

Inferência bayesiana sob a ótica da teoria da decisão

Prof. Caio Azevedo

Motivação

- De uma forma geral, todas as questões de Inferência Estatística (frequentista ou bayesiana), podem ser estudadas sob a ótica da Teoria da Decisão ([ref 1](#), [ref 2](#)).
- De um modo rudimentar, a Teoria da Decisão consiste em um conjunto de metodologias que nos levam à escolher uma (eventualmente mais de uma), entre várias ações (decisões) possíveis, de modo a minimizar alguma perda ou a maximizar algum ganho.
- Por exemplo, qual estimador (frequentista) escolher (ação, decisão), entre aqueles que são não viciados? Podemos escolher aquele, por exemplo, que apresenta a menor variância (perda).

Elementos básicos da Teoria da Decisão (frequentista & bayesiana)

- Medidas de qualidade básica são:
 - Função de perda.
 - Perda esperada (risco frequentista).
 - Risco de Bayes.
 - Risco de Bayes integrado ou à posteriori.
- A inferência frequentista utiliza os dois primeiros elementos acima.
- A inferência bayesiana utiliza os quatro elementos acima.
- Seja $\mathbf{X}|\boldsymbol{\theta} = (X_1|\boldsymbol{\theta}, \dots, X_n|\boldsymbol{\theta})'$ um vetor aleatório com fdp $f_{\mathbf{X}|\boldsymbol{\theta}}(\cdot|\boldsymbol{\theta})$, $\boldsymbol{\theta} \in \Theta \subseteq \mathcal{R}^k$.

Introdução à Teoria da Decisão

- Os elementos básicos da Teoria da Decisão são:

1 Θ : espaço paramétrico (estado da natureza).

2 \mathcal{A} : é o conjunto das possíveis ações que podem ser tomadas (exemplos):

- \mathcal{A} : {é o conjunto dos estimadores pontuais}.

- \mathcal{A} : {é o conjunto das funções de teste}.

3 Uma função de decisão definida por $d : \mathcal{X} \rightarrow \mathcal{A}$, ($x \rightarrow d(x)$) que é formulada para se obter informações sobre θ . Notação:

\mathcal{D} : {classe de todas as funções de decisão}.

4 Para avaliar a escolha de uma função de decisão ($d \in \mathcal{D}$), vamos considerar o conceito de função perda.

Função de perda

- Seja $\delta(\mathbf{X})$ um estimador (frequentista ou bayesiano) e $\delta(\mathbf{x})$ a respectiva estimativa.
- Seja θ o parâmetro de interesse.
- Seja \mathcal{D} o conjunto de todos os estimadores “possíveis” para θ .

Função de perda

- A função de perda (as vezes chamada de função perda) é definida por:

$$L(\delta, \theta) = L(\delta(\mathbf{x}), \theta)$$
$$(\mathcal{D}, \Theta) \rightarrow \mathcal{R}^+$$

tal que $L(., .)$ satisfaz as seguintes propriedades (próximo slide):

- a) $L(\delta, \theta) \geq 0, \forall d \in \mathcal{D}, \theta \in \Theta.$
- b) $L(\delta, \theta) = 0,$ se $d = \theta.$

- Note que considerarmos $d = d(\mathbf{X})$ então $L(d(\mathbf{X}), \theta)$ é uma va.

Exemplos de função de perda

- $L_1 = (\delta - \theta)^2$ (perda quadrática).
- $L_2 = |\delta - \theta|$ (perda modular).
- $L_3 = \begin{cases} A, & \text{se } |\delta - \theta| > \epsilon, \epsilon > 0 \\ 0, & \text{se } |\delta - \theta| \leq \epsilon \end{cases}$ (perda (0,A)).
- $L_4 = \rho(\theta)|\delta - \theta|^r, \rho(\theta) \geq 0, \forall \theta, r > 0$ (perda generalizada).

Perda esperada (risco frequentista)

- Para uma dada função de perda, o risco frequentista é definido como sendo o seu valor esperado em relação à distribuição de $\mathbf{X}|\theta$, ou seja

$$R(\delta, \theta) = \mathcal{E}_{\mathbf{X}|\theta}[L(\delta, \theta)] = \begin{cases} \sum_{\mathbf{x} \in \mathbf{X}(\Omega)} L(\delta(\mathbf{X}), \theta) p(\mathbf{x}|\theta), & \text{se } \mathbf{X} \text{ for discreto} \\ \int_{\mathbf{X}(\Omega)} L(\delta(\mathbf{X}), \theta) p(\mathbf{x}|\theta) d\mathbf{x}, & \text{se } \mathbf{X} \text{ for contínuo} \end{cases}$$

- Exemplo [Erro quadrático médio (frequentista)]: $\mathcal{E}_{\mathbf{X}|\theta}[(\delta - \theta)^2]$.
- Obs: $\mathcal{X} = \mathbf{X}(\Omega)$.

Perda esperada (risco frequentista)

- Em geral, na inferência frequentista, busca-se o estimador que minimiza o risco acima definido (restrito à uma determinada subclasse de estimadores). Por exemplo, o ENVVUM.
- Obs: Se $L(\delta, \theta) = (\theta - \delta)^2$, então

$$\begin{aligned}R(d, \theta) &= \mathcal{E}_{\mathbf{X}|\theta} [(\theta - \delta)^2] = EQM_{\theta}(\delta) \\ &= \mathcal{V}_{\theta}(\delta) + B_{\theta}^2(\delta)\end{aligned}$$

- Mais detalhes sobre a inferência frequentista e teoria da decisão veja [aqui](#).

Perda esperada (risco frequentista)

- Def: Dizemos que um procedimento d_1 é melhor do que um procedimento d_2 se

$$R(d_1, \theta) \leq R(d_2, \theta), \forall \theta \in \Theta \text{ e}$$

$R(d_1, \theta) < R(d_2, \theta)$, para pelo menos um θ .

- Se d_1 e d_2 são tais que: $R(d_1, \theta) = R(d_2, \theta), \forall \theta \in \Theta$ dizemos que d_1 e d_2 são equivalentes.

Risco de Bayes

- Seja $p \equiv p(\theta)$ uma priori definida para θ .
- O risco de Bayes é definido como a perda média do risco frequentista, à priori, em relação à θ , ou seja

$$r(\delta, p) = \int_{\Theta} R(\delta, \theta) p(\theta) d\theta$$

- Contudo, em princípio, tal medida considera (explicitamente) apenas a priori.
- Como introduzir a posteriori no risco de Bayes?

Risco de Bayes (cont.)

- Note que

$$\begin{aligned}r(\delta, p) &= \int_{\Theta} R(\delta, \theta) p(\theta) d\theta \\&= \int_{\Theta} \left[\int_{\mathbf{X}(\Omega)} L(\delta(\mathbf{X}), \theta) p(\mathbf{x}|\theta) d\mathbf{x} \right] p(\theta) d\theta \\&= \int_{\Theta} \left[\int_{\mathbf{X}(\Omega)} L(\delta(\mathbf{X}), \theta) \frac{p(\mathbf{x}|\theta)p(\theta)}{p(\mathbf{x})} p(\mathbf{x}) d\mathbf{x} \right] d\theta \\&= \int_{\mathbf{X}(\Omega)} \underbrace{\left[\int_{\Theta} L(\delta(\mathbf{X}), \theta) p(\theta|\mathbf{x}) d\theta \right]}_{R_B(\delta, p)} p(\mathbf{x}) d\mathbf{x} \\&= \int_{\mathbf{X}(\Omega)} R_B(\delta, p) p(\mathbf{x}) d\mathbf{x}\end{aligned}$$

Risco à posteriori (ou integrado)

- Em geral, $R_B(\delta, p) = \int_{\Theta} L(\theta, d(\mathbf{x}))\pi(\theta|\mathbf{x})d\theta = \mathcal{E}_{\theta|\mathbf{x}}(L(\theta, d(\mathbf{x})))$ é chamado de risco integrado ou à posteriori de Bayes.
- O estimador Bayesiano (δ^p) que minimiza $R_B(\delta, p)$ é chamado de estimador de Bayes. Ou seja,

$$r(\delta^p, p) = \inf_{\delta \in \mathcal{D}} r(\delta, p) \quad (1)$$

- Encontrar o estimador de Bayes significa minimizar $\mathcal{E}_{\theta|\mathbf{x}}(L(\delta, \theta))$.

Risco à posteriori

- Obs: Segundo a definição acima, pode ocorrer que:
 - Não exista δ^P em \mathcal{D} que satisfaça (1).
 - Pode existir mais de um estimador de Bayes.
- A priori não precisa ser uma distribuição de probabilidade, tampouco ser própria $\left(\int_{\Theta} p(\theta)d\theta = \infty\right)$.

Estimadores Bayesianos associados à funções de perda específicas

- O estimador EAP é o estimador de Bayes para a função de perda $L_1 = (\delta - \theta)^2$.
- O estimador MeAP (mediana a posteriori) é o estimador de Bayes para a função de perda $L_4 = a|\delta - \theta|$, em que a é uma constante.
- O estimador MAP (moda a posteriori) é o estimador de Bayes para a função de perda $L_3 = \begin{cases} A, & \text{se } |\delta - \theta| > \epsilon, \epsilon > 0 \\ 0, & \text{se } |\delta - \theta| \leq \epsilon \end{cases}$

Demonstração para a função de perda $L_1 = (\delta - \theta)^2$

- Queremos minimizar $g(\delta) = \int_{\Theta} (\delta - \theta)^2 p(\theta|\mathbf{x}) d\theta$ em relação à δ .
Com efeito, note que:

$$\begin{aligned} g(\delta) &= \delta^2 \int_{\Theta} p(\theta|\mathbf{x}) d\theta - 2\delta \int_{\Theta} \theta p(\theta|\mathbf{x}) d\theta + \int_{\Theta} \theta^2 p(\theta|\mathbf{x}) d\theta \\ &= \delta^2 - 2\delta \mathcal{E}(\theta|\mathbf{X}) + \mathcal{E}(\theta^2|\mathbf{X}) \end{aligned}$$

- Derivando a expressão acima com relação à δ , igualando a expressão resultante à 0 e resolvendo-a em relação à δ , temos que

$$\hat{\delta} = \hat{\theta}_{Bayes} = \mathcal{E}(\theta|\mathbf{X})$$

Voltando ao Exemplo da $U(0, \theta)$

- $X_i | \theta \stackrel{i.i.d.}{\sim} U(0, \theta), i = 1, \dots, n$. Considere a função de perda $L(\delta, \theta) = \frac{(\delta - \theta)^2}{\theta^2}$.
- Vamos considerar $p(\theta) = I_{(0,1)}(\theta)$.
- (Exercício) Pode-se provar que

$$p(\theta | \mathbf{x}) = \frac{\left(\frac{1}{\theta}\right)^n I_{(y_n, 1)}(\theta)}{[1/(n-1)](y_n^{-n+1} - 1)}$$

- Queremos encontrar o estimador Bayesiano que minimiza

$$\int_{y_n}^1 \frac{(\delta - \theta)^2}{\theta^2} p(\theta | \mathbf{x}) d\theta$$

Voltando ao Exemplo 9 (cont.)

- Ou seja, buscamos o estimador que minimiza

$$\begin{aligned} & \int_{y_n}^1 (\delta - \theta)^2 \frac{1}{\theta^{n+2}} d\theta \\ = & \delta^2 \int_{y_n}^1 \frac{1}{\theta^{n+2}} d\theta - 2\delta \int_{y_n}^1 \frac{1}{\theta^{n+1}} d\theta + \int_{y_n}^1 \frac{1}{\theta^n} d\theta \end{aligned}$$

- Derivando a expressão acima com relação à δ , igualando a expressão resultante à 0 e resolvendo-a em relação à δ , temos que

$$\hat{\theta}_{Bayes} = \hat{\delta} = \frac{n+1}{n} \frac{1 - y_n^n}{1 - y_n^{n+1}} y_n$$

Estimador Minimax

- Voltando ao risco frequentista, o objetivo é encontrar o estimador (frequentista), digamos δ^* , que minimize o risco uniformemente em θ , ou seja:

$$R(\delta^*, \theta) \leq R(\delta, \theta), \forall \theta \in \theta, \text{ e, } \forall \delta \in \mathcal{D}$$

em que \mathcal{D} a classe de todos os estimadores possíveis (sabemos que isso é praticamente impossível).

Estimador Minimax

- Uma outra abordagem, consiste em considerar o estimador Bayesiano que minimize o máximo (supremo) do risco frequentista, ou seja, encontrar o estimador (Bayesiano), digamos δ' , tal que

$$\sup_{\theta \in \Theta} R(\delta', \theta) \leq \sup_{\theta \in \Theta} R(\delta, \theta), \forall \delta \in \mathcal{D}.$$

- Pode-se provar que se $\hat{\theta}_{Bayes}$ é o estimador de Bayes de θ , tal que $R(\hat{\theta}_{Bayes}, \theta)$ não dependa de θ , então $\hat{\theta}_{Bayes}$ é o estimador minimax de θ .

Voltando ao Exemplo 1

- $X_i|\theta \stackrel{i.i.d.}{\sim} \text{Bernoulli}(\theta), i = 1, \dots, n.$
- Considere a família conjugada de prioris e a função de perda quadrática $L_1 = (\delta - \theta)^2.$
- Vamos encontrar o estimador Minimax para θ sob a perda e a priori acima definidas.
- Sabemos que o estimador de Bayes, neste caso, é a esperança à posteriori, ou seja

$$\hat{\theta}_{\text{Bayes}} = \frac{n\bar{X} + a}{n + a + b}$$

Voltando ao Exemplo 1 (cont.)

- Neste caso, temos que (Exercício):

$$\begin{aligned}R(\delta, \theta) &= \mathcal{E}_{\mathbf{X}|\theta} \left[\left(\frac{n\bar{X} + a}{n + a + b} - \theta \right)^2 \right] \\ &= \frac{1}{(n + a + b)^2} [A\theta^2 - B\theta + a^2]\end{aligned}$$

em que $A = ((a + b)^2 - n)$ e $B = (2a(a + b) - n)$. Assim, $\hat{\theta}_{Bayes}$ é minimax $\Leftrightarrow A = B = 0$, ou seja, $\Leftrightarrow a = b = \frac{\sqrt{n}}{2}$. Assim,

$$R(\hat{\theta}_{Bayes}, \delta) = \frac{1}{4(1 + \sqrt{n})^2} \text{ e } \hat{\theta}_{Bayes} = \frac{n\bar{X} + \sqrt{n}/2}{n + \sqrt{n}}$$