



Universidade de Brasília
Departamento de Estatística

**Previsão do Índice Nacional de Preços ao Consumidor: Abordagens
Tradicionais de Séries Temporais e de Aprendizado de Máquina**

João Victor de Oliveira Nogueira

Relatório apresentado para o Departamento de Estatística da Universidade de Brasília como parte dos requisitos necessários para obtenção do grau de Bacharel em Estatística.

**Brasília
2025**

João Victor de Oliveira Nogueira

**Previsão do Índice Nacional de Preços ao Consumidor: Abordagens
Tradicionais de Séries Temporais e de Aprendizado de Máquina**

Orientador(a): Prof. Helton Saulo Bezerra dos Santos

Relatório apresentado para o Departamento de Estatística da Universidade de Brasília como parte dos requisitos necessários para obtenção do grau de Bacharel em Estatística.

**Brasília
2025**

Agradecimentos

A Deus, por me conceder a oportunidade de viver e a cada dia buscar os meus sonhos, e por todas as bênçãos.

Aos meus pais, por serem a base de quem sou e meus exemplos de vida, por me proporcionarem amor, por me apoiarem nesta conquista e por estarem comigo em todos os momentos.

Ao meu irmão, familiares e amigos, por todo o apoio e amizade proporcionado.

A minha companheira, por fazer parte desta jornada da graduação e crescimento de vida.

Ao professor orientador Helton Saulo, pela credibilidade, paciência e confiança no trabalho prestado.

Resumo

Este trabalho compara modelos de séries temporais tradicionais (SARIMAX, ETS) e de aprendizado de máquina (GBM, XGBoost) para prever o Índice Nacional de Preços ao Consumidor (INPC), utilizando um vasto banco de dados econômicos e validação por janela deslizante. Os resultados mostram que, embora os modelos de aprendizado de máquina tenham maior estabilidade de erro (RMSE) em média, a abordagem SARIMAX tende a ficar mais acurada em horizontes maiores, e apresenta maior acurácia para dados recentes fora da amostra.

Palavras-chave: Software R, Machine Learning, Aprendizado de Máquina, Séries Temporais, SARIMAX, GBM, XGBOOST, ETS, Previsão, INPC.

Lista de Tabelas

1	Valores de RMSE para Diferentes Modelos (Horizontes 1-20, Dados Recentes).	21
2	Valores de RMSE para Diferentes Modelos (Horizontes 21-39, Dados Recentes).	22
3	Variação Percentual: Real vs. Previsões (Out/24 - Mai/25).	24
4	MAE da Variação Percentual: Real vs. Previsões (Out/24 - Mai/25). . . .	24
5	INPC Percentual Acumulado no ano de 2025.	24
6	Banco de dados variáveis.	27
7	Banco de dados variáveis	28

Lista de Figuras

1	Série Histórica do INPC (Janeiro/2011 a Maio/2025)	16
2	Variação Percentual do INPC (Janeiro/2011 a Maio/2025)	17
3	Exemplo de validação por técnica de janela deslizante	19
4	Comparação do RMSE para horizontes de previsão	21
5	Gráfico dos valores previstos e INPC real	23

Sumário

1 Introdução	8
2 Modelos Preditivos	10
2.1 SARIMAX	10
2.2 ETS	11
2.3 GBM	12
2.4 XGBoost	13
2.5 Medidas de comparação de modelos	14
2.5.1 AIC	14
2.5.2 MAE	14
2.5.3 RMSE	14
2.6 Redução de dimensionalidade via LASSO	15
3 Detalhes de Implementação	16
3.1 Conjunto de dados	16
3.2 Seleção de modelos	18
3.3 Validação cruzada	18
4 Resultados	20
4.1 Análise de desempenho via validação por janela deslizante	20
4.2 Análise comparativa fora da amostra com dados observados (outubro de 2024 a maio de 2025)	22
5 Conclusão	25
Referências	26
Apêndice	27

1 Introdução

A inflação é caracterizada pelo aumento generalizado dos preços de bens e serviços na economia, sendo mensurada por índices de preços, como o Índice Nacional de Preços ao Consumidor Amplo (IPCA) e o Índice Nacional de Preços ao Consumidor (INPC), ambos utilizados pelo governo federal. As consequências da inflação incluem a redução do poder de compra, a diminuição do rendimento real de investimentos, a incerteza econômica e a possível alteração da taxa de juros por parte do Banco Central.

O INPC, conforme detalhado em IBGE (2016), é uma ferramenta crucial para compreender a saúde econômica do país, analisando o poder de compra da população assalariada que recebe entre um e cinco salários mínimos. O cálculo do índice é realizado a cada 30 dias, em quatro subperíodos de sete dias, avaliando a variação dos preços de diversas mercadorias pesquisadas em todo o território nacional. Isso é feito por meio da Pesquisa de Locais de Compra e da coleta específica de preços para itens não abrangidos por essa pesquisa. Para obter o índice nacional, é calculada a média aritmética ponderada pela população residente urbana do INPC de cidades como Rio Branco, São Luís, Aracaju, Campo Grande, Goiânia, Brasília, Belém, Fortaleza, Recife, Salvador, Belo Horizonte, Grande Vitória, Rio de Janeiro, São Paulo, Curitiba e Porto Alegre. A data de início da medição do INPC é dezembro de 1993.

A previsão de índices de preços utilizando técnicas de séries temporais é um tema amplamente estudado na academia. Por exemplo, o trabalho de Chan (2009) emprega modelos de séries temporais para prever o IPCA e, ao combinar os resultados de forma simples ou ponderada, obtém um modelo altamente preciso para previsões fora da amostra. O uso de técnicas de aprendizado de máquina é explorado por Silva et al. (2023), que aplicam diversas abordagens, focando na experimentação de diferentes formas de pré-processamento dos dados para o treinamento dos modelos de previsão. Chu e Qureshi (2023) investigam a variação do PIB dos Estados Unidos utilizando múltiplos modelos de aprendizado de máquina com dados de alta e baixa frequência, concluindo que, para cada horizonte de previsão, um modelo específico apresenta resultados superiores.

