

# A Melhor Pior Priori: Minimizando a Variância de Amostragem por Importância para Troca de Prioris

Amanda Perez<sup>1</sup>, Luiz Max Carvalho<sup>2</sup>, Diego Mesquita<sup>3</sup>  
 FGV EMAP, Rio de Janeiro, RJ

O paradigma bayesiano de inferência estatística apresenta a grande conveniência de permitir a incorporação de conhecimento *a priori* ao processo de modelagem. Em especial, em muitos contextos, é de grande interesse estimar  $\mathbb{E}_p[h(\theta)]$ , onde  $h$  é uma função (mensurável) de teste e  $\theta$  é o parâmetro de interesse do modelo, cuja distribuição *a posteriori* é  $p(\theta | X) \propto \mathcal{L}(X | \theta)\pi(\theta)$ . Entretanto, nem sempre é possível obter essa posteriori, seja por limitações de poder computacional ou mesmo por má convergência das cadeias de Markov ao realizar MCMC.

Nesses casos, uma alternativa é a troca de prioris: utiliza-se uma priori mais simples que a de interesse (“priori substituta”) para a obtenção de uma distribuição *a posteriori*. Após isso, podemos utilizar amostragem por importância (IS) para amostrar da *a posteriori* de interesse. No entanto, existe a possibilidade de a variância do estimador ser muito alta ou mesmo infinita, a depender da escolha da priori substituta e da função de teste  $h$  [2]. No presente trabalho, utilizamos métodos de descida do gradiente para encontrar uma priori substituta que minimize essa variância.

É conhecido que, no caso geral, essa variância pode ser minimizada por uma distribuição conhecida com forma fechada [3]. Contudo, se o interesse é estimar  $\mathbb{E}_p[h(\theta)]$ , a variância é minimizada quando escolhe-se como priori substituta a distribuição cuja posteriori  $q$  seja dada por:

$$q(\theta | X) \propto |h(\theta)| p(\theta | X). \quad (1)$$

Essa escolha depende da posteriori de interesse  $p(\theta|X)$ , que não nos é acessível, impossibilitando usar diretamente o resultado em (1). Nossa proposta, então, é escolher uma priori  $\pi_s(\theta)$  para substituir a priori de interesse  $\pi(\theta)$  tal que sua posteriori  $p_s(\theta|X)$  minimize a divergência KL entre  $p_s$  e  $q$ . Usando  $D_{KL}(p_s||q)$  como função de perda, pode-se simplificar o problema de otimização a:

$$\pi_s^*(\theta) = \arg \min_{\pi_s \in \Pi_s} \log c_s + \mathbb{E}_{p_s} \left[ \frac{\pi_s(\theta)}{|h(\theta)| \pi(\theta)} \right], \quad (2)$$

onde  $c_s$  é a constante que normaliza a distribuição  $p_s$ , isto é, se  $\mathcal{L}(X | \theta)$  é a verossimilhança dos dados, então  $p_s(\theta | X) = c_s \pi_s(\theta) \mathcal{L}(X | \theta)$ . Caso nos limitemos ao uso de prioris substitutas conjugadas, teremos  $c_s$  e  $p_s$  conhecidas, o que nos permite avaliar (aproximadamente) a função de perda descrita em (2), usando Monte Carlo. Assim, fixando uma forma paramétrica para  $\pi_s$ , podemos utilizar algoritmos de descida do gradiente para obter os parâmetros ótimos da distribuição.

Além disso, foi possível generalizar o resultado para o caso em que há múltiplas funções de teste a serem consideradas (digamos  $h_1, \dots, h_m$ ). Para esse caso, buscou-se minimizar a média das variâncias do estimador de IS para cada uma das funções, obtendo como distribuição *a posteriori* substituta ótima:  $g(\theta | X) \propto p(\theta | X) \sqrt{\sum_{i=1}^m h_i(\theta)^2}$ . Esta expressão é muito semelhante à apresentada em (1), tendo como diferença apenas que a função  $h$  agora seria uma função de  $h_1, \dots, h_m$ .

<sup>1</sup>perez.amanda.de.m@gmail.com

<sup>2</sup>luiz.fagundes@fgv.br

<sup>3</sup>diego.mesquita@fgv.br

Este detalhe auxilia na implementação para diferentes funções de teste simultaneamente, pois permite minimizar  $D_{\text{KL}}(p_s \| g)$  de maneira análoga, bastando tomar  $|h(\theta)| = \sqrt{\sum_{i=1}^m h_i(\theta)^2}$ .

Para ambos os casos, realizamos experimentos envolvendo um cenário simples e computacionalmente tratável. Assumimos uma sequência de observações  $X_1, \dots, X_n \sim \mathcal{N}(0, \sigma^2)$ , com média conhecida e variância  $\theta := \sigma^2$  desconhecida. Os dados utilizados foram gerados amostrando de uma normal de média zero e variância pequena, o que sugeriria modelar a priori de  $\sigma = \sqrt{\theta}$  como uma distribuição com suporte em  $\mathbb{R}^{>0}$  e alta densidade na vizinhança de zero, e.g.,  $\mathcal{N}(0, 1)$  truncada em zero. Mas, supondo a impossibilidade de usar essa distribuição para inferir  $\sigma$ , poderíamos tomar  $\theta \sim \text{GamaInversa}(\alpha, \beta)$  como priori (conjugada) e aplicar IS para obter a posteriori de interesse.

Para essa implementação, foi utilizada a linguagem Python, com as bibliotecas PyTorch, PyStan e Numpy. A otimização dos parâmetros foi feita utilizando o algoritmo Adam [1].

Aplicando o método proposto para diferentes funções de teste, tanto individual quanto simultaneamente, obtivemos resultados promissores, que apontam que, ao utilizar a Gama Inversa com os parâmetros ótimos encontrados, o estimador de IS converge mais rapidamente e para resultados mais próximos dos obtidos por MCMC para a posteriori de interesse (vide a Figura 1). Esses resultados indicam o potencial do nosso método, e trabalhos futuros poderiam ampliar a variedade de experimentos e generalizar nossa abordagem para casos com priors substitutas não-conjugadas.

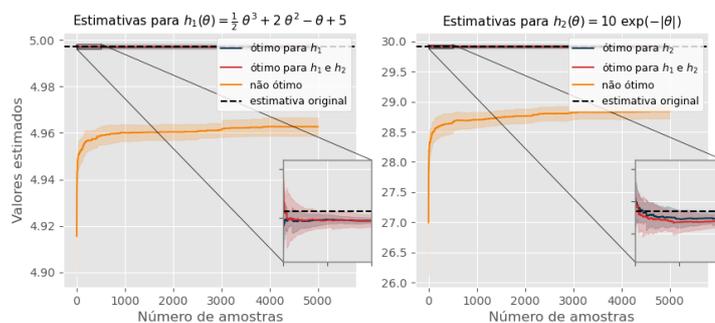


Figura 1: Estimativas obtidas por IS em 30 realizações do experimento para diferentes priors substitutas e duas funções de teste ao variar o número de amostras de importância. Fonte: dos autores.

## Agradecimentos

Este trabalho recebeu o apoio da Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro FAPERJ (SEI-260003/000709/2023), da Fundação de Amparo à Pesquisa do Estado de São Paulo FAPESP (2023/00815-6) e do Conselho Nacional de Desenvolvimento Científico e Tecnológico CNPq (404336/2023-0).

## Referências

- [1] D. Kingma e J. Ba. “Adam: A Method for Stochastic Optimization”. Em: **International Conference on Learning Representations (ICLR)**. San Diego, CA, USA, 2015.
- [2] W. Neiswanger e E. Xing. “Post-Inference Prior Swapping”. Em: **Proceedings of the 34th International Conference on Machine Learning**. Vol. 70. 2017, pp. 2594–2602. DOI: 10.48550/ARXIV.1606.00787.
- [3] A. B. Owen. **Monte Carlo theory, methods and examples**. Acessado em 14/03/2024, <https://artowen.su.domains/mc/Ch-var-is.pdf>. 2013. Cap. 9.