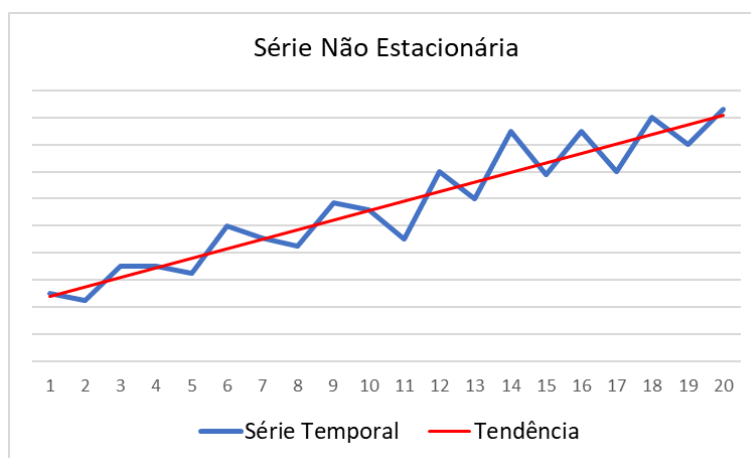
Figura 2 - Série Estacionária



Fonte: Elaborado pelo autor, 2026.

Por outro lado, séries não estacionárias exibem tendência, mudanças de nível ou variabilidade crescente, não permanecendo estáveis em torno de uma média constante. A Figura 3 demonstra o comportamento citado:

Figura 3 - Série Não Estacionária



Fonte: Elaborado pelo autor, 2026.

A não estacionariedade homogênea refere-se a séries que apresentam tendências ou mudanças de níveis, mas podem ser estabilizadas, enquanto as séries não estacionárias explosivas referem-se a séries que apresentam um crescimento (ou decrescimento) acelerado e ilimitado. A maioria dos procedimentos estatísticos de análise e previsão de séries temporais pressupõe que a série seja estacionária, em outros casos é necessário transformar os dados originais em uma série estacionária.

Nessa ótica, a depender da complexidade dos dados, transformá-los em estacionários para adequá-los ao modelo preditivo pode ser trabalhoso, sendo necessário a adoção de um outro modelo que seja capaz de tratá-los adequadamente.

Seja $Y = \{y_{\{1\}}, y_{\{2\}}, \dots, y_{\{T\}}\}$ uma série temporal univariada, onde $y_{\{t\}} \in \mathbb{R}$ é o valor observado no passo de tempo discreto t , e T é o número total de observações disponíveis. A previsão utiliza uma janela de comprimento C , denotada por $Y_{\{t-C+1:t\}} = \{y_{\{t-C+1\}}, \dots, y_{\{t\}}\}$, afim de prever valores futuros H , denotados por $Y_{\{t+1:t+H\}} = \{y_{\{t+1\}}, \dots, y_{\{t+H\}}\}$. Portanto, um modelo de previsão, denotado por M , é uma função que observa a janela de contexto para prever o horizonte:

$$M: Y_{\{t-C+1:t\}} \mapsto \hat{Y}_{\{t+1:t+H\}}, \quad (1)$$

onde $\hat{Y}_{\{t+1:t+H\}}$ representa a previsão.

Em métodos de previsões pontuais, a saída $\hat{Y}_{\{t+1:t+H\}}$ é uma única sequência de valores preditos, onde cada $\hat{y}_{\{t+h\}}$ é a melhor estimativa para o valor futuro $y_{\{t+h\}}$,

$$Y_{\{t-C+1:t\}} = \{y_{\{1\}}, y_{\{2\}}, \dots, y_{\{T\}}\}, \quad (2)$$

Na previsão probabilística, a saída de M não é um conjunto de valores pontuais, mas sim uma distribuição de probabilidade completa com valores futuros

$$M: Y_{\{t-C+1:t\}} \mapsto \hat{E}_{\{t+1:t+H\}}, \quad (3)$$

onde $\hat{E}_{\{t+1:t+H\}}$ representa a distribuição de probabilidade condicional estimada sobre o horizonte de previsão, permitindo quantificar a incerteza.

Portanto, o objetivo é avaliar o desempenho das previsões pontuais e probabilísticas geradas a partir das séries temporais de cada variável escolhida.

2.4 Modelos Clássicos de Previsão

Modelos clássicos como ARIMA e SARIMA são amplamente utilizados na previsão de séries temporais por serem simples, interpretáveis e eficazes, sendo referência em análises com dados históricos bem estruturados.

De acordo com Morettin (2018), a metodologia de Box e Jenkins (1970) “consiste em ajustar modelos autorregressivos integrados de médias móveis, ARIMA (p, d, q), a um conjunto de dados”.

O ARIMA (*AutoRegressive Integrated Moving Average*) é amplamente utilizado para previsão de séries temporais, estimando valores futuros com base nos parâmetros (p, d, q), onde: p é número de termos autorregressivos (AR), sendo o número de observações passadas que o modelo utiliza para prever o futuro; d é número de diferenciações necessárias para tornar a série estacionária (I) e q corresponde ao número de termos de médias móveis (MA), sendo o número de erros passados (resíduos) que o modelo usa para ajustar a previsão.

Embora sejam interpretáveis, as previsões pontuais não fornecem, por si só, uma medida da incerteza associada ao processo preditivo. Do ponto de vista gerencial, especialmente quando a tomada de decisão estratégica depende de indicadores da Construção Civil, é essencial compreender o grau de incerteza envolvido nas projeções (Makridakis, Tassos e Hyndman; 1998).

O ARIMA gera previsões pontuais e permite intervalos de previsão baseados em suposições estatísticas, mas sua capacidade probabilística é restrita a suposições gaussianas. Em cenários onde a avaliação de risco exige modelagem mais rica da incerteza, especialmente em setores como a Construção Civil, sujeitos a volatilidade macroeconômica (Giambiagi, 2011), o ARIMA pode ser insuficiente, pois não captura distribuições complexas devido a suposição de normalidade e linearidade dos dados, ou mudanças estruturais pela premissa de parâmetros constantes (estacionariedade).

Para mitigar as limitações relacionadas à captura de padrões sazonais, a literatura propõe a extensão do modelo para o SARIMA (Seasonal AutoRegressive Integrated Moving Average). Esta abordagem incorpora componentes estacionais multiplicativos à estrutura clássica, sendo denotada por ARIMA (p, d, q) \times (P, D, Q) $_s$. Neste formato, os parâmetros maiúsculos representam, respectivamente, os termos autorregressivos, de integração e de médias móveis sazonais, enquanto s define a periodicidade da série. No

contexto da Construção Civil, o SARIMA se mostra particularmente relevante por capturar dinâmicas que o ARIMA ignora, como a variação na demanda imobiliária em períodos específicos do ano, permitindo modelar a correlação não apenas entre meses consecutivos, mas entre os mesmos meses de anos diferentes.

Ainda assim, mesmo com a adição da componente sazonal, o SARIMA mantém a premissa de linearidade, o que reforça a necessidade de comparação com modelos não lineares para cenários de alta complexidade.


2.5 Modelos de Fundação de Séries Temporais (TSFMs)

Recentemente, a evolução do aprendizado de máquina deu origem aos Modelos de Fundação para Séries Temporais (TSFMs). Diferente da abordagem tradicional, que exige o treinamento de um modelo específico para cada base de dados, esses modelos são pré-treinados em vastos e heterogêneos conjuntos de dados, permitindo a aplicação do aprendizado por transferência (*transfer learning*). Dessa forma, um único modelo generalista pode ser adaptado para executar tarefas específicas com alta eficiência em novos cenários.

O alicerce técnico dos primeiros TSFMs é a arquitetura Transformer (Vaswani *et al.*, 2017). O diferencial dessa arquitetura reside no mecanismo de Atenção Plena (*Self-Attention*), que permite ao modelo avaliar a importância relativa de todos os pontos históricos em relação ao instante atual. Isso possibilita a captura de dependências de longo alcance de forma muito mais eficaz que os modelos recorrentes tradicionais (como RNNs ou LSTMs).

Como os *Transformers* processam os dados em paralelo, e não em sequência, eles utilizam a Codificação Posicional (*Positional Encoding*) para preservar a cronologia essencial das séries temporais. Além da capacidade de processamento, os TSFMs modernos destacam-se pela previsão probabilística: em vez de fornecerem apenas um valor único (estimativa pontual), eles geram uma distribuição de probabilidade, permitindo quantificar a incerteza, fator crítico para a tomada de decisão no planejamento e controle da produção.

A Figura 4 esquematiza o funcionamento da arquitetura geral do primeiro TSFM.

Figura 4 - Arquitetura Transformer

Fonte: Elaborado pelo autor, 2026.

Contudo, o campo de modelos fundacionais não se limita aos *Transformers*. Ma *et al.* (2024) introduziram o uso da arquitetura Mamba para reduzir a complexidade computacional em séries temporais extensas, mantendo a capacidade de generalização *zero-shot*.

Essa robustez técnica sustenta aplicações como a de Ribeiro *et al.* (2025), que investigou o desempenho desses modelos no contexto epidemiológico. O estudo ressalta que, para a saúde pública, a capacidade de quantificar incertezas é superior às previsões pontuais tradicionais.

Os Modelos de Fundação de Séries Temporais atuam como o preditor M em um ambiente *zero-shot* – ou seja – não é necessário treinar o modelo com a série temporal Y . Os padrões gerais aprendidos durante o pré-treinamento são aplicados em séries temporais não vistas, permitindo produzir previsões pontuais e probabilísticas.

Nesse sentido, é possível notar um ganho na aplicação de Modelos de Séries Temporais em relação a aplicação dos modelos clássicos, devido a sua capacidade de capturar dependências temporais complexas em cenários *zero-shot* (cenários onde os dados não foram previamente treinados), dispensando a modelagem estatística específica. O presente trabalho visa avaliar se este ganho ocorre quando o objetivo é prever indicadores da Construção Civil, possibilitando que estruturas organizacionais tenham uma gestão mais eficiente.

2.6 Trabalhos Relacionados

A evolução dos modelos preditivos consolidou-se, nos últimos anos, como um pilar estratégico para diversos setores. Na Construção Civil, pesquisas recentes exploram como paradigmas de Inteligência Artificial, notadamente algoritmos de Aprendizado de Máquina e Redes Neurais Profundas, podem elevar a acurácia das projeções, otimizando processos críticos como o planejamento físico-financeiro e o gerenciamento de riscos.

Nessa perspectiva, a Tabela 1 sintetiza os modelos emergentes aplicados ao setor, apresentando uma análise comparativa de suas implementações e respectivos desfechos.

Tabela 1 - Trabalhos Relacionados

TEMA	AUTOR	MODELOS UTILIZADOS	CONCLUSÕES
Prever a demanda futura por construções residenciais em diferentes regiões metropolitanas dos Estados Unidos.	Barker <i>et al.</i> (2021)	A previsão foi feita com três modelos supervisionados de <i>machine learning</i> : Regressão Linear Múltipla, <i>XGBoost Regressor</i> e Rede Neural Artificial (MLP).	O modelo com melhor desempenho foi o MLP, que capturou melhor os padrões complexos da série histórica. O estudo aborda que modelos clássicos apresentam limitações por não serem capazes de lidar com não linearidades.
Prever custos de construção utilizando modelos de <i>Deep Learning</i> .	Shi; Shide. (2025)	LSTM (<i>Long Short-Term Memory</i>), GRU (<i>Gated Recurrent Unit</i>) e Transformer.	O modelo <i>Transformer</i> superou as arquiteturas recorrentes (LSTM/GRU), demonstrando maior eficácia na captura de dependências de longo prazo e interações complexas através do mecanismo <i>Self-Attention</i> .

Fonte: Elaborado pelo autor, 2026.

A análise dos dados apresentados na Tabela 1 justifica a exploração de Modelos de Fundação de Séries Temporais para o setor da Construção Civil. Observa-se um avanço tecnológico em que modelos de aprendizado de máquina superam abordagens estatísticas tradicionais (Barker *et al.*, 2021) e, mais recentemente, arquiteturas baseadas em *Transformers* apresentam desempenho superior a modelos recorrentes (Shi e Shide, 2025).

Para o levantamento desse estado de arte, realizou-se uma pesquisa bibliográfica através do Google Acadêmico, empregando os termos de busca: *construction, forecasting, prediction*.

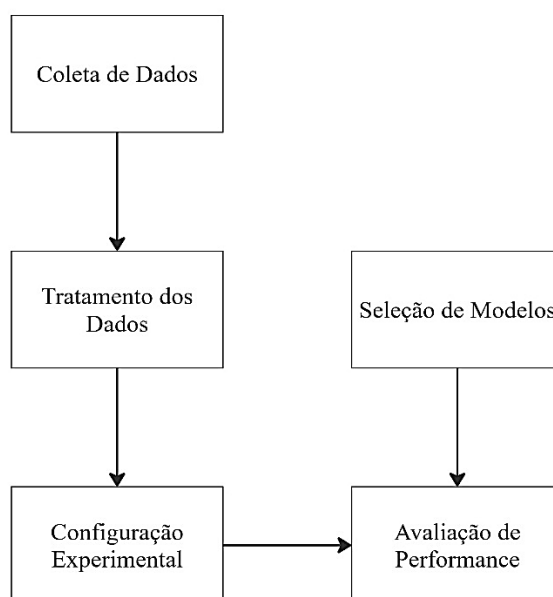
3 METODOLOGIA

Gunther (2006) define como método quantitativo aquele em que a pesquisa tem como base variáveis e fatores exatos e mensuráveis para análise de proposta. Enquanto Boclin (1999) sugere que, além de quantitativa, uma avaliação também deve ser comparativa.

Baseado nos conceitos anteriores, a metodologia adotada no presente trabalho foi elaborada visando garantir a coerência com os objetivos propostos, uma vez que os indicadores macroeconômicos abordados serviram como base para comparação dos modelos de previsão, culminando em uma pesquisa quantitativa e descritiva.

A Figura 5 apresenta uma visão geral de todo o processo metodológico, contemplando desde a etapa de coleta dos dados até a configuração e aplicação dos modelos utilizados para a geração das previsões.

Figura 5 - Processo Metodológico



Fonte: Elaborado pelo autor, 2026.

As seções a seguir detalharão o processo metodológico aplicado, iniciando-se pela Coleta de Dados, que fundamenta a seleção dos indicadores da construção civil para o suporte à tomada de decisão. Sequencialmente, a seção de Tratamento de Dados expõe os procedimentos de estruturação e as estatísticas descritivas das séries, enquanto a Configuração Experimental estabelece o delineamento dos testes, incluindo a definição

de janelas de contexto e horizontes para simular cenários de planejamento. A fundamentação técnica prossegue na seção de Seleção de Modelos, que discute a escolha da abordagem clássica e dos TSFMs com suas respectivas arquiteturas, culminando na Avaliação de Performance, onde são apresentadas as métricas estatísticas utilizadas para validar a precisão das previsões geradas.

3.1 Coleta de Dados

Os indicadores foram selecionados com base em sua relevância para o setor da Construção Civil e em seu potencial, para quando analisados de forma integrada, resultarem em um planejamento eficaz por meio da elaboração de cenários futuros. A amostra considerada compreende a variação mensal do INCC, obtido por meio do portal da Fundação Getúlio Vargas (FGV); a média mensal da taxa SELIC, consultadas no portal do Banco Central do Brasil (BCB); e os valores mensais do CUB global, bem como de seus componentes: materiais, mão de obra, despesas administrativas e equipamentos, coletados no portal da Câmara Brasileira da Indústria da Construção (CBIC).

3.2 Tratamento dos Dados

Os dados foram estruturados como séries temporais, possibilitando a utilização de modelos clássicos paramétricos, bem como dos modelos mais atuais, que capturam padrões temporais complexos por meio de aprendizado a partir dos próprios dados.

Os registros coletados abrangem o período a partir de janeiro de 2010 até janeiro de 2025, resultando em uma janela de 181 meses e foram organizados em planilhas do Microsoft Excel, etapa fundamental para garantir a padronização dos históricos e integridade das variáveis antes da fase de modelagem, permitindo a exportação de arquivos prontos e estruturados para serem consumidos pelo ambiente de programação.

As estatísticas descritivas dos dados, que incluem a contagem (Cont.), média (Méd.), desvio padrão (D.P.), valores mínimos (Mín.) e máximos (Máx.), além dos quartis (25%, 50% e 75%), são apresentadas na Tabela 2.

Tabela 2 – Estatísticas Descritivas

	INCC	Taxa SELIC	CUB Global	CUB Material	CUB Mão de Obra	CUB Desp. Administrativa	CUB Equipamento
Cont.	181	181	181	181	181	181	181
Méd.	0,57	9,52	1391,73	600,96	735,00	49,76	6,01
D.P.	0,52	3,46	400,13	189,19	209,65	9,63	1,54
Min.	-0,02	1,90	824,85	408,66	382,29	30,15	3,75
25%	0,23	6,90	1074,50	464,43	562,13	42,57	5,01
50%	0,41	10,42	1329,22	507,85	763,19	52,83	5,61
75%	0,72	12,15	1671,71	759,33	852,88	54,85	6,47
Máx.	2,94	14,15	2210,41	996,56	1136,75	66,98	10,12

Fonte: Elaborado pelo autor, 2026.

Optou-se pela não aplicação de métodos de normalização ou padronização dos dados, visto que nas características intrínsecas das arquiteturas dos TSFMs há o ajustamento das magnitudes das informações de entrada. Da mesma forma, o AutoARIMA é capaz de processar séries em sua escala original sem prejuízo à convergência do algoritmo.

É possível visualizar as séries temporais das variáveis na seção [ANEXOS](#).

3.3 Configuração Experimental

Segundo Hewamalage *et al.* (2023), para uma avaliação rigorosa de previsões em séries temporais, os protocolos devem diferir substancialmente das práticas padrão de regressão em *Machine learning*, devido a dependências temporais e não-estacionariedade dos dados.

Diferente das abordagens tradicionais de aprendizado de máquina, que exigem a divisão dos dados em conjuntos de treino e teste para ajuste de parâmetros, este trabalho adota o princípio *zero-shot* para os TSFMs. Nesse contexto, a série temporal não é utilizada para treinamento, mas sim para o fornecimento de uma Janela de Contexto (C), que serve como base informativa para que o modelo pré-treinado gere a Janela de Horizonte (H).

Conforme ilustrado na Figura 6, a Janela de Contexto (em laranja) mantém-se fixa, enquanto a Janela de Horizonte (em azul) representa o período futuro a ser previsto em cada iteração.


Figura 6 - Abordagem por Origem Fixa

Fonte: Elaborado pelo autor, 2026.

Diferente da origem fixa, a origem móvel atualiza a origem de previsão ao longo do tempo, criando múltiplos períodos de teste.

Nessa configuração, a janela de contexto é deslocada progressivamente ao longo do tempo, incorporando novas observações e descartando as mais antigas a cada iteração. Para cada posição da janela de contexto, é definida uma janela de horizonte correspondente ao período futuro a ser previsto. Essa estratégia permite que o modelo utilize informações mais recentes da série temporal em cada previsão, favorecendo a adaptação a mudanças dinâmicas do comportamento dos dados.

A Figura 7 ilustra a abordagem de origem móvel, caracterizada pelo deslocamento progressivo da janela de contexto ao longo da série temporal.

Figura 7 - Abordagem por Origem Móvel

Fonte: Adaptado de Ribeiro, Luz e Gertrudes (2025, p. 5).

Nesse contexto, as séries foram particionadas em blocos independentes, onde o tamanho de cada janela é a soma do Contexto (C) e do Horizonte (H).

A definição dos horizontes de previsão (H) em 12 (curto prazo) e 24 (médio/longo prazo) meses visa refletir cenários de planejamento realistas, onde $H = 12$ captura um ciclo sazonal completo, o que é essencial para o planejamento orçamentário anual na Construção Civil e $H = 24$ permite avaliar a degradação do modelo ao tentar prever tendências macroeconômicas mais distantes.

Quanto ao comprimento do Contexto (C), os valores propostos cobrem três níveis cruciais de informação histórica:

- $C = 24$ meses, oferece um histórico focado em tendências recentes;
- $C = 60$ meses, permite capturar ciclos econômicos de médio prazo e padrões sazonais repetidos;
- $C = 120$ meses, extrair padrões complexos e de longo prazo.

Além disso, com a configuração mais longa proposta sendo ($C + H = 120 + 24 = 144$ meses), será possível realizar ao menos uma validação completa sobre os dados, uma vez que cada indicador apresenta uma janela de 181 meses.

Adotou-se a estratégia de origem móvel com a execução de 10 janelas deslizantes, permitindo avaliar a estabilidade e a capacidade de generalização dos modelos ao longo de diferentes períodos. Essa abordagem permite que os resultados obtidos não sejam decorrentes de flutuações sazonais ou anomalias pontuais.

3.4 Seleção de Modelos

A escolha de modelos clássicos justifica-se pela necessidade de estabelecer um limiar mínimo de desempenho estatístico robusto, servindo como referência metodológica para a avaliação comparativa de abordagens mais complexas, como nos TSFMs.

A utilização do AutoARIMA como representante dos modelos clássicos fundamenta-se em sua capacidade de automatizar a busca pelos parâmetros ideais de ordens autorregressivas, de diferenciação e de média móvel. Ao identificar padrões sazonais nos dados e incorporar os termos correspondentes, o algoritmo funciona

efetivamente como um modelo SARIMA sempre que a natureza cíclica da série temporal assim o exige.

No que se refere aos Modelos de Fundação de Séries Temporais, a premissa de seleção concentrou-se em modelos capazes de operar em regime *zero-shot*, porém com diferentes arquiteturas de funcionamento, o que possibilita uma análise comparativa da eficácia entre essas arquiteturas. Ademais, foram priorizados modelos que não tenham sido previamente treinados nas séries de dados utilizadas neste estudo.

A Tabela 3 detalha os modelos escolhidos e suas respectivas arquiteturas.


Tabela 3 - Visão Geral dos Modelos TSFMs

MODELO	ARQUITETURA	DATASET DE PRÉ-TREINO PRINCIPAL
Chronos	T5-based LM Framework	Corpus de Linguagem T5 e Monash Archive
Moirai	Encoder	LOTSAs (Large-scale Open Time Series Archive)

Fonte: Elaborado pelo autor, 2026.

A arquitetura adotada no modelo Chronos baseia-se na conversão de valores numéricos em *tokens*, permitindo que o modelo “leia” séries temporais de forma análoga ao processamento de texto. O treinamento é realizado sobre um conjunto diversificado de dados, que inclui séries reais, como dados financeiros e meteorológicos, bem como dados sintéticos gerados por processos gaussianos. Essa combinação possibilita ao modelo aprender padrões estatísticos gerais e transferíveis entre diferentes domínios. A Figura 8 ilustra a arquitetura utilizada no modelo Chronos.

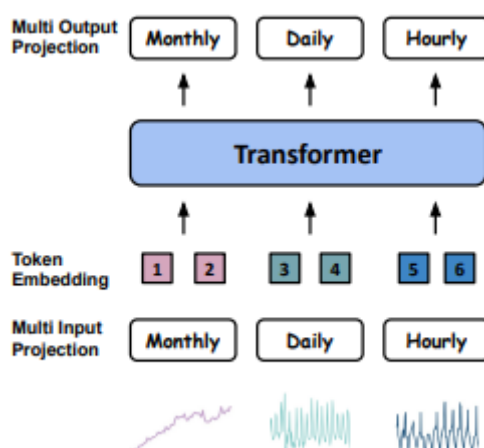
Figura 8 - Arquitetura do modelo Chronos



Fonte: Ansari *et al.* (2024, p. 2).

Enquanto na estrutura do modelo Moirai, a série é dividida em *patches*, possibilitando que uma mesma série seja observada em diferentes tamanhos e frequências. Os dados de treinamento são provenientes de um dos maiores arquivos de dados do mundo (LOTSAs), contendo desde batimentos cardíacos a variações de energia, ou seja, o modelo foi treinado em diferentes magnitudes numéricas. A Figura 9 demonstra o funcionamento da arquitetura do modelo Moirai.

Figura 9 - Arquitetura do modelo Moirai



Fonte: Liu *et al.* (2024, p. 4).

A execução dos modelos preditivos foi realizada em ambiente de nuvem via *Google Colab*, utilizando a linguagem de programação *Python 3.10* e bibliotecas de

computação científica como *Pandas* e *NumPy*. O modelo estatístico AutoARIMA foi implementado através da biblioteca *pmdarima*, que automatiza a seleção dos parâmetros (p , d , q). Para os modelos de fundação, utilizou-se a biblioteca *PyTorch* com aceleração por GPU (CUDA) para processar as arquiteturas baseadas em Transformers: o *Chronos*, desenvolvido pela *Amazon Science*, e o *Moirai*, da *Salesforce AI Research*, ambos operados sob o paradigma *zero-shot* via integração com a biblioteca *uni2ts* e *GluonTS*.

3.5 Avaliação de Performance

De acordo com Hewamalage *et al.* (2023), considerando as estatísticas descritivas apresentadas na Tabela 2, a presença de valores negativos e a heterogeneidade das escalas dos dados tornam a métrica MASE (Erro Médio Absoluto Escalonado) mais adequada para a avaliação do desempenho dos modelos em previsões pontuais.

Para a avaliação das previsões probabilísticas, o presente trabalho fundamentou sua estrutura metodológica no estudo de Ribeiro *et al.* (2025), adotando o CRPS (Índice de Probabilidade Contínua) como a métrica central. A escolha do CRPS justifica-se por sua capacidade de avaliar a qualidade da distribuição de probabilidade completa prevista, indo além de simples estimativas pontuais e permitindo uma análise mais rica das incertezas inerentes aos indicadores econômicos.

Para comparar o desempenho entre os modelos clássicos e os modelos de fundação, foram aplicados protocolos de testes estatísticos seguindo a mesma base referencial. Inicialmente, utilizou-se o teste de Friedman para verificar se existiam diferenças de desempenho estatisticamente significativas entre as múltiplas arquiteturas avaliadas ao longo das diversas janelas de tempo. Complementarmente, realizou-se a análise *post-hoc* usando o método de Nemenyi para identificar de forma específica as diferenças pareadas entre os modelos, permitindo a construção de rankings de desempenho validados por diagramas de diferença crítica.

O processamento estatístico e a geração dos Diagramas de Diferença Crítica foram realizados utilizando as bibliotecas *SciPy* e *Matplotlib*, garantindo a robustez científica necessária para a validação das conclusões.

4 RESULTADOS E DISCUSSÃO

As tabelas de resultados a seguir estão estruturadas de forma a permitir uma comparação entre os modelos, em diferentes janelas de Contexto (C) e Horizonte (H). Para agilizar a análise visual, aplicou-se um sistema de *heatmap*: tons claros ou esverdeados indicam maior precisão, enquanto tons saturados ou avermelhados apontam maiores desvios.

A análise de desempenho dos modelos iniciou-se visando testar o desempenho dos modelos em um horizonte de curto prazo (H = 12 meses) para previsões pontuais avaliadas pela métrica MASE. A Tabela 4 apresenta o desempenho obtido.

Tabela 4 - Resultados a curto prazo (MASE)

	MASE				
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	24	12	0,0019	0,0040	0,0174
CUB Equipamento	24	12	0,0027	0,0023	0,0073
CUB Global	24	12	0,0030	0,0035	0,0163
CUB Mão de Obra	24	12	0,0032	0,0014	0,0179
CUB Material	24	12	0,0062	0,0050	0,0087
INCC	24	12	0,0009	0,0008	0,0008
Taxa SELIC	24	12	0,0220	0,0165	0,0285
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	60	12	0,0019	0,0029	0,0168
CUB Equipamento	60	12	0,0032	0,0037	0,0177
CUB Global	60	12	0,0048	0,0051	0,0936
CUB Mão de Obra	60	12	0,0052	0,0033	0,0687
CUB Material	60	12	0,0119	0,0081	0,1103
INCC	60	12	0,0008	0,0009	0,0011
Taxa SELIC	60	12	0,0085	0,0142	0,0348
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	120	12	0,0030	0,0040	0,0308
CUB Equipamento	120	12	0,0030	0,0034	0,0277
CUB Global	120	12	0,0100	0,0069	0,2198
CUB Mão de Obra	120	12	0,0033	0,0031	0,1315
CUB Material	120	12	0,0204	0,0169	0,2935
INCC	120	12	0,0007	0,0007	0,0008
Taxa SELIC	120	12	0,0076	0,0156	0,0173

Fonte: Elaborado pelo autor, 2026.

No horizonte de 12 meses, observa-se uma paridade competitiva entre o modelo clássico AutoARIMA e o TSFM Chronos, indicando que, em prazos curtos, a modelagem linear e os modelos pré-treinados em larga escala convergem em patamares de erro similares. Esta equivalência sugere que a complexidade arquitetural dos modelos não necessariamente se traduz em ganhos de precisão drásticos quando a incerteza temporal é reduzida.

Em contrapartida, o modelo Moirai manifesta uma sensibilidade ao volume de dados históricos, apresentando uma degradação do MASE à medida que o contexto é expandido para 120 meses.

A Tabela 5 apresenta os resultados quando o horizonte é expandido para 24 meses.

Tabela 5 - Resultados a longo prazo (MASE)

MASE					
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	24	24	0,0028	0,0050	0,0209
CUB Equipamento	24	24	0,0065	0,0150	0,0444
CUB Global	24	24	0,0411	0,0065	0,0876
CUB Mão de Obra	24	24	0,0083	0,0069	0,0615
CUB Material	24	24	0,0440	0,0297	0,0862
INCC	24	24	0,0021	0,0008	0,0030
Taxa SELIC	24	24	0,0378	0,0185	0,0252
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	60	24	0,0069	0,0064	0,0172
CUB Equipamento	60	24	0,0074	0,0066	0,0185
CUB Global	60	24	0,0529	0,0358	0,2563
CUB Mão de Obra	60	24	0,0222	0,0119	0,1372
CUB Material	60	24	0,0614	0,0348	0,2493
INCC	60	24	0,0018	0,0010	0,0017
Taxa SELIC	60	24	0,0207	0,0205	0,0673
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	120	24	0,0049	0,0074	0,0312
CUB Equipamento	120	24	0,0090	0,0093	0,0311
CUB Global	120	24	0,0469	0,0255	0,3312
CUB Mão de Obra	120	24	0,0093	0,0077	0,1578
CUB Material	120	24	0,0905	0,0311	0,4384
INCC	120	24	0,0006	0,0006	0,0009
Taxa SELIC	120	24	0,0114	0,0204	0,0361

Fonte: Elaborado pelo autor, 2026.

No horizonte de 24 meses, o modelo AutoARIMA mantém-se pareado ao modelo Chronos, esse comportamento indica que, mesmo diante de um aumento moderado da incerteza temporal, a modelagem estatística clássica permanece eficaz na captura de padrões relevantes, sem apresentar perdas expressivas de acurácia em relação a modelos fundacionais pré-treinados.

Em contraste, o modelo Moirai evidencia dificuldades crescentes à medida que o volume de dados históricos é ampliado. Sugerindo limitações do modelo em lidar com ruídos e mudanças estruturais de longo prazo.

Já na análise de previsões probabilísticas, foi utilizado a métrica CRPS nas mesmas janelas. A Tabela 6 exhibe os resultados para $H = 12$.

Tabela 6 - Resultados a curto prazo (CRPS)

CRPS					
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	24	12	0,3767	0,7971	3,5788
CUB Equipamento	24	12	0,3386	0,2648	0,8725
CUB Global	24	12	15,5179	19,6434	83,8278
CUB Mão de Obra	24	12	9,8551	9,8777	60,6781
CUB Material	24	12	12,9328	14,2959	16,9939
INCC	24	12	0,2362	0,2343	0,2806
Taxa SELIC	24	12	1,0522	0,9082	1,2802
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	60	12	0,6081	0,8175	5,9229
CUB Equipamento	60	12	0,2686	0,3389	1,7279
CUB Global	60	12	13,4349	18,3863	227,5881
CUB Mão de Obra	60	12	8,3830	8,4659	123,9045
CUB Material	60	12	13,1423	8,6169	104,1538
INCC	60	12	0,1715	0,1886	0,2986
Taxa SELIC	60	12	0,5327	1,0497	1,8406
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	120	12	0,6592	0,9593	7,7995
CUB Equipamento	120	12	0,2317	0,2459	2,2596
CUB Global	120	12	18,2493	14,6680	402,0055
CUB Mão de Obra	120	12	4,9961	5,7307	189,4597
CUB Material	120	12	13,3605	11,6248	195,4041
INCC	120	12	0,1754	0,1834	0,2698
Taxa SELIC	120	12	0,4483	0,8782	1,0672

Fonte: Elaborado pelo autor, 2026.

No horizonte de 12 meses, os resultados de CRPS indicam um desempenho novamente competitivo entre o AutoARIMA e o modelo Chronos, com alternância de superioridade dependendo da série analisada. Em contraste, o modelo Moirai exibe valores de CRPS significativamente inferior, indicando dificuldades na modelagem adequada da distribuição preditiva, mesmo em horizontes curtos.

A Tabela 7, por sua vez, mostra os resultados obtidos nas previsões probabilísticas quando o horizonte é expandido para 24 meses.

Tabela 7 - Resultados a longo prazo (CRPS)

	CRPS				
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	24	24	0,5545	1,3973	5,8073
CUB Equipamento	24	24	0,2474	0,4390	1,7502
CUB Global	24	24	145,7263	32,7904	183,9031
CUB Mão de Obra	24	24	16,0629	20,5933	118,6811
CUB Material	24	24	48,4963	26,5941	58,9023
INCC	24	24	0,4021	0,2214	0,7404
Taxa SELIC	24	24	5,8357	1,7305	2,9255
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	60	24	2,3025	1,8656	6,8429
CUB Equipamento	60	24	0,7105	0,6697	2,1472
CUB Global	60	24	68,6578	59,4655	329,2263
CUB Mão de Obra	60	24	25,2668	20,6893	166,7189
CUB Material	60	24	45,8859	28,8764	163,2729
INCC	60	24	0,2838	0,1781	0,3665
Taxa SELIC	60	24	1,2560	1,2476	3,9692
	C	H	AutoARIMA	Chronos	Moirai
CUB Desp. Administrativa	120	24	1,0770	1,8504	7,5663
CUB Equipamento	120	24	0,6062	0,5834	2,4923
CUB Global	120	24	57,4585	39,4780	479,0342
CUB Mão de Obra	120	24	11,6624	11,7250	216,2850
CUB Material	120	24	42,9238	18,7799	241,6507
INCC	120	24	0,1811	0,1722	0,3309
Taxa SELIC	120	24	0,7620	1,1779	1,7368

Fonte: Elaborado pelo autor, 2026.

Quando o horizonte de previsão foi ampliado para 24 meses, o modelo Chronos destacou-se como o mais confiável e estável, mantendo níveis baixos de erro. O AutoARIMA surpreendeu apresentando desempenho relativamente próximo ao Chronos.

Em contrapartida, o Moirai obteve o pior desempenho nesse cenário, sobretudo quando treinado com 120 meses de histórico, o que reforça a evidência de que o modelo apresenta limitações no tratamento de excesso de informação passada em previsões de longo prazo.

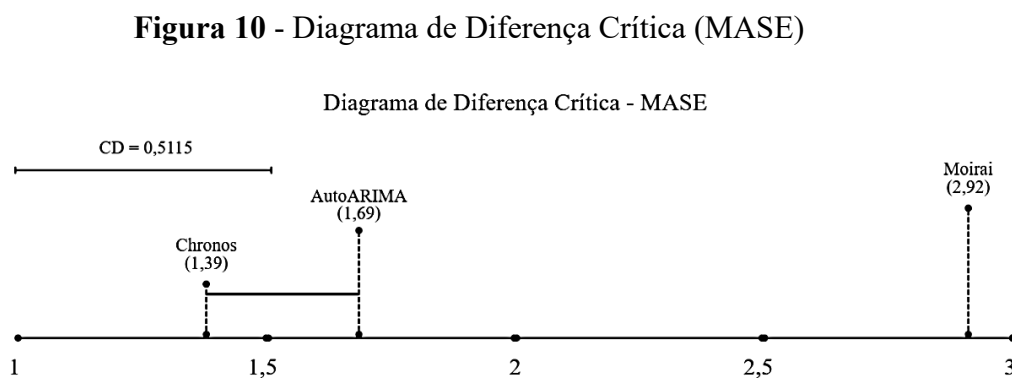
Logo, é possível concluir que a eficácia dos TSFMs é variável e dependente da natureza do indicador. No presente estudo, o Chronos emerge como solução mais equilibrada e precisa para previsões ao longo prazo, reduzindo não apenas o erro pontual, mas também oferecendo uma estimativa de incerteza mais coerente. O AutoARIMA, embora superado na maioria das previsões dos custos de obra, permanece sendo um excelente método de previsão. Por fim, o Moirai comprova que a escolha do modelo deve priorizar sua robustez, e não o quanto é inovador.

Com o intuito de determinar se as variações de desempenho entre os modelos são significantes dentre as várias janelas de contexto e horizonte, aplicou-se o teste de Friedman. A combinação das sete variáveis com seis possíveis janelas resultou em 42 blocos experimentais.

Após a execução do teste de Friedman, observou-se um valor- p inferior ao nível de significância adotado de 0,05 ($p < 0,0001$), o que resulta na rejeição da hipótese nula (H_0) de que os modelos apresentam desempenhos equivalentes.


Diante da rejeição da H_0 , procedeu para aplicação da análise *post-hoc* de Nemenyi, ranqueando e comparando os modelos par a par. Em ambas as métricas, o modelo Chronos liderou, seguido pelo AutoARIMA, em último o modelo Moirai.

A Figura 10 apresenta o diagrama de Diferença Crítica pela métrica MASE.



Fonte: Elaborado pelo autor, 2026.

A Figura 11 também avalia a Diferença Crítica dos modelos, porém pela métrica CRPS.

Figura 11 - Diagrama de Diferença Crítica (CRPS)

Fonte: Elaborado pelo autor, 2026.

Em ambos os diagramas há barras de conectividade entre os modelos Chronos e AutoARIMA, indicando desempenhos estatisticamente equivalentes. Por outro lado, a ausência de conectividade entre o Moirai e demais modelos demonstra inferioridade estatística significativa para o conjunto de dados avaliado.

Portanto, conclui-se que, para os indicadores avaliados, a combinação de estratégica entre o Chronos e AutoARIMA oferece robustez para o planejamento. Do ponto de vista da Engenharia de Produção, a conciliação dos modelos permite uma gestão de riscos otimizada em diferentes horizontes. Enquanto o Chronos provou-se superior na captura de tendências e variações ao longo prazo, principalmente para custos, o AutoARIMA mantém sua eficácia na projeção de indicadores econômicos, permitindo tomadas de decisões mais assertivas.

Em um contexto de tomada de decisão para suporte ao PCP, um modelo com eficácia preditiva pode reduzir estoques de segurança baseados em incerteza, antecipar a necessidade de contratação de mão de obra sazonal e garantir compras de insumos em janelas de preços mais favoráveis.

5 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

A presente pesquisa cumpriu seu objetivo ao avaliar o desempenho de previsões *zero-shot* frente a um modelo com abordagem clássica no contexto da Construção Civil. Os resultados revelaram que, embora vivemos em uma era acelerada de inovação, a adoção de tecnologias de ponta não garante, por si só, superioridade técnica. Observou-se que o modelo ARIMA manteve superioridade ao modelo Moirai em diversos cenários. Contudo, a equivalência estatística entre ARIMA e Chronos nos resultados valida o potencial dos TSFMs como ferramentas disruptivas para o setor.

A principal contribuição desse trabalho para o Planejamento e Controle da Produção é a demonstração de que é possível implementar um sistema de previsão híbrido. Para empresas do setor, essa abordagem traz orçamentos mais assertivos, redução de estoques e uma gestão de fluxo de caixa protegida contra as incertezas do mercado.

Apesar dos resultados promissores, a implementação prática dessas ferramentas exige um conhecimento interdisciplinar em programação e estatística, o que pode dificultar a adoção imediata por gestores que utilizam ferramentas convencionais. Além disso, o acesso e tratamento dos dados carece de padronização e facilidade de coleta.

Por fim, como desdobramento dessa pesquisa, sugere-se a expansão das análises de modelos avaliados, incluindo novos TSFMs quanto outros modelos estatísticos clássicos e/ou que utilizam *Machine learning*, e a adoção de outros indicadores a serem avaliados.

REFERÊNCIAS BIBLIOGRÁFICAS

ANSARI, Abdul Fatir *et al.* **Chronos: Learning the language of time series.** *arXiv preprint*, 2024. Disponível em: <<https://arxiv.org/abs/2403.07815>>. Acesso em: 28 jan. 2026.

BANCO CENTRAL DO BRASIL (BCB). **Taxa Selic:** definição e impactos na economia brasileira. Brasília, DF: BCB, 2024. Disponível em: <https://www.bcb.gov.br>. Acesso em: 02 fev. 2026.

BARKER, Jayson; RAMOS, Emil; RODGERS, John; SHAHZAD, Saqib. *Machine learning* forecasting of construction demand in the USA as indicated by economic, geographic and demographic cues. *SMU Data Science Review*, [s. l.], v. 5, n. 2, art. 4, 2021.

BOCLIN, Roberto. Indicadores de desempenho: novas estratégias da educação superior. *Ensaio: Avaliação e Políticas Públicas em Educação*, Rio de Janeiro, v. 7, n. 24, p. 299–308, jul./set. 1999.

BOX, G. E. P.; JENKINS, G. M. **Time series analysis: forecasting and control.** San Francisco: Holden-Day, 1970.

BRASIL. Ministério do Trabalho e Emprego. **Novo Caged: Emprego formal teve crescimento de 16,5% em 2024.** [Brasília, DF], 30 jan. 2025. Disponível em: <https://www.gov.br/trabalho-e-emprego/pt-br/noticias-e-conteudo/2025/janeiro/novo-caged-emprego-formal-teve-crescimento-de-16-5-em-2024>. Acesso em: 11 nov. 2025.

CÂMARA BRASILEIRA DA INDÚSTRIA DA CONSTRUÇÃO (CBIC). **CUB:** Custo Unitário Básico - Metodologia de cálculo. Brasília, DF: CBIC, 2024. Disponível em: <https://cbic.org.br>. Acesso em: 02 fev. 2026.

CARVALHO PEREIRA, Alan Francisco; LIMA, Paulo Henrique Carneiro. O COMPORTAMENTO DO VALOR AGREGADO BRUTO DA CONSTRUÇÃO CIVIL AO LONGO DOS ÚLTIMOS 10 ANOS: UMA APLICAÇÃO DE MÉTODOS DE ANÁLISE DE SÉRIES TEMPORAIS. *Revista Pernambucana de Administração*, [S. l.], v. 4, n. 1, 2025. DOI: 10.70678/rpad.v4i1.1395. Disponível em: <https://periodicos.upe.br/index.php/rpad/article/view/1395>. Acesso em: 15 nov. 2025.

CORRÊA, Henrique L.; GIANESI, Irineu Gustavo N.; CAON, Mauro. **Planejamento, Programação e Controle da Produção - MRP II / ERP, 6ª edição.** Rio de Janeiro:

Atlas, 2018. E-book. p.2. ISBN 9788597018554. Disponível em: <https://integrada.minhabiblioteca.com.br/reader/books/9788597018554/>. Acesso em: 15 nov. 2025.

DAS, Abhimanyu *et al.* A decoder-only foundation model for time-series forecasting. In: **FORTY-FIRST INTERNATIONAL CONFERENCE ON MACHINE LEARNING**, 2024, Viena. *Anais [...]*. Viena: PMLR, 2024. Disponível em: proceedings.mlr.press. Acesso em: 28 jan. 2026.

FUNDAÇÃO GETULIO VARGAS (FGV). **Índice Nacional de Custo da Construção (INCC): Metodologia e conceitos**. Rio de Janeiro: FGV IBRE, 2024. Disponível em: <https://portalibre.fgv.br>. Acesso em: 02 fev. 2026.

GARZA, Azul; CHALLU, Cristian; MERGENTHALER-CANSECO, Max. *TimeGPT-1*. San Francisco: Nixtla, 2024. **arXiv preprint**, arXiv:2310.03589v3. Disponível em: <https://arxiv.org/abs/2310.03589>. Acesso em: 28 jan. 2026.

GIAMBIAGI, F.; ALÉM, A. C. **Finanças públicas: teoria e prática no Brasil**. 4. ed. atual. Rio de Janeiro: Elsevier, 2011.

GÜNTHER, Hartmut. **Pesquisa qualitativa versus pesquisa quantitativa: esta é a questão?** Brasília: Universidade de Brasília, 2006.

HEWAMALAGE, Hansika; ACKERMANN, Klaus; BERGMEIR, Christoph. Forecast evaluation for data scientists: common pitfalls and best practices. **Data Mining and Knowledge Discovery**, [s. l.], v. 37, n. 2, p. 788-832, 2023.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Agência de Notícias. **PIB cresce 3,4% em 2024 e fecha o ano em R\$ 11,7 trilhões**. Rio de Janeiro, 1º mar. 2025. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-sala-de-imprensa/2013-agencia-de-noticias/releases/42774-pib-cresce-3-4-em-2024-e-fecha-o-ano-em-r-11-7-trilhoes>. Acesso em: 11 nov. 2025.

LIU, Xu *et al.* *Moirai-MoE: Empowering Time Series Foundation Models with Sparse Mixture of Experts*. **arXiv preprint**, arXiv:2410.10469, 2024. Disponível em: <https://arxiv.org/abs/2410.10469>. Acesso em: 28 jan. 2026.

MA, Haoyu *et al.* *A Mamba foundation model for time series forecasting*. **arXiv preprint**, arXiv:2411.02941, 2024. Disponível em: <https://arxiv.org/abs/2411.02941>. Acesso em: 28 jan. 2026.

MACHADO, Ricardo Luiz. **Um modelo de PCP de curto prazo para a construção civil**. 1998. Dissertação (Mestrado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 1998.

MAKRIDAKIS, S.; TASSOS, P.; HYNDMAN, R. J. **Forecasting: Methods and Applications**. Wiley, 1998.

MORETTIN, Pedro A. **Análise de Séries Temporais**. São Paulo: Editora Blucher, 2018. E-book. p.21. ISBN 9788521213529. Disponível em: <https://integrada.minhabiblioteca.com.br/reader/books/9788521213529/>. Acesso em: 16 nov. 2025.

RAFIEL, M. H.; ADELI, H. **Novel Machine-Learning Model for Estimating Construction Costs Considering Economic Variables and Indexes**. *Journal of Construction Engineering and Management*, v. 144, n. 12, 2018. Disponível em: ASCE Library.

RIBEIRO, L. M.; LUZ, E.; GERTRUDES, J. C. How effective are time series foundation models for epidemiological data analysis? In: **IEEE-EMBS INTERNATIONAL CONFERENCE ON BIOMEDICAL AND HEALTH INFORMATICS**, 2025. *Anais...* 2025.

SHI, T.; SHIDE, K. A comparative analysis of LSTM, GRU, and Transformer models for construction cost prediction with multidimensional feature integration. *Journal of Asian Architecture and Building Engineering*, [s. l.], p. 1–16, 2025.


SUCCAR, B.; KASSEM, M. **Macro-BIM adoption: Conceptual structures**. *Automation in Construction*, v. 57, p. 64-79, set. 2015.

TRIBUNAL DE CONTAS DA UNIÃO (TCU). **Metade das obras financiadas com recursos federais estão paradas**. Brasília, DF: Secom, 30 jul. 2025. Disponível em: <https://portal.tcu.gov.br/imprensa/noticias/metade-das-obras-financiadas-com-recursos-federais-estao-paradas>. Acesso em: 11 nov. 2025.


VASWANI, Ashish *et al.* *Attention is all you need*. In: **INTERNATIONAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS**, 31., 2017, Long Beach. *Proceedings...* Red Hook, NY: Curran Associates, 2017. p. 6000–6010.

ANEXOS


Série Temporal: CUB Equipamento




Série Temporal: CUB Desp. Administrativa



Série Temporal: CUB Mão de Obra



Série Temporal: Cub Material



Série Temporal: CUB Global

