

Princípios fundamentais da Inferência bayesiana

Prof. Caio Azevedo

Relembrando

- Posteriori : $p(\theta|\mathbf{x}) = \frac{p(\mathbf{x}|\theta)p(\theta)}{p(\mathbf{x})}$, em que

$$p(\mathbf{x}) = \begin{cases} \int_{\Theta} p(\mathbf{x}|\theta)p(\theta)d\theta, & \text{se } \theta \text{ for uma v.a.c.,} \\ \sum_{\theta \in \Theta} p(\mathbf{x}|\theta)p(\theta), & \text{se } \theta \text{ for uma v.a.d.} \end{cases}$$

- Se $p(\theta) \propto I_{\Theta}(\theta)$, então $p(\theta|\mathbf{x}) \propto p(\mathbf{x}|\theta)$ (a posteriori é proporcional à verossimilhança) e o estimador bayesiano MAP coincide (numericamente) com o EMV.
- Na obtenção da posteriori, tudo que não depender de θ , tanto na verossimilhança quanto na priori, pode ser desconsiderado.

Princípios da IB

- Os três princípios básicos da Inferência bayesiana são:
 - Princípio da Verossimilhança.
 - Princípio da Suficiência.
 - Princípio da Condicionalidade.
- A inferência frequentista compactua com o **princípio da suficiência**, pode ou não compactuar com o princípio da condicionalidade, mas não compactua com o princípio da verossimilhança.

Princípio da Verossimilhança

- Sejam $\mathbf{X} = (X_1, \dots, X_n)' \in \Omega_x$ e $\mathbf{Y} = (Y_1, \dots, Y_n)' \in \Omega_y$ ($\Omega_{(\cdot)}$ sendo o respectivo suporte das distribuições) dois vetores aleatórios (pertencentes ao mesmo espaço estatístico), que dependem do mesmo parâmetro θ e que possuem verossimilhanças distintas, mas que obedecem a seguinte relação :

$$p(\mathbf{x}|\theta) = K(\mathbf{x}, \mathbf{y})f(\mathbf{y}|\theta) \propto p(\mathbf{y}|\theta), \forall \theta \in \Theta$$

em que $K(\mathbf{x}, \mathbf{y})$ não depende de θ . Então, sob a mesma priori, as posteriores obtidas a partir de \mathbf{x} e \mathbf{y} são iguais, ou seja

$$p(\theta|\mathbf{x}) = p(\theta|\mathbf{y})$$

Princípio da Verossimilhança (cont.)

- Demonstração (caso contínuo):

$$\begin{aligned} p(\theta|\mathbf{x}) &= \frac{p(\mathbf{x}|\theta)p(\theta)}{\int_{\Theta} p(\mathbf{x}|\theta)p(\theta)d\theta} = \frac{p(\mathbf{y}|\theta)K(\mathbf{x}, \mathbf{y})p(\theta)}{\int_{\Theta} p(\mathbf{y}|\theta)K(\mathbf{x}, \mathbf{y})p(\theta)d\theta} \\ &= \frac{p(\mathbf{y}|\theta)p(\theta)}{\int_{\Theta} p(\mathbf{y}|\theta)p(\theta)d\theta} = p(\theta|\mathbf{y}) \end{aligned}$$

- Exercício: repetir para o caso discreto.

Princípio da Verossimilhança (cont.)

- Exemplo: Suponha que desejamos estimar θ (probabilidade de observar cara (C) no lançamento de uma moeda) e que, para um determinado experimento, observou-se

$$\{C, \bar{C}, C, C, \bar{C}, \bar{C}, C, \bar{C}, \bar{C}, \bar{C}\}$$

Princípio da Verossimilhança (cont.)

- Entre outras possibilidades, os dados acima poderiam ter sido gerados a partir dos seguintes experimentos:
 - Lançar a moeda 10 vezes e contabilizar o número de caras ($X \sim \text{binomial}(10, \theta)$).
 - Lançar uma moeda, até obter um total de 4 caras, contabilizando o número de lançamentos ($Y \sim \text{Binomial-Negativa}(4, \theta)$).

Princípio da Verossimilhança (cont.)

- Em termos de verossimilhança dos modelos:

- Primeiro caso:

$$p(x|\theta) = \frac{10!}{x!(10-x)!} \theta^x (1-\theta)^{10-x} \mathbb{1}_{\{0,1,\dots,10\}}(x) \propto \theta^x (1-\theta)^{10-x}$$

- Segundo caso:

$$p(y|\theta) = \frac{(y-1)!}{(y-4)!3!} (1-\theta)^{y-r} \theta^r \mathbb{1}_{\{r,r+1,\dots\}}(y) \propto (1-\theta)^{y-4} \theta^4.$$

- Utilizando os dados observados nas verossimilhanças:

- No primeiro caso, para os dados em questão, temos que:

$$p(6|\theta) \propto \theta^4 (1-\theta)^6.$$

- No segundo caso, para os dados em questão, temos que:

$$p(10|\theta) \propto \theta^4 (1-\theta)^6.$$

Princípio da Verossimilhança (cont.)

- Logo,

$$p(x|\theta) \propto p(y|\theta)$$

e, portanto, sob uma mesma priori para θ , a posteriori obtida a partir de x seria igual à posteriori obtida a partir de y . Ou seja a “inferência bayesiana” seria a mesma.

- Contudo, por exemplo, os estimadores de máxima verossimilhança (emv) de θ sob cada um dos modelos, seriam diferentes.

Princípio da suficiência

- Seja $T = g(\mathbf{X})$ uma **estatística suficiente** para um parâmetro θ . associado à uma verossimilhança $p(\cdot|\theta)$. Então, a distribuição à posteriori dependerá apenas de T (ou, equivalentemente, de sua distribuição).
- Prova (caso contínuo): Se T é uma estatística suficiente, então pelo teorema da fatoração de Neyman, temos que:

$$p(\mathbf{x}|\theta) = g(t; \theta)h(\mathbf{x}),$$

assim, vem que

$$p(\theta|\mathbf{x}) = \frac{p(\mathbf{x}|\theta)p(\theta)}{\int_{\Theta} p(\mathbf{x}|\theta)p(\theta)d\theta} = \frac{g(t; \theta)h(\mathbf{x})p(\theta)}{\int_{\Theta} g(t; \theta)h(\mathbf{x})p(\theta)d\theta} = \frac{g(t; \theta)p(\theta)}{\int_{\Theta} g(t; \theta)p(\theta)d\theta}$$

Princípio da suficiência (cont.)

- Em geral, se $g(\cdot; \theta)$ não for a própria distribuição de T , está associada à ela.
- Com efeito, considere $X_1|\mu, \dots, X_n|\mu \stackrel{iid}{\sim} N(\mu, \sigma^2)$, com σ^2 conhecido (exercício).
- Ao invés de usarmos a verossimilhança associada à amostra, podemos usar a distribuição da estatística suficiente $\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$.

Princípio da condicionalidade

- Suponha que dispomos de m experimentos possíveis de serem realizados, denotados por E_1, \dots, E_m , a fim de levantar informações (dados) para se fazer inferência à respeito de um parâmetro θ . Considere que tais experimentos, embora diferentes, sejam semelhantes entre si.
- Suponha que sorteamos um experimento, entre os m , ao acaso, e que o utilizamos para levantar informações. O princípio da condicionalidade diz que os outros experimentos que não foram sorteadas são irrelevantes para se estimar θ . Ou seja, apenas o experimento realizado é relevante.

Princípio da condicionalidade (cont.)

- Exemplo: (extraído de [Paulino et al \(2018\)](#)). Pretende-se testar as hipóteses $H_0 : \theta = 0$ vs $H_1 : \theta = 10$. Considere-se que o experimento E (a ser utilizado) é uma mistura de dois experimentos, E_1 , escolhido com probabilidade p e consistindo em observar uma variável aleatória $X \sim N(\theta, 10)$ (ou seja, usar um instrumento menos preciso) e E_2 , escolhido com probabilidade $1 - p$ e consistindo em observar uma variável aleatória $X' \sim N(\theta, 1)$ (ou seja, usar um instrumento mais preciso).

Princípio da condicionalidade (cont.)

- Suponha que um primeiro Estatístico adote o seguinte procedimento:
 - Se for escolhido o experimento E_1 , rejeita H_0 quando $X > K_0$, com $\Phi(K_0/10) = 1 - \xi$.
 - Se for escolhido o experimento E_2 , rejeita H_0 quando $X' > K_1$, com $\Phi(K_1) = 1 - \zeta$.

e declara que seu teste tem nível de significância $\alpha = p\xi + (1 - p)\zeta$.

- Tal procedimento viola o princípio da condicionalidade.

Princípio da condicionalidade (cont.)

- Por outro lado, suponha que um segundo Estatístico adote o seguinte procedimento:
 - Se for escolhido o experimento E_1 , ignora o que poderia acontecer se E_2 tivesse sido sorteado, rejeita H_0 quando $X > K_0$ com $\Phi(K_0/10) = 1 - \xi$ e declara que seu teste tem nível de significância ξ .
 - Se for escolhido o experimento E_2 , ignora o que poderia acontecer se E_1 tivesse sido sorteado, rejeita H_0 quando $X' > K_0$ com $\Phi(K_1) = 1 - \zeta$ e declara que seu teste tem nível de significância ζ .
- Tal procedimento respeita o princípio da condicionalidade.

Princípio da condicionalidade (cont.)

- Suponha, ainda, um terceiro Estatístico, que adota o seguinte procedimento:
 - Se for escolhido o experimento E_1 , ignora o que poderia acontecer se E_2 tivesse sido sorteado, observa $X = x$ e afirma interessar-se somente na evidência provida por x sobre H_0 , ou seja $P(H_0|x)$.
 - Se for escolhido o experimento E_2 , ignora o que poderia acontecer se E_1 tivesse sido sorteado, observa $X = x'$ e afirma interessar-se somente na evidência provida por x' sobre H_0 , ou seja $P(H_0|x')$.
- Tal procedimento respeita o princípio da condicionalidade. Essencialmente, trata-se de usar a posteriori como estimador (bayesiano) de interesse.