Este trabalho busca identificar as ferramentas de previsão mais eficazes para o comportamento do INPC, considerando os fatores de variação observados na economia nacional e internacional. A compreensão do comportamento desse índice pode otimizar a gestão financeira de governos, empresas e indivíduos, além de subsidiar a formulação de políticas públicas de apoio econômico, reajustes salariais e benefícios previdenciários. Para a previsão do INPC, serão empregados métodos de séries temporais, como o modelo

de espaço de estado de suavização exponencial (ETS) (HYNDMAN et al., 2002; HYNDMAN et al., 2008) e o modelo sazonal autorregressivo integrado de médias móveis com termos exógenos (SARIMAX) (VAGROPOULOS et al., 2016), além de técnicas de aprendizado de máquina, incluindo o modelo de regressão impulsionada generalizada (GBM) (FRIEDMAN, 2001; FRIEDMAN, 2002) e o boosting de gradiente extremo (XGBOOST) (CHEN; GUESTRIN, 2016).

O restante do trabalho é organizado da seguinte forma. O Capítulo 2, “Modelos Preditivos” , apresenta as metodologias de previsão que serão utilizadas, incluindo SARIMAX, ETS, GBM, XGBoost e medidas de comparação de modelos. No Capítulo 3, “Detalhes de Implementação” , o conjunto de dados, a seleção dos modelos e a validação são discutidos. No Capítulo 4, “Resultados”, os resultados das previsões são apresentados e discutidos. Por fim, no Capítulo 5, “Conclusão”, as conclusões gerais sobre o trabalho são apresentadas.

2 Modelos Preditivos

Este capítulo apresenta as metodologias de previsão empregadas no estudo para prever o INPC. Serão detalhados tanto os modelos tradicionais de séries temporais, como o SARIMAX e o ETS, quanto as técnicas de aprendizado de máquina, incluindo GBM e XGBoost. Adicionalmente, serão descritas as métricas utilizadas para a comparação e avaliação do desempenho preditivo de cada abordagem. Por fim, a técnica de redução de dimensionalidade LASSO (operador de seleção e encolhimento absoluto mínimo) será apresentada. Essa técnica é útil para escolher previamente covariáveis relevantes nos modelos SARIMAX, GBM e XGBoost.

2.1 SARIMAX

O modelo Autorregressivo Integrado de Médias Móveis com Sazonalidade (SARIMA) é uma generalização do modelo ARIMA, amplamente utilizado na modelagem de séries temporais univariadas. A principal diferença entre os dois está na capacidade do SARIMA de capturar padrões sazonais por meio da inclusão de operadores e polinômios específicos.

O modelo ARIMA(p, d, q) é definido pela equação:

$$\Phi_p(L)(1 - L)^d y_t = \Theta_q(L)\varepsilon_t, \quad (2.1.1)$$

em que y_t representa a série temporal observada no instante t ; L é o operador defasagem, tal que $L^k y_t = y_{t-k}$; o operador $(1 - L)^d$ realiza a diferenciação não sazonal de ordem d , aplicada para tornar a série estacionária; $\Phi_p(L) = 1 - \phi_1 L - \dots - \phi_p L^p$ é o polinômio autorregressivo de ordem p ; $\Theta_q(L) = 1 + \theta_1 L + \dots + \theta_q L^q$ é o polinômio de médias móveis de ordem q ; e ε_t é o termo de erro aleatório (ruído branco), assumido como um processo estocástico com média zero, variância constante e ausência de autocorrelação serial.

A versão sazonal do ARIMA, conhecida como SARIMA(p, d, q)(P, D, Q) $_s$, incorpora componentes adicionais capazes de capturar a estrutura periódica da série. O modelo é descrito pela equação:

$$\phi_p(L)\Phi_P(L^s)(1 - L)^d(1 - L^s)^D y_t = \theta_q(L)\Theta_Q(L^s)\varepsilon_t, \quad (2.1.2)$$

em que s denota a periodicidade sazonal (por exemplo, $s = 12$ para séries mensais); $\phi_p(L)$ e $\theta_q(L)$ correspondem aos polinômios autorregressivo e de médias móveis de ordens p e q ,

respectivamente, já definidos na estrutura ARIMA; $\Phi_P(L^s) = 1 - \Phi_1 L^s - \dots - \Phi_P L^{Ps}$ é o polinômio autorregressivo sazonal de ordem P , construído com defasagens múltiplas de s ; $\Theta_Q(L^s) = 1 + \Theta_1 L^s + \dots + \Theta_Q L^{Qs}$ é o polinômio de médias móveis sazonais de ordem Q ; o operador $(1 - L^s)^D$ realiza a diferenciação sazonal de ordem D , cuja aplicação conjunta com $(1 - L)^d$ assegura a estacionariedade da série processada.

Para incorporar o efeito de variáveis exógenas definido por Hyndman e Athanasopoulos (2018), utiliza-se o modelo *SARIMAX* como uma regressão múltipla com o termo de erro ϵ_t substituído por η_t , o qual representa o processo SARIMA. Este modelo é formulado como:

$$y_t = \beta_0 + \beta_1 x_{1,t} + \dots + \beta_k x_{k,t} + \eta_t, \quad (2.1.3)$$

em que $x_{k,t}$ são os regressores atuais no tempo t e podem ser os regressores com defasagens caso a variável x_t influencie y_t não apenas no tempo t , mas também no tempo $t - 1$ ou $t - 2$ por exemplo. O modelo SARIMAX, portanto, integra a estrutura dinâmica da série temporal com os efeitos explicativos de variáveis externas.

2.2 ETS

Os modelos de espaço de estado desenvolvidos em Hyndman et al. (2002) e Hyndman et al. (2008) descrevem as características do erro, tendência e sazonalidade (ETS). Esta técnica permite uma evolução em relação aos métodos de alisamento exponencial que geram previsões pontuais sobre a série temporal, e com os modelos de espaço de estado é possível calcular também intervalos de predição. Os modelos ETS apresentam variações para lidar com erro, tendência e sazonalidade. O erro pode ser utilizado aditivo ou multiplicativo. Quanto à tendência, o modelo pode não utilizar tendência, ou então ela pode ser aditiva, ou aditiva amortecida. No caso da sazonalidade, ela pode estar ausente, aditiva, ou multiplicativa.

A estrutura geral de um modelo ETS pode ser representada por:

$$y_t = h(x_{t-1}) + k(x_{t-1})\varepsilon_t, \quad (2.2.1)$$

$$x_t = f(x_{t-1}) + g(x_{t-1})\varepsilon_t, \quad (2.2.2)$$

em que y_t é a variável observada no tempo t ; x_t é o vetor de estados latentes composto pelos componentes $x_t = (l_t, b_t, s_t, s_{t-1}, \dots, s_{t-(m-1)})$, correspondendo ao nível, tendência e sazonalidade da série; ε_t representa um termo de erro com média zero e variância constante; $\mu_t = h(x_{t-1})$ é a média condicional da série; e $e_t = k(x_{t-1})\varepsilon_t$ representa o ruído

observado. Assim, a equação do modelo pode ser escrita como $y_t = \mu_t + e_t$.

2.3 GBM

O método Gradient Boosting Machine (GBM) (FRIEDMAN, 2001; FRIEDMAN, 2002), fundamenta-se no princípio do boosting. Nessa abordagem, modelos fracos — algoritmos preditivos que, individualmente, têm um desempenho apenas ligeiramente superior ao de uma suposição aleatória, como árvores de decisão rasas — são combinados sequencialmente para construir um modelo preditivo robusto. A cada iteração, um novo modelo é ajustado aos resíduos (erros) da predição anterior. Esse novo modelo é então ponderado de acordo com sua capacidade de reduzir o erro total, contribuindo para a construção gradual de um modelo final de alta precisão.

Esse método é especialmente eficaz quando são utilizadas árvores de decisão como modelos base, dada sua capacidade de tratar variáveis numéricas e categóricas, lidar com valores ausentes e capturar não linearidades. A função de perda $L(y, F(x))$ pode assumir diferentes formas, sendo o erro quadrático e o erro quadrático médio (EQM) escolhas comuns.

Seja y uma variável dependente e $\mathbf{x}$ um conjunto de covariáveis, a formulação geral do método é dada pelo Algoritmo 1. Exemplos comuns de funções perda L são erro quadrático ($L(y, F(x)) = (y - F(x))^2$) e erro absoluto ($L(y, F(x)) = |y - F(x)|$). Note que $F(\mathbf{x})$ é construído como um conjunto aditivo de M funções base, $h_m(\mathbf{x}, \mathbf{a}_m)$, tipicamente árvores de decisão. Partindo de uma estimativa inicial $F_0(\mathbf{x})$, o modelo é atualizado iterativamente segundo a regra:

$$F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + \gamma_m h_m(\mathbf{x}, \mathbf{a}_m), \quad m = 1, \dots, M.$$

A cada passo m , a função base h_m (com seus parâmetros $\mathbf{a}_m$) e seu peso γ_m são escolhidos para minimizar a função de perda $L(y, F_m(\mathbf{x}))$, ajustando o modelo na direção que mais efetivamente reduz o erro.

1. Inicialize o modelo com:

$$F_0(\mathbf{x}) = \arg \min_{\gamma} \sum_{i=1}^N L(y_i, \gamma).$$

2. Para $m = 1, \dots, M$, faça:

(a) Calcule os pseudo-resíduos:

$$r_i^{(m)} = - \left[\frac{\partial L(y_i, F(\mathbf{x}_i))}{\partial F(\mathbf{x}_i)} \right]_{F(\mathbf{x})=F_{m-1}(\mathbf{x})}, \quad i = 1, \dots, N.$$

(b) Ajuste a função aprendiz base $h_m(\mathbf{x}; \mathbf{a}_m)$ aos resíduos:

$$\mathbf{a}_m = \arg \min_{\mathbf{a}, \beta} \sum_{i=1}^N \left(r_i^{(m)} - \beta h(\mathbf{x}_i; \mathbf{a}) \right)^2.$$

(c) Determine a taxa de aprendizado γ_m :

$$\gamma_m = \arg \min_{\gamma} \sum_{i=1}^N L(y_i, F_{m-1}(\mathbf{x}_i) + \gamma h_m(\mathbf{x}_i; \mathbf{a}_m)).$$

(d) Atualize o modelo:

$$F_m(\mathbf{x}) = F_{m-1}(\mathbf{x}) + \gamma_m h_m(\mathbf{x}; \mathbf{a}_m).$$

3. Retorne o modelo final $F_M(\mathbf{x})$.

2.4 XGBoost

O algoritmo XGBoost, desenvolvido por Chen e Guestrin (2016), constitui uma extensão computacionalmente otimizada do GBM. Sua principal inovação está na execução paralela do treinamento de árvores e na introdução explícita de regularização, o que reduz o risco de sobreajuste.

A função de perda regularizada adotada no XGBoost é definida por:

$$L(\phi) = \sum_{i=1}^N l(y_i, \hat{y}_i) + \sum_{m=1}^M \Omega(f_m), \quad (2.4.1)$$

em que a penalização $\Omega(f)$ imposta a cada árvore f é dada por:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2, \quad (2.4.2)$$

sendo T o número de folhas da árvore, γ o parâmetro de penalização pela complexidade da estrutura e λ o coeficiente de regularização L2, o qual adiciona o quadrado do valor dos coeficientes à função de perda como penalidade. Essa formulação controla a profundidade das árvores e favorece soluções mais parcimoniosas.

2.5 Medidas de comparação de modelos

A comparação entre modelos preditivos pode ser realizada com base em critérios de informação e métricas de erro – como Critério de Informação de Akaike (AIC), Erro Absoluto Médio (MAE), e Raiz do Erro Quadrático Médio (RMSE) – os quais avaliam tanto a qualidade do ajuste quanto a capacidade preditiva do modelo.

2.5.1 AIC

O AIC, proposto por Akaike (1998), combina o grau de ajuste com a penalização pela complexidade do modelo. Sua fórmula é dada por:

$$AIC = 2k - 2\ln(\hat{L}), \quad (2.5.1)$$

em que k representa o número de parâmetros estimados e $\hat{L}$ é o valor da função de verossimilhança no ponto de máxima verossimilhança. Modelos com menor AIC são preferíveis, desde que a diferença seja substancial.

2.5.2 MAE

O MAE corresponde à média dos valores absolutos dos erros entre as observações reais y_i e as previsões $\hat{y}_i$, sendo definido por:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (2.5.2)$$

Essa métrica é menos sensível a grandes desvios em comparação ao erro quadrático médio.

2.5.3 RMSE

O RMSE é obtida a partir da raiz quadrada da média dos erros ao quadrado:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (2.5.3)$$

Essa métrica penaliza mais fortemente grandes erros e é amplamente utilizada em avaliação de modelos preditivos.

2.6 Redução de dimensionalidade via LASSO

A regressão LASSO, introduzida por Tibshirani (1996), é uma técnica de regressão linear que impõe uma penalização L1, a qual adiciona o valor absoluto dos coeficientes à função de custo como penalidade. Promovendo a seleção automática de variáveis e, consequentemente, a redução da dimensionalidade do modelo.

O critério de minimização adotado é:

$$\min_{\beta} \left(\sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2 + \lambda \sum_{j=1}^p |\beta_j| \right), \quad (2.6.1)$$

em que y_i representa a variável dependente para a i -ésima observação; x_{ij} representa o valor da j -ésima covariável na i -ésima observação; β_j são os coeficientes de regressão a serem estimados; e λ é o parâmetro de penalização que controla a magnitude da regularização. Valores maiores de λ forçam mais coeficientes a zero, resultando em um modelo mais parcimonioso.

3 Detalhes de Implementação

Neste capítulo, são descritos os procedimentos práticos e metodológicos adotados para a construção e avaliação dos modelos de previsão do INPC. O detalhamento abrange a composição do conjunto de dados, as estratégias para a seleção e ajuste de cada modelo, e o método de validação empregado para comparar o desempenho preditivo das diferentes abordagens. O código utilizado para implementação das técnicas e modelos utilizados neste trabalho está disponível no link da seção de apêndice.

3.1 Conjunto de dados

A análise utiliza um conjunto de dados com 165 observações para cada variável, abrangendo o período de janeiro de 2011 a setembro de 2024, o comportamento do INPC pode ser visualizado na Figura 1 e Figura 2. Para o tratamento das séries, foram aplicadas as primeiras diferenças a fim de torná-las estacionárias. Adicionalmente, as variáveis foram sazonalmente ajustadas, quando necessário, utilizando o método X-13ARIMA-SEATS (SAX; EDDELBUETTEL, 2018). O horizonte de previsão foi definido em $H=39$ passos.

Figura 1: Série Histórica do INPC (Janeiro/2011 a Maio/2025)





Figura 2: Variação Percentual do INPC (Janeiro/2011 a Maio/2025)



O conjunto de dados utilizado para fazer as previsões consiste na série temporal do INPC e também dados econômicos (utilizados como covariáveis) nacionais de diversas fontes: ABRAS (Associação Brasileira de Supermercados), ANBIMA (Associação Brasileira das Entidades dos Mercados Financeiro e de Capitais), BACEN (Banco Central do Brasil), CNC (Confederação Nacional do Comércio), CNI (Confederação Nacional da Indústria, CONAB (Companhia Nacional de Abastecimento), Eletrobras, FGV (Fundação Getúlio Vargas), FECOMERCIO-SP (Federação do Comércio de Bens, Serviços e Turismo de São Paulo), FIPE (Fundação Instituto de Pesquisas Econômicas), IBGE (Instituto Brasileiro de Geografia e Estatística), IPEA (Instituto de Pesquisa Econômica Aplicada), ONS (Operador Nacional do Sistema Elétrico) e SEAB (Secretaria da Agricultura e do Abastecimento).

Para exemplificar, algumas covariáveis presentes no conjunto de dados são:

- ANBIMA: Taxa de juros pré-fixada - estrutura a termo
- BACEN: Balanço de pagamentos - balança comercial exportações
- BACEN: Taxa de câmbio - R\$/US\$ - Comercial - Compra - Média
- CNC: Intenção de Consumo das famílias - Abaixo de 10 salários mínimos
- IPEA: Salário Mínimo Real

A descrição de todas 123 covariáveis utilizadas está disponível no Apêndice.

3.2 Seleção de modelos

As covariáveis utilizadas (ver Apêndice) para os modelos SARIMAX, GBM e XGBoost foram escolhidas segundo a regularização LASSO com λ de 1.422, reduzindo assim a dimensionalidade.

Para encontrar o melhor modelo da técnica de previsão SARIMAX, utilizou-se a função *auto.arima* do software R, que testa diversos modelos da família ARIMA e os ranqueia de acordo com o critério de Akaike. Foram selecionados quais modelos SARIMA mais se adequam à série histórica do INPC segundo o critério de Akaike. A partir desta informação, os 5 modelos com menor AIC foram selecionados. Posteriormente, foram treinados modelos SARIMAX, incorporando a informação das covariáveis exógenas ao processo de modelagem.

Para selecionar o modelo ETS que melhor se adequasse aos dados históricos do INPC, foi utilizada a função *ets* do software R, a qual testa todas as variações para as componentes de erro, tendência e sazonalidade e seleciona o melhor baseado no AIC.

Para a seleção do melhor modelo da técnica GBM e XGBoost, ocorreu o processo de validação cruzada com ajuste (tuning) de hiperparâmetros. Os parâmetros otimizados incluíram o número de árvores de regressão, a profundidade máxima das árvores, o número mínimo de observações por nó e a taxa de aprendizado (learning rate).

O código de desenvolvimento do estudo está disponível em: <https://github.com/NogJoaoEstudos/Previsao-INPC>


3.3 Validação cruzada

O método de validação dos resultados de cada modelo selecionado para a previsão da série temporal do INPC foi a validação por técnica de janela deslizante, com exemplo na Figura 3. Este método consiste em dividir o conjunto de dados da série temporal em diversas janelas de treino e teste.

Cada iteração inicia com o treinamento do modelo com o número estipulado de observações de treino e a previsão é feita para o número de horizontes de previsão (“H” meses à frente). O erro da previsão será calculado de acordo com o dado real observado. Nas iterações subsequentes, a janela se desloca “H” observações para frente e repete o processo até todo o banco de dados ser esgotado, ao fim é calculada a média dos erros das previsões para “H” estipulado.

É possível visualizar o processo de validação por técnica de janela deslizante com a imagem abaixo:

Figura 3: Exemplo de validação por técnica de janela deslizante.



4 Resultados

Neste capítulo, são apresentados e analisados os resultados obtidos a partir dos quatro modelos de previsão: ETS, XGBoost, GBM e SARIMAX. A avaliação da performance é dividida em duas etapas:

- primeiro, uma análise de janeiro de 2011 a setembro de 2024 baseada na métrica RMSE, obtida através da validação por janela deslizante, é realizada;
- segundo, uma comparação direta das previsões com valores reais fora da amostra (outubro de 2024 a maio de 2025) do INPC é realizada utilizando o MAE.

4.1 Análise de desempenho via validação por janela deslizante

Os dados de treino na primeira iteração da janela deslizante vão até Julho/2020 (70% dos dados). As Tabelas 1 e 2 exibem os valores de RMSE para cada modelo em horizontes de previsão de 1 a 39 meses; já a Figura 4 ilustra visualmente o desempenho dos modelos. Observa-se o seguinte:

- (1-12 meses): Os modelos de aprendizado de máquina, XGBoost e GBM, demonstram uma performance superior e mais estável. Eles consistentemente apresentam os menores valores de RMSE. O erro para esses modelos varia pouco, mantendo-se em um patamar baixo, enquanto os modelos de séries temporais ETS e SARIMAX apresentam um erro significativamente maior e crescente neste período.
- (acima de 12 meses): Os modelos XGBoost e GBM mantêm sua consistência, com pouca variação no RMSE. Em contrapartida, o modelo SARIMAX exibe um comportamento notável: a partir do 17º horizonte de previsão, seu RMSE inicia uma tendência de queda, tornando-se progressivamente mais acurado. No 38º horizonte, o SARIMAX alcança um RMSE de 12,52, o menor valor entre todos os modelos para horizontes longos. O modelo ETS, por outro lado, não apresenta uma melhora gradual, mantendo um erro elevado.

Tabela 1: Valores de RMSE para Diferentes Modelos (Horizontes 1-20, Dados Recentes).

Horizonte	ETS	XGBoost	GBM	Sarimax
1	19.41	12.36	12.65	19.71
2	22.86	13.73	13.47	22.74
3	25.81	13.87	14.19	24.25
4	27.41	14.06	14.62	24.48
5	28.18	14.07	14.68	24.52
6	27.85	14.13	14.89	24.62
7	26.97	14.22	15.13	24.14
8	25.52	14.2	15.45	24.49
9	24.63	14.25	15.77	23.92
10	24.72	14.14	15.67	24.25
11	25.5	14.21	15.59	24.29
12	26.39	14.17	15.58	24.09
13	27.89	14.16	15.52	24.32
14	28.53	14.2	15.49	24.46
15	29.36	14.2	15.46	24.62
16	30.53	14.22	15.44	25.9
17	31.18	14.32	15.41	27.24
18	31.66	14.32	15.43	27.15
19	32.74	14.39	15.51	25.34
20	32.61	14.46	15.62	22.95

Comparação do RMSE por Horizonte de Previsão




Figura 4: Comparação do RMSE para horizontes de previsão.

Tabela 2: Valores de RMSE para Diferentes Modelos (Horizontes 21-39, Dados Recentes).

Horizonte	ETS	XGBoost	GBM	Sarimax
21	32.47	14.49	15.73	23.14
22	32.25	14.54	15.77	20.4
23	31.33	14.51	15.79	21.93
24	30.58	14.55	15.75	21.96
25	29.98	14.57	15.72	21.72
26	29.5	14.56	15.63	21.75
27	29.67	14.58	15.66	21.44
28	30.26	14.56	15.66	22.33
29	31.08	14.59	15.67	20.11
30	31.79	14.62	15.74	19.46
31	32.18	14.58	15.65	17.42
32	31.89	14.54	15.58	17.46
33	31.6	14.48	15.57	15.11
34	31.07	14.48	15.57	14.62
35	29.6	14.42	15.56	14.93
36	29.14	14.42	15.54	14.1
37	28.82	14.48	15.54	13.46
38	28.78	14.46	15.6	12.52
39	29.74	14.46	15.65	15.37

4.2 Análise comparativa fora da amostra com dados observados (outubro de 2024 a maio de 2025)

Embora a validação por janela deslizante ofereça uma medida adequada da performance média dos modelos, é importante avaliar o desempenho dos modelos com dados recentes e fora da amostra inicial dos dados. Nesse contexto, as covariáveis são previstas para o horizonte outubro de 2024 a maio de 2025, com seleção via validação cruzada dos modelos SARIMA e ETS.

A Figura 5 e as Tabelas 3, 4 e 5 comparam as previsões com os valores reais observados entre outubro de 2024 e maio de 2025. Ao avaliar o MAE da variação percentual mensal, o modelo SARIMAX se destacou com o menor erro (0,259), seguido de perto pelo XGBOOST (0,265). Este resultado indica que, para este período específico de curto prazo, a técnica SARIMAX foi a mais precisa.

A superioridade do SARIMAX em cenários recentes é confirmada pela Tabela 5. A previsão do INPC acumulado para 2025 do modelo SARIMAX (2,80%) foi a que mais

se aproximou do valor real observado (3,34%), com uma diferença de apenas 0,54 pontos percentuais. Os demais modelos subestimaram significativamente a inflação acumulada, ficando em um patamar muito distante do valor real.

Em conclusão, os resultados sugerem que, embora os modelos de aprendizado de máquina ofereçam maior estabilidade e robustez na média dos cenários (validação por janela deslizante), o modelo SARIMAX demonstrou ser a ferramenta mais precisa para previsões em dados reais recentes e em horizontes de longo prazo. A escolha da melhor ferramenta depende, portanto, do horizonte de previsão desejado e das características do período histórico analisado.




Figura 5: Gráfico dos valores previstos e INPC real.

Tabela 3: Variação Percentual: Real vs. Previsões (Out/24 - Mai/25).

Mês/Ano	Real %	ETS %	XGBoost %	GBM %	SARIMAX %
Out/24	0.61	0.3	0.35	0.34	0.45
Nov/24	0.33	0.3	0.42	0.55	0.51
Dez/24	0.48	0.3	0.39	0.33	0.58
Jan/25	0.0	0.3	0.29	0.28	0.53
Fev/25	1.48	0.3	0.33	0.31	0.47
Mar/25	0.51	0.3	0.29	0.27	0.41
Abr/25	0.48	0.3	0.28	0.3	0.38
Mai/25	0.35	0.3	0.29	0.29	0.40

Tabela 4: MAE da Variação Percentual: Real vs. Previsões (Out/24 - Mai/25).

Modelo	MAE
ETS	0.266
XGBOOST	0.265
GBM	0.288
SARIMAX	0.259

Tabela 5: INPC Percentual Acumulado no ano de 2025.

INPC %	ETS %	XGBoost %	GBM %	SARIMAX %
3.34	1.81	1.85	1.79	2.80

5 Conclusão

Com base nos resultados, o estudo conclui que os modelos de aprendizado de máquina, XGBoost e GBM, mostraram maior estabilidade de erro (RMSE) durante todos horizontes de previsão na validação por janela deslizante. Em contrapartida, a técnica tradicional SARIMAX, apesar de um erro inicial maior, tende progressivamente a ficar mais acurada para horizontes de 17 meses em diante. Na comparação com dados reais recentes (outubro de 2024 a maio de 2025), o SARIMAX demonstrou ser o modelo mais acurado, apresentando o menor Erro Médio Absoluto (MAE) e a previsão de inflação acumulada mais próxima do valor observado. A escolha da melhor ferramenta de previsão, portanto, depende do horizonte temporal, com o SARIMAX se mostrando o mais preciso para os dados recentes fora da amostra. Em trabalhos futuros, é possível comparar as técnicas presentes no trabalho com redes neurais LSTM, modelos Transformers e diferentes abordagens de pré-processamento dos dados.

Referências

- AKAIKE, H. Information theory and an extension of the maximum likelihood principle. In: *Selected papers of hirotugu akaike*. [S.l.]: Springer, 1998. p. 199–213.
- CHAN, M. *Modelos de previsão de inflação e estudo da dinâmica inflacionária brasileira*. Tese (Doutorado), 2009.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. [S.l.]: ACM, 2016. p. 785–794.
- CHU, B.; QURESHI, S. Comparing Out-of-Sample Performance of Machine Learning Methods to Forecast U.S. GDP Growth. *Computational Economics*, v. 62, n. 4, p. 1567–1609, December 2023. Disponível em: https://ideas.repec.org/a/kap/compec/v62y2023i4d10.1007_s10614-022-10312-z.html.
- FRIEDMAN, J. H. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, Institute of Mathematical Statistics, v. 29, n. 5, p. 1189 – 1232, 2001. Disponível em: <https://doi.org/10.1214/aos/1013203451>.
- FRIEDMAN, J. H. Stochastic gradient boosting. *Computational Statistics & Data Analysis*, v. 38, n. 4, p. 367–378, 2002. ISSN 0167-9473. Nonlinear Methods and Data Mining. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0167947301000652>.
- HYNDMAN, R. et al. Forecasting with exponential smoothing. the state space approach. In: _____. [S.l.: s.n.], 2008.
- HYNDMAN, R. et al. A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of Forecasting*, v. 18, p. 439–454, 02 2002.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. [S.l.]: OTexts, 2018.
- IBGE. *Para compreender o INPC: um texto simplificado*. 7. ed. Rio de Janeiro: IBGE, 2016. 59 p. ISBN 9788524043796.
- SAX, C.; EDDERBUETTEL, D. Seasonal adjustment by x-13arima-seats in r. *Journal of Statistical Software*, v. 87, n. 11, p. 1–17, 2018. Disponível em: <https://doi.org/10.18637/jss.v087.i11>.
- SILVA, M. M. C. d. O. et al. Previsão da inflação no brasil utilizando abordagem desagregada e aprendizado de máquina. Inspier, 2023.
- TIBSHIRANI, R. Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, Oxford University Press, v. 58, n. 1, p. 267–288, 1996.
- VAGROPOULOS, S. I. et al. Comparison of SARIMAX, SARIMA, modified SARIMA and ANN-based models for short-term PV generation forecasting. In: *2016 IEEE International Energy Conference (ENERGYCON)*. [S.l.: s.n.], 2016. p. 1–6.

Apêndice

Tabela 6: Banco de dados variáveis.

Variável	Descrição
ABRAS12_INVNR12	Consumo nos lares - variação real
ANBIMA12.TJTLN112	Taxa de juros pré fixada - estrutura a termo - LTN - 1 mês
ANBIMA12.TJTLN1212	Taxa de juros pré fixada - estrutura a termo - LTN - 12 meses
ANBIMA12.TJTLN312	Taxa de juros pré fixada - estrutura a termo - LTN - 3 meses
ANBIMA12.TJTLN612	Taxa de juros pré fixada - estrutura a termo - LTN - 6 meses
SGS12_IBCBR12	IBC-Br - índice real (2002=100)
BPAG12_BCM12	Balanco de pagamentos - balança comercial - importações
BPAG12_BCX12	Balanco de pagamentos - balança comercial - exportações
BM12_IPCAEXP1212	Expectativa média de Inflação - IPCA - taxa acumulada 12 meses
BM12_IPCAEXP612	Expectativa média de Inflação - IPCA - taxa anualizada 6 meses
BM12.ERC12	Taxa de câmbio - R\$ / US\$ - comercial - compra - média
BM12.ERCF12	Taxa de câmbio - R\$ / US\$ - comercial - compra - fim período
BM12.ERV12	Taxa de câmbio - R\$ / US\$ - comercial - venda - média
BM12.ERV12	Taxa de câmbio - R\$ / US\$ - comercial - venda - fim período
PAN12.ERV12	Taxa de câmbio nominal
BM12.TJCDI12	Taxa de juros - CDI / Over - acumulada no mês
BM12.TJLP12	Taxa de juros - TJLP
BM12.TJOVER12	Taxa de juros - Over / Selic - acumulada no mês
BM12.TJTR12	Taxa de juros - TR - primeiro dia do mês
PAN12.TJOVER12	Taxa de juros nominal - Over / Selic
BM12.DTSPY12	DSLPI - total - setor público não-financeiro
BM12.NFSPJNYS12	NFSP - setor público - juros nominais - sem desvalorização cambial - fluxo em 12 meses
BM12.NFSPNNAS12	NFSP - setor público - resultado nominal - sem desvalorização cambial - fluxo acumulado em 12 meses
BM12.NFSPNYS12	NFSP - setor público - resultado nominal - sem desvalorização cambial - fluxo acumulado em 12 meses
BM12.NFSPPNAS12	NFSP - setor público - resultado primário - sem desvalorização cambial - fluxo acumulado em 12 meses
BM12.NFSPPNYS12	NFSP - setor público - resultado primário - sem desvalorização cambial - fluxo mensal corrente
BM12.NFSPPPYS12	NFSP - setor público - resultado primário - sem desvalorização cambial - fluxo acumulado em 12 meses
BM12.CCA12	Operações de crédito - concessões - total
BM12.CCAPF12	Operações de crédito - concessões - pessoa física
BM12.CCAPJ12	Operações de crédito - concessões - pessoa jurídica
BM12.CIN12	Operações de crédito - inadimplência da carteira de crédito - total
BM12.CINPF12	Operações de crédito - inadimplência da carteira de crédito - pessoa física
BM12.CINPJ12	Operações de crédito - inadimplência da carteira de crédito - pessoa jurídica
BM12.CRDCAPF12	Operações de crédito - concessões - recursos direcionados - pessoa física
BM12.CRDCAPJ12	Operações de crédito - concessões - recursos direcionados - pessoa jurídica
BM12.CRLCAPF12	Operações de crédito - concessões de crédito - recursos livres - pessoa física
BM12.CRLCAPJ12	Operações de crédito - concessões de crédito - recursos livres - pessoa jurídica
BM12.CS12	Operações de crédito - saldo da carteira de crédito - total
BM12.CTJ12	Operações de crédito - taxa média de juros - total
BM12.CTJPF12	Operações de crédito - taxa média de juros - pessoa física
BM12.M0MN12	Base monetária restrita - M0 - média
BM12.M0N12	Base monetária restrita - M0 - fim de período
BM12.M0NY12	Base monetária restrita - M0 - fim de período
PAN12.MTV12	Balança comercial - importações (BPM6)
PAN12.XTV12	Balança comercial - exportações (BPM6)
CNC12_ICF12	Intenção de consumo das famílias - total
CNC12_ICFAB12	Intenção de consumo das famílias - Abaixo de 10 salários mínimos
CNC12_ICFAC12	Intenção de consumo das famílias - Acima de 10 salários mínimos
CNC12_IEEC12	Expectativas do empresário do comércio
CNI12_HTRAB12	Indicadores Industriais - horas trabalhadas - indústria - índice (média 2006 = 100)
CNI12_ICEICA12	Índice de Confiança do Empresário Industrial (ICEI) - condições atuais
CNI12_ICEIEXP12	Índice de Confiança do Empresário Industrial (ICEI) - expectativas
CNI12_ICEIGER12	Índice de Confiança do Empresário Industrial (ICEI) - geral
CNI12_INDE12	Sondagem Industrial - produção indústria geral - estoques - evolução - índice
CNI12_NUCAP12	Indicadores Industriais - utilização da capacidade instalada - indústria - índice (média 2006 = 100)
CNI12_PEEMP12	Indicadores Industriais - pessoal empregado - indústria - índice (média 2006 = 100)
CNI12_REMN12	Indicadores Industriais - massa salarial - indústria - índice real (média 2006 = 100)
CNI12_REMR12	Indicadores Industriais - massa salarial - real - indústria - índice (média 2006 = 100)
CNI12_RENDR12	Indicadores Industriais - rendimento médio real - indústria - índice (média 2006 = 100)
CNI12_VENREA12	Indicadores Industriais - faturamento real - indústria - índice (média 2006 = 100)
DEPAE12.ATMI12	Preço médio - atacado - milho (em grão) - 60 kg - SP
ELETR012.CEECO12	Energia elétrica - consumo - região Centro-Oeste (CO) - quantidade
ELETR012.CEECOM12	Energia elétrica - consumo - comércio - quantidade

Tabela 7: Banco de dados variáveis

Variável	Descrição
ELETRO12.CEEIND12	Energia elétrica - consumo - indústria - quantidade
ELETRO12.CEENE12	Energia elétrica - consumo - região Nordeste (NE) - quantidade
ELETRO12.CEENO12	Energia elétrica - consumo - região Norte (N) - quantidade
ELETRO12.CEEOUT12	Energia elétrica - consumo - outros setores - quantidade
ELETRO12.CEERES12	Energia elétrica - consumo - residência - quantidade
ELETRO12.CEES12	Energia elétrica - Consumo - região Sudeste (SE) - quantidade
ELETRO12.CEESU12	Energia elétrica - consumo - região Sul (S) - quantidade
ELETRO12.CEET12	Energia elétrica - consumo - quantidade
ELETRO12.CEETCOM12	Energia elétrica - consumo - comércio - tarifa média por MWh
ELETRO12.CEETIND12	Energia elétrica - consumo - indústria - tarifa média por MWh
ELETRO12.CEETRES12	Energia elétrica - consumo - residência - tarifa média por MWh
ELETRO12.CEETT12	Energia elétrica - consumo - tarifa média por MWh
CE12.CUTIND12	Utilização da capacidade instalada - indústria - média
FCESP12.IIC12	Índice de confiança do consumidor (ICC)
FCESP12.IICA12	Índice de condições econômicas atuais (ICEA)
FCESP12.IICF12	Índice de expectativas do consumidor (IEC)
FIPE12.VENBR12	Índice de Preços FipecZap - imóveis anunciados - vendas - Brasil - índice (jun. 2012 = 100)
PMC12.IVVRN12	Vendas reais - varejo - índice (média 2022 = 100)
PMC12.IVVRNAMP12	Vendas reais - varejo ampliado - índice (média 2022 = 100)
PMC12.VRCONSTN12	Vendas reais - varejo - materiais de construção - índice (média 2022 = 100)
PMC12.VRELETRN12	Vendas reais - varejo - móveis e eletrodomésticos - índice (média 2022 = 100)
PMC12.VRFARMN12	Vendas reais - varejo - artigos farmacêuticos - índice (média 2022 = 100)
PMC12.VRSUPN12	Vendas reais - varejo - hipermercados, produtos alimentícios, bebidas e fumo - índice (média 2022 = 100)
PMC12.VRSUPTN12	Vendas reais - varejo - hipermercados e supermercados - índice (média 2022 = 100)
PMC12.VRVEICN12	Vendas reais - varejo - veículos, motos, partes e peças - índice (média 2022 = 100)
PMC12.VRVESTN12	Vendas reais - varejo - tecidos, vestuário e calçados - índice (média 2022 = 100)
PNADC12.ESPUB12	Pessoas ocupadas - empregado no setor público (inclusive servidor estatutário e militar)
PNADC12.ESPUBCC12	Pessoas ocupadas - empregado no setor público com carteira assinada (inclusive servidor estatutário e militar)
PNADC12.ESPUBMIL12	Pessoas ocupadas - empregado no setor público - servidor estatutário e militar
PNADC12.ESPUBSC12	Pessoas ocupadas - empregado no setor público sem carteira assinada (inclusive servidor estatutário e militar)
PNADC12.MRTE12	Massa de rendimento real de todos os trabalhos efetivos mensais
PNADC12.MRTH12	Massa de rendimento real de todos os trabalhos habituais mensais
PNADC12.MRTE12	Massa de rendimento de todos os trabalhos efetivos mensais
PNADC12.MRTH12	Massa de rendimento de todos os trabalhos habituais mensais
PNADC12.NOCUP12	Nível da ocupação
GAC12.SALMINRE12	Salário mínimo real
GAC12.TCERXM12	Taxa de câmbio - efetiva real - IPA-DI-Origem - exportações - manufaturados - índice (média 2010 = 100)
GAC12.TCERXMINPC12	Taxa de câmbio - efetiva real - INPC - exportações - manufaturados - índice (média 2010 = 100)
GAC12.TCERXT12	Taxa de câmbio - efetiva real - IPA-DI - exportações - índice (média 2010 = 100)
GAC12.TCERXTINPC12	Taxa de câmbio - efetiva real - INPC - exportações - índice (média 2010 = 100)
PAN12.TCERXTINPC12	Taxa de câmbio - efetiva real - INPC - exportações - índice (média 2010 = 100)
PNADC12.MRTEM12	Massa de rendimento de todos os trabalhos efetivos mensais - mensalizada
PNADC12.MRTHM12	Massa de rendimento de todos os trabalhos habituais mensais - mensalizada
PNADC12.NOCUPM12	Nível da ocupação - mensalizada
ONS12.CONV12	Energia elétrica - geração - térmica convencional - quantidade
ONS12.HIDR12	Energia elétrica - geração - hidráulica - quantidade
DERAL12.ATARPO12	Preço médio - atacado - arroz (polido tipo 1) - 30 kg - PR
DERAL12.ATBCAD12	Preço médio - atacado - bovinos - carcaça dianteira - kg - PR
DERAL12.ATBCAT12	Preço médio - atacado - bovinos - carcaça traseira - kg - PR
DERAL12.ATFEC12	Preço médio - atacado - feijão de cor - 30 kg - PR
DERAL12.ATFEP12	Preço médio - atacado - feijão preto - 30 kg - PR
DERAL12.ATFRR12	Preço médio - atacado - frango resfriado - kg - PR
DERAL12.ATFSO12	Preço médio - atacado - soja (em farelo) - tonelada - PR
DERAL12.ATFTRC12	Preço médio - atacado - farinha de trigo - 25 kg - PR
DERAL12.ATMC12	Preço médio - atacado - milho - 60 kg - PR
DERAL12.ATOLR12	Preço médio - atacado - óleo de soja - refinado - 20 latas - PR
DERAL12.ATOVE12	Preço médio - atacado - ovo extra tipo 1 - 30 dúzias - PR
DERAL12.ATOVG12	Preço médio - atacado - ovo grande tipo 2 - 30 dúzias - PR
DERAL12.ATOVMI12	Preço médio - atacado - ovo médio tipo 3 - 30 dúzias - PR
DERAL12.ATSCAR12	Preço médio - atacado - suínos - de raça - carcaça - kg - PR