

Introdução à Inferência Bayesiana

Prof. Caio Azevedo

Introdução

- A inferência bayesiana (IB) é baseada, essencialmente, no **teorema de Bayes**, que é uma consequência da definição de probabilidade condicional (e o teorema da probabilidade total).
- Com efeito, se A e B são dois eventos do mesmo espaço amostral, então:

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

- Os alicerces da IB são (slide seguinte):

Introdução

- a) Assumir que θ é aleatório, em certo sentido, (va, para modelar a incerteza que temos sobre ele), com suporte $\Theta \subseteq \mathcal{R}^k$
- b) A descrição desse comportamento aleatório (incerteza) é especificado através da distribuição a priori ($\pi(\cdot)$) (não necessariamente uma distribuição de probabilidade).
- c) O modelo estatístico é especificado por $f_X(\cdot|\theta) \equiv f_X(\cdot, \theta)$, cuja interpