

## Modelagem probabilística do índice $IPCA_{12}$

Luciano Gonçalves Batista<sup>1</sup>, Samantha Gowêa Oliveira<sup>1</sup>, Eduardo Campana Barbosa<sup>1†</sup>, Paulo César Emiliano<sup>1</sup>, Maurício Silva Lacerda<sup>1</sup>, Kamila Andrade de Oliveira<sup>2</sup>

<sup>1</sup> Programa de Estatística Aplicada e Biometria - Departamento de Estatística (DET/UFV).

<sup>2</sup> Departamento de Engenharia Agrícola, Campus Chapadinha (DEA/UFMA).

**Resumo:** O objetivo desse trabalho foi ajustar uma distribuição aos dados de  $IPCA_{12}$  e estimar a probabilidade deste índice permanecer dentro dos limites de confiança estabelecidos pelo Banco Central do Brasil para o ano de 2024, que são de  $3\% \pm 1,5\%$ . Para escolher entre as distribuições log-normal, gama e Weibull foram analisados o teste de Kolmogorov-Smirnov e o Critério de Informação de Akaike (AIC). O modelo gama com parâmetros  $\hat{\alpha} \approx 5,81$  e  $\hat{\beta} \approx 1,09$  foi selecionado e com ele estimou-se que a probabilidade do verdadeiro valor do IPCA permanecer dentro do intervalo de confiança estabelecido pelo BC para o ano 2024 seria de 25,45%. Adicionalmente, mantendo-se fixa a margem de  $\pm 1,5\%$ , foi possível concluir que o valor ou a meta do IPCA que maximizaria a cobertura do intervalo deveria ser de 5,4% ao invés de 3%. Mais especificamente:  $P(5,4\% - 1,5\% \leq IPCA_{12} \leq 5,4\% + 1,5\%) = 45,94\%$ .

**Palavras-chave:** Assimetria; curtose; máxima verossimilhança.

## Probabilistic modeling of the $IPCA_{12}$ index

**Abstract:** The objective of this work was to fit a distribution to the  $IPCA_{12}$  dataset and estimate the probability of this index remaining within the confidence limits established by the Central Bank of Brazil for year 2024, which are  $3\% \pm 1.5\%$ . To choose between the log-normal, Gamma, and Weibull distributions, Kolmogorov-Smirnov test, and the Akaike Information Criterion (AIC) were analyzed. The Gamma model with parameters  $\hat{\alpha} \approx 5.81$  and  $\hat{\beta} \approx 1.09$  was selected, and it was estimated that the probability of the true value of IPCA staying within the confidence interval established by the Central Bank for the year 2024 would be 25.45%. Furthermore, maintaining a margin of  $\pm 1.5\%$ , it was possible to conclude that the IPCA value or target that would maximize coverage of the range should be 5.4% instead of 3%. More specifically:  $P(5.4\% - 1.5\% \leq IPCA_{12} \leq 5.4\% + 1.5\%) = 45.94\%$ .

**Keywords:** Asymmetry; kurtosis; maximum likelihood.

## Introdução

O Índice Nacional de Preços ao Consumidor Amplo, ou IPCA, produzido pelo IBGE (Instituto Brasileiro de Geografia e Estatística), desempenha um importante papel na economia brasileira, que é o de medir, oficialmente, a inflação no país (Ferreira e Figueiredo, 2002). Em particular, o  $IPCA_{12}$  informa a inflação ou a variação percentual acumulada nos preços de uma ampla cesta de produtos e serviços ofertados no Brasil ao longo dos últimos 12 meses. O acompanhamento desse índice fornece, além de uma visão abrangente da tendência inflacionária no país, uma ideia do impacto direto da inflação na renda e no poder de compra dos cidadãos brasileiros (Barros e Neri, 1996).

Para tentar minimizar os efeitos da inflação sob a economia do país, o que o governo faz, via Banco Central (BC), é estabelecer metas e limites de confiança para esse índice. Em geral, através da intervenção do BC nos valores da taxa de juros da economia brasileira (ou taxa SELIC) a inflação vai sendo controlada e o que se espera é que o verdadeiro valor do  $IPCA_{12}$  fique dentro do intervalo estipulado (Delfim Netto, 1999; Ferreira e Petrassi, 2002). Por exemplo, para o ano de 2024, a previsão do BC para a inflação é a de que ela fique entre  $3\% \pm 1,5\%$ , ou seja, entre 1,5% e 4,5%. Com o intuito de atingir esse objetivo, já no ano de 2023 os cortes da taxa SELIC

<sup>†</sup> Autor correspondente: [eduardo.barbosa@ufv.br](mailto:eduardo.barbosa@ufv.br).

começaram a ocorrer, sendo o primeiro deles realizado em agosto, de 13,75% para 13,25%, e o segundo em setembro, de 13,25% para 12,75%.

Neste sentido, o presente trabalho visa ajustar um modelo ou uma distribuição aos dados históricos de  $IPCA_{12}$  e estimar a probabilidade do verdadeiro valor desse índice permanecer dentro dos limites de confiança estabelecidos pelo Banco Central do Brasil para 2024, que é de  $3\% \pm 1,5\%$ . Com os resultados obtidos será possível avaliar se as previsões do Banco Central são, ou não, prováveis/factíveis sob o ponto de vista probabilístico.

## Referencial teórico

### Coeficiente de assimetria

O terceiro momento em relação à média,  $\mu_3 = E[X - E(X)]^3$ , é denominado como medida de assimetria ou simplesmente assimetria (Mood et al, 1974). O conhecimento do terceiro momento ajuda-nos a obter uma pista ou, uma ideia, sobre a natureza ou a forma da distribuição de probabilidade dos dados. As distribuições simétricas possuem  $\mu_3 = 0$ , enquanto uma distribuição não simétrica pode ter o terceiro momento não nulo. Mais especificamente, uma distribuição com assimetria a esquerda terá o terceiro momento em torno da média negativo; já uma distribuição assimétrica a direita terá o terceiro momento em relação à média positivo. A razão  $\gamma_1 = \frac{\mu_3}{\sigma^3}$  é adimensional e conhecida como coeficiente de assimetria. Um estimador para esse coeficiente é definido como:

$$\hat{\gamma}_1 = \frac{\hat{\mu}^3}{\hat{\sigma}^3} \quad \text{em que} \quad \hat{\mu}^3 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^3 \quad \text{e} \quad \hat{\sigma}^3 = \left[ \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \right]^{\frac{3}{2}}.$$

### Coeficiente de curtose

O quarto momento em relação à média,  $\mu_4 = E[X - E(X)]^4$ , é utilizado para expressar o excesso de curtose dos dados ou, em outras palavras, o peso das caudas de uma distribuição. A padronização mais comum indica que a curtose de uma distribuição normal seja igual a três e, conseqüentemente, o excesso de curtose igual a zero. Portanto, o coeficiente de curtose pode ser definido como  $\gamma_2 = \frac{\mu_4}{\sigma^4}$  ou  $\gamma_3 = \frac{\mu_4}{\sigma^4} - 3$ . Nesse trabalho adotamos a primeira opção, que é como o *software* livre R (R, 2023), no pacote *moments*, estima o valor desse coeficiente. Quanto a interpretação do coeficiente de curtose podemos concluir que uma distribuição será:

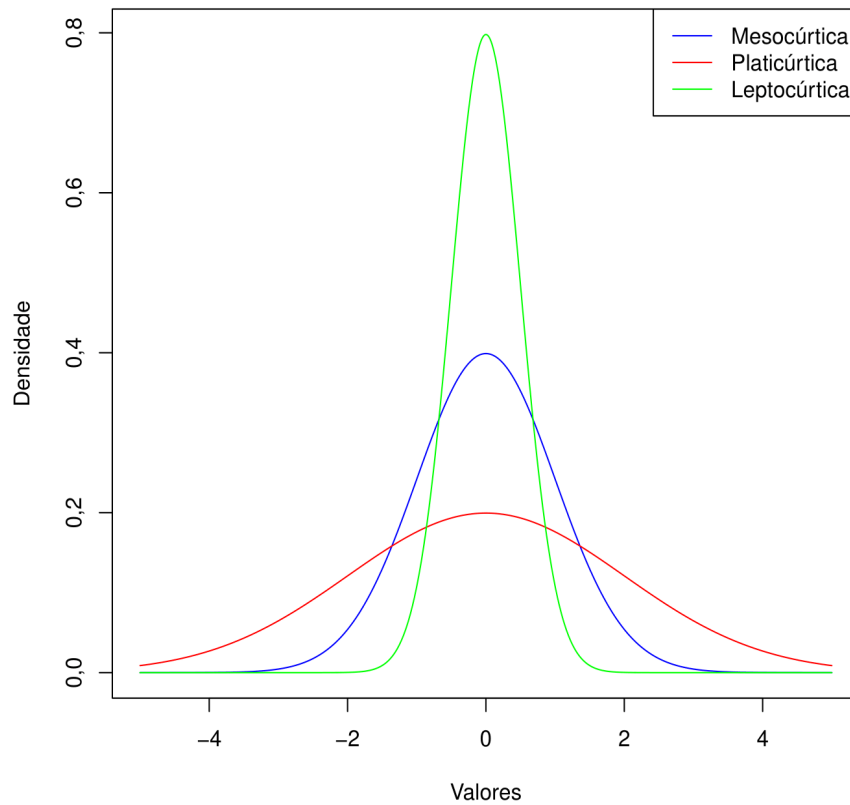
- i) Platicúrtica ( $\gamma_2 < 3$ ): Distribuição com caudas mais leves e um pico mais achatado em relação à distribuição normal;
- ii) Mesocúrtica ( $\gamma_2 \approx 3$ ): Distribuição com caudas e pico semelhantes ao da distribuição normal;
- iii) Leptocúrtica ( $\gamma_2 > 3$ ): Distribuição com caudas mais pesadas e um pico mais alto e fino em relação à distribuição normal.

Uma forma de estimar o coeficiente de curtose é apresentada a seguir:

$$\hat{\gamma}_2 = \frac{\hat{\mu}^4}{\hat{\sigma}^4} \quad \text{em que} \quad \hat{\mu}^4 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^4 \quad \text{e} \quad \hat{\sigma}^4 = \left[ \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \right]^2.$$

A Figura 1 ilustra um esboço das distribuições platicúrtica, mesocúrtica e leptocúrtica.

Figura 1: Distribuição platicúrtica, mesocúrtica e leptocúrtica.



Fonte: Dos autores.

## Distribuição log-normal

A distribuição de probabilidade log-normal é contínua e frequentemente utilizada para modelar dados positivos ou com assimetria positiva. É conhecida como log-normal porque a distribuição dos valores da variável original, sob a escala logarítmica, segue distribuição normal. Formalmente:

**Theorem 1** Se  $X$  é uma variável aleatória com suporte em  $\mathbb{R}_+^*$  e  $Y = \ln(X)$  tem distribuição normal com média  $\mu$  e variância  $\sigma^2$ , então  $X$  é dita ter distribuição log-normal, para a qual

$$f(x) = \frac{1}{x\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{[\ln(x) - \mu]^2}{2\sigma^2}\right\}, \quad x > 0,$$

$$E(X) = \mu = \exp\left(\mu + \frac{\sigma^2}{2}\right)$$

$$V(X) = \sigma^2 = \exp(2\mu + 2\sigma^2) - \exp(2\mu + \sigma^2)$$

A função suporte  $[\ell(\mu; \sigma^2; \mathbf{x})]$  do modelo log-normal é:


$$\ell(\mu; \sigma^2; \mathbf{x}) = -\frac{n}{2} \ln(2\pi\sigma^2) - \sum_{i=1}^n \ln(x_i) - \frac{1}{2\sigma^2} \sum_{i=1}^n [\ln(x_i) - \mu]^2.$$

Os estimadores de máxima verossimilhança para os parâmetros  $\mu$  e  $\sigma^2$  do modelo log-normal podem ser definidos analiticamente, sendo, respectivamente:

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n \ln(X_i) = \overline{\ln(X)} \quad \text{e} \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n [\ln(X_i) - \overline{\ln(X)}]^2.$$

A Figura 2 ilustra a distribuição log-normal para  $\mu = 0$  e diversos valores de  $\sigma$ .

Figura 2: Distribuição log-normal para diferentes parâmetros de  $\sigma$  e  $\mu = 0$ .



Fonte: Dos autores.

## Distribuição gama

Assim como a distribuição log-normal, a distribuição gama é apropriada para modelar dados positivos ou com assimetria positiva. Sua função densidade de probabilidade é definida como:

$$f(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-\frac{x}{\beta}}, \quad x \geq 0,$$

em que  $\Gamma(z) = \int_0^\infty t^{z-1} e^{-t} dt$ , para  $z > 0$ . Além disso,  $\alpha$  (*shape parameter*) e  $\beta$  (*scale parameter*) representam, respectivamente, os parâmetros de forma e escala da distribuição. É comum também encontrar uma parametrização da distribuição gama em função de  $\theta = \frac{1}{\beta}$ . Se  $X$  é uma variável aleatória contínua com distribuição Gama( $\alpha, \beta$ ), então:

$$E(X) = \mu = \alpha\beta$$

$$V(X) = \sigma^2 = \alpha\beta^2$$

A função suporte  $[\ell(\alpha; \beta; \mathbf{x})]$  do modelo gama é:


$$\ell(\alpha; \beta; \mathbf{x}) = -n \ln[\Gamma(\alpha)] - n\alpha \ln(\beta) + (\alpha - 1) \sum_{i=1}^n \ln(x_i) - \frac{1}{\beta} \sum_{i=1}^n x_i.$$

No entanto, os estimadores de máxima verossimilhança para os parâmetros  $\alpha$  e  $\beta$  do modelo gama não podem ser encontrados analiticamente. Por isso, métodos numéricos precisam ser utilizados para resolver o seguinte sistema de equações:

$$\begin{cases} \frac{\partial \ell(\alpha; \beta; \mathbf{x})}{\partial \alpha} = 0 \\ \frac{\partial \ell(\alpha; \beta; \mathbf{x})}{\partial \beta} = 0 \end{cases} \Rightarrow \begin{cases} \frac{-n}{\Gamma(\hat{\alpha})} \frac{d\Gamma(\hat{\alpha})}{d\alpha} - n \ln(\hat{\beta}) + \sum_{i=1}^n \ln(x_i) = 0 \\ \frac{n\hat{\alpha}}{\hat{\beta}} + \frac{1}{\hat{\beta}^2} \sum_{i=1}^n x_i = 0 \end{cases}$$

A Figura 3 apresenta a distribuição gama para alguns valores dos parâmetros  $\alpha$  e  $\beta$ .

Figura 3: Distribuição gama para diferentes valores de  $\alpha$  e  $\beta$ .



Fonte: Dos autores.

## Distribuição Weibull

A distribuição Weibull é apropriada para modelar dados positivos, simétricos ou assimétricos (assimetria positiva ou negativa). Sua função densidade de probabilidade é dada a seguir:

$$f(x) = \frac{\alpha}{\beta} \left(\frac{x}{\beta}\right)^{\alpha-1} e^{-(x/\beta)^\alpha}, \quad x > 0,$$

em que  $\alpha$  (*shape parameter*) e  $\beta$  (*scale parameter*) representam, respectivamente, os parâmetros de forma e escala da distribuição. Se  $X$  é uma variável aleatória com distribuição Weibull, então:

$$E(X) = \mu = \beta \Gamma\left(1 + \frac{1}{\alpha}\right)$$

$$V(X) = \sigma^2 = \beta^2 \left\{ \Gamma \left( 1 + \frac{2}{\alpha} \right) - \left[ \Gamma \left( 1 + \frac{1}{\alpha} \right) \right]^2 \right\}$$

Adicionalmente, a função suporte  $[\ell(\alpha; \beta; \mathbf{x})]$  do modelo Weibull é definido como:


$$\ell(\alpha; \beta; \mathbf{x}) = n \ln(\alpha) - n\alpha \ln(\beta) + (\alpha - 1) \sum_{i=1}^n \ln(x_i) - \sum_{i=1}^n \left( \frac{x_i}{\beta} \right)^\alpha.$$

Note, porém, que os estimadores de máxima verossimilhança para os parâmetros  $\alpha$  e  $\beta$  do modelo Weibull não podem ser obtidos analiticamente. Por isso métodos numéricos precisam ser utilizados para resolver o seguinte sistema de equações:

$$\begin{cases} \frac{\partial \ell(\alpha; \beta; \mathbf{x})}{\partial \alpha} = 0 \\ \frac{\partial \ell(\alpha; \beta; \mathbf{x})}{\partial \beta} = 0 \end{cases} \Rightarrow \begin{cases} \frac{n}{\alpha} + n \ln \left( \frac{1}{\beta} \right) + \sum_{i=1}^n \ln(x_i) - \sum_{i=1}^n \left( \frac{x_i}{\beta} \right)^{\hat{\alpha}} \ln \left( \frac{x_i}{\beta} \right) = 0 \\ -\frac{n\hat{\alpha}}{\beta} - \alpha \left( \frac{1}{\beta} \right)^{\hat{\alpha}-1} \sum_{i=1}^n x_i^{\hat{\alpha}} = 0 \end{cases}.$$

A Figura 4, apresenta a distribuição Weibull para alguns valores dos parâmetros  $\alpha$  e  $\beta$ .

Figura 4: Gráfico para a distribuição Weibull para alguns valores dos parâmetros  $\alpha$  e  $\beta$ .



Fonte: Dos autores.

## Teste de Kolmogorov Smirnov

Admita uma amostra aleatória  $X_1, X_2, \dots, X_n$  com função de distribuição empírica dada por  $F_n(x)$ , tal que:

$$F_n(x) = \hat{P}[X \leq x] = \frac{1}{n} \sum_{i=1}^n I_{(-\infty, x]}(X_i),$$

sendo ainda:

$$I_{(-\infty, x]}(X_i) = \begin{cases} 1, & \text{se } x \leq X_i \\ 0, & \text{se } x > X_i \end{cases}$$

De forma resumida, o teste não-paramétrico de Kolmogorov-Smirnov (Conover, 1971) mensura a distância entre a função de distribuição empírica ou dos dados  $[F_n(x)]$  e uma função de distribuição de referência ou teórica  $[F_X(x)]$ , isto é, de algum modelo probabilístico já documentado na literatura. Mais especificamente, testa-se as seguintes hipóteses:

$$\begin{cases} H_0 : F_X(x) = F_n(x) \\ H_1 : F_X(x) \neq F_n(x) \end{cases}$$

A estatística de teste é definida por:

$$D_n = \sup_x |F_n(x) - F_X(x)|,$$

em que  $D_n$  é o supremo (menor limite superior) dentre todas as diferenças particulares resultantes de  $|F_n(x) - F_X(x)|$ . Maiores detalhes sobre a distribuição exata de  $D_n$  e, conseqüentemente, sobre a fórmula para o cálculo do valor  $p$  podem consultados em Marsaglia et al. (2003).

## Critério de Informação de Akaike

O Critério de Informação de Akaike (Akaike, 1974) ou simplesmente AIC é definido como:

$$AIC = -2 \ln L(\hat{\theta}) + 2k,$$

em que  $L(\hat{\theta})$  é o valor da função de verossimilhança ajustada do modelo e  $k$  é o número de parâmetros a serem estimados. Segundo Emiliano et al. (2014), uma das formas de escolher a distribuição que melhor se ajusta a um determinado conjunto de dados é observando aquela que apresenta o menor valor de AIC.

## Metodologia

Os dados utilizados neste estudo são valores históricos e atuais do índice  $IPCA_{12}$ , produzido mensalmente pelo IBGE. Mais especificamente, foram obtidas 271 observações que compreendem o período de dezembro do ano 2000 até junho do ano de 2023. O acesso a essas informações foi realizado através da plataforma gratuita denominada como “Dados de mercado”, cujo *link* para consulta é: <https://www.dadosdemercado.com.br>.

A análise inicial consistiu em entender o comportamento dos dados através de uma análise descritiva (cálculo de medidas de posição, de dispersão, de assimetria e de curtose). Além disso, foi construído o histograma de probabilidades dos valores de  $IPCA_{12}$ . De acordo com essas estatísticas e gráficos iniciais foram identificados na literatura alguns modelos ou distribuições de probabilidade que poderiam se adequar aos dados.

Os parâmetros dos modelos escolhidos foram estimados por máxima verossimilhança (Miller, 2011) e para validar o ajuste dos dados a essas distribuições foi utilizado o teste de Kolmogorov-Smirnov (KS), admitindo um nível de significância de 5%.

Dentre as distribuições selecionadas, aquelas que se adequaram aos dados ou que foram aprovadas pelo teste KS, a escolhida foi aquela que minimizou o Critério de Informação de Akaike (AIC).

O *software* livre R (R, 2023) foi utilizado para realizar as análises estatísticas e a estimação dos parâmetros dos modelos. Os pacotes (funções) utilizados foram: *moments* (*skewness*, *kurtosis*), *MASS* (*fitdistr*) e *fitdistrplus* (*fitdist*).

## Resultados e discussão

A tabela abaixo apresenta a estatística descritiva dos valores de  $IPCA_{12}$ .

Tabela 1: Estatística descritiva dos valores de  $IPCA_{12}$ .

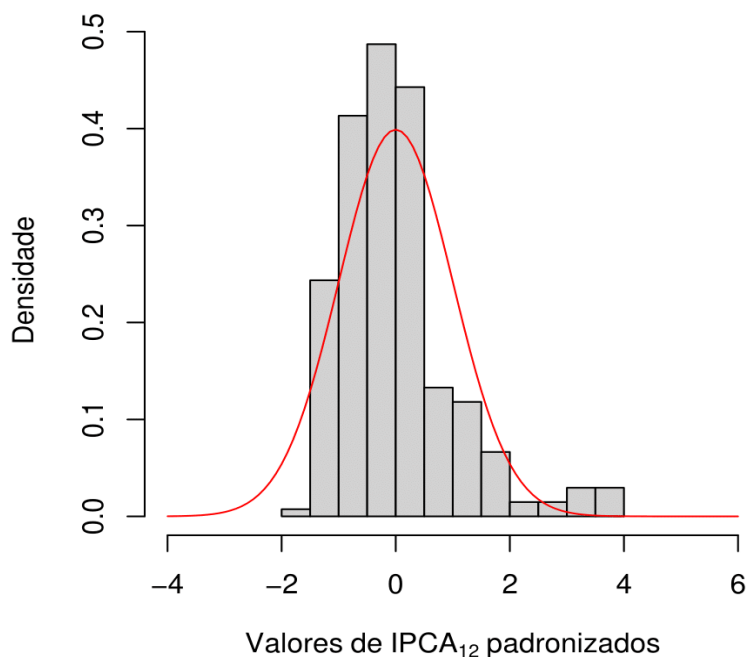
Estatísticas	Estimador	Estimativas
Mínimo	$X_{(1)}$	1,88
Média	$\bar{X}$	6,37
Mediana	$Md_X$	5,99
Moda	$Mo_X$	5,20
Máximo	$X_{(n)}$	17,24
Variância	$S_X^2$	8,00
Desvio-padrão	$S_X$	2,83
Coefficiente de variação	$CV_X$	44,44
Coefficiente de assimetria	$\hat{\gamma}_1$	1,42
Coefficiente de curtose	$\hat{\gamma}_2$	5,70

Fonte: Dos autores.

Note que a distribuição empírica apresenta-se positivamente assimétrica, uma vez que  $Mo_X = 5,20 < Md_X = 5,99 < \bar{X} = 6,37$ . Essa hipótese é corroborada pela estimativa do coeficiente de assimetria, que foi superior a 0, ou seja,  $\hat{\gamma}_1 = 1,42 > 0$ . Nesse caso a moda amostral seria um estimador mais recomendado para resumir os dados, sendo que o seu valor indica que no Brasil, historicamente, o  $IPCA_{12}$  mais recorrente ou representativo estaria próximo de 5,20%.

É possível observar que a distribuição dos dados é leptocúrtica, com caudas mais densas ou pesadas do que a de uma distribuição normal padrão, já que  $\hat{\gamma}_2 = 5,70 > 3$ . Logo, a probabilidade de valores tão, ou mais extremos, de  $IPCA_{12}$  ocorrerem é maior do que a probabilidade que seria obtida se os dados originais tivessem sido gerados de uma distribuição normal padrão. Veja a Figura 5:

Figura 5: Histograma dos dados e curva de densidade de uma  $N(0,1)$ .



Fonte: Dos autores.



Uma vez que os valores de  $IPCA_{12}$  são positivos e também positivamente assimétricos, foram escolhidas três distribuições contínuas de probabilidade com o intuito de modelar os dados. Mais especificamente, as distribuições foram: log-normal, gama e Weibull. A tabela abaixo ilustra as estimativas de máxima verossimilhança dos parâmetros dessas distribuições, bem como os seus respectivos erros padrão.

Tabela 2: Estimativas de máxima verossimilhança (Erro padrão da estimativa).

log-normal	Gama	Weibull
$\hat{\mu} \approx 1,76$ (0,025)	$\hat{\alpha} \approx 5,81$ (0,486)	$\hat{\alpha} \approx 2,36$ (0,101)
$\hat{\sigma} \approx 0,42$ (0,018)	$\hat{\beta} \approx 1,09$ (0,096)	$\hat{\beta} \approx 7,19$ (0,196)

Fonte: Dos autores.

Posteriormente, o teste de Kolmogorov-Smirnov foi utilizado para avaliar se as distribuições estimadas se ajustavam adequadamente aos dados amostrais. A tabela a seguir ilustra o valor  $p$  para o teste KS e também o resultado do AIC para cada uma dessas distribuições.


Tabela 3: Valor p - Teste Kolmogorov-Smirnov.

Log-normal	Gama	Weibull
$p \approx 3\%$ $AIC \approx 1257$	$p \approx 13\%$ $AIC \approx 1267$	$p \approx 0,5\%$ $AIC \approx 1305$

Fonte: Dos autores.

Como observado, a 5% de significância, apenas a distribuição Gama se ajustou adequadamente aos dados segundo o teste KS. Por esse motivo essa distribuição foi selecionada, mesmo não possuindo o menor valor de AIC. Como complemento, a Figura 6 ilustra o gráfico da função suporte do modelo gama ajustado, indicando que a combinação de estimativas que produz o seu valor máximo,  $l(\hat{\alpha}, \hat{\beta}; x) \approx -632$ , são os valores de  $\hat{\alpha} \approx 5,81$  e  $\hat{\beta} \approx 1,09$ .

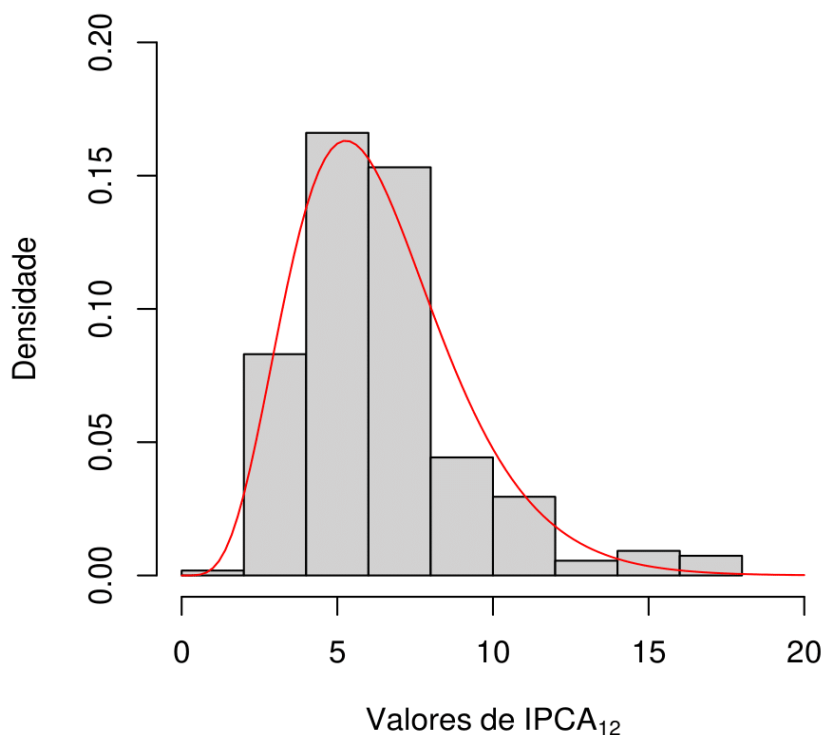
Figura 6: Função suporte ajustada para o modelo Gama( $\hat{\alpha} \approx 5,81; \hat{\beta} \approx 1,09$ ).



Fonte: Dos autores.

Já a Figura 7 apresenta o histograma de probabilidades dos dados e, sobreposto a este, a curva da distribuição gama ajustada, isto é, com os parâmetros estimados  $\hat{\alpha} \approx 5,81$  e  $\hat{\beta} \approx 1,09$ .

Figura 7: Histograma da distribuição gama, sobre os dados de  $IPCA_{12}$ .



Fonte: Dos autores.

Por fim, com a distribuição Gama( $\hat{\alpha} \approx 5,81$ ;  $\hat{\beta} \approx 1,09$ ) ajustada aos dados históricos de  $IPCA_{12}$ , estimou-se a probabilidade do verdadeiro valor desse índice permanecer dentro dos limites de confiança estabelecidos pelo BC para o ano de 2024:

$$P[3\% - 1,5\% \leq IPCA_{12} \leq 3\% + 1,5\%] = P[1,5\% \leq IPCA_{12} \leq 4,5\%] = 25,45\%.$$

Note que a probabilidade estimada é aproximadamente 25%, ou seja, é pouco provável que o governo consiga atender seus objetivos econômicos se a meta para o IPCA no ano de 2024 for de 3%. Por esse motivo, seria interessante encontrar um valor de  $x$ , ou uma meta de inflação, mais adequada, de forma que:

$$x = \arg \max_x [P(x\% - 1,5\% \leq IPCA_{12} \leq x\% + 1,5\%)].$$

A Figura 8 informa, com base na distribuição Gama( $\hat{\alpha} \approx 5,81$ ;  $\hat{\beta} \approx 1,09$ ), que o valor de  $x$  que maximiza a probabilidade de cobertura do intervalo é  $x = IPCA_{Meta} = 5,4\%$ . Ou seja:

$$P[5,4\% - 1,5\% \leq IPCA_{12} \leq 5,4\% + 1,5\%] = P[3,9\% \leq IPCA_{12} \leq 6,9\%] = 45,94\%.$$

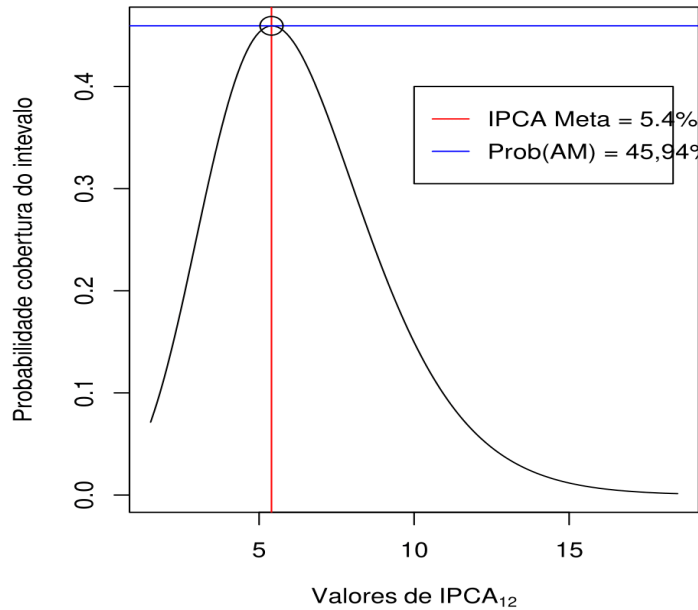


Figura 8: Meta de IPCA e probabilidade de cobertura do intervalo.

## Conclusões

Os resultados demonstraram que é mais provável (quase 3 vezes) que o  $IPCA_{12}$  se mantenha fora dos limites de confiança estabelecidos pelo governo em 2024. Adicionalmente, mantendo fixa a margem de  $\pm 1,5\%$ , para maximizar a probabilidade de cobertura do intervalo, a meta do  $IPCA_{12}$  deveria ser de  $5,4\%$  ao invés de  $3\%$ . Mais especificamente:

$$P[5,4\% - 1,5\% \leq IPCA_{12} \leq 5,4\% + 1,5\%] = P[3,9\% \leq IPCA_{12} \leq 6,9\%] = 45,94\%.$$

## Acknowledgements

Os autores agradecem Capes, CNPq, Fapemig e a Universidade Federal de Viçosa que deram suporte financeiro para realização deste artigo.

## References

- AKAIKE, H. A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, Notre Dame, v. 19, n. 6, p. 717-723, 1974.
- BARROS, R. P. de; NERI, M. M., R. *Pobreza e inflação no Brasil: Uma análise agregada*. Economia Brasileira em Perspectiva. Rio de Janeiro: IPEA, vol 1, 1996. 838 p.
- CONOVER, W. J. *Practical Nonparametric Statistical*. John Wiley & Sons Inc., New York, 462 p.
- DELFIN NETTO, A. Sobre as metas inflacionárias. *Revista de Economia Aplicada*, v. 3, n. 3, 1999.
- EMILIANO, P. C.; VIVANCO, M. J. F.; MENEZES, F. S. Information criteria: How do they behave in different models?. *Computational Statistics & Data Analysis*, v. 69, p. 141-153, 2014.
- FERREIRA, T. P.; FIGUEIREDO F. M. R. Os preços administrados e a inflação no Brasil. *Banco Central do Brasil Trabalhos para Discussão*, n. 59, Brasília, dez. 2002.
- FERREIRA, T.P.; PETRASSI, M. B. S. Regime de metas de inflação: resenha sobre a experiência internacional. *Banco Central do Brasil. Notas Técnicas*, nº 30, Brasília, nov., 2002.

- MARSAGLIA G., TSANG W. W., WANG J. Evaluating Kolmogorov's distribution. *Journal of Statistical Software*, v. 8, n. 18, 2003.
- MILLER, R. B. *Maximum likelihood estimation and inference: with examples in R, SAS, and ADMB*. 1. ed. [S.l.]: Wiley, 2011.
- MOOD, A. M.; GRAYBILL, F. A.; BOES, D. C. *Introduction to the theory of statistics*. Singapore: McGraw-Hill, 1974. 564 p.
- R CORE TEAM. *R: a language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. 2023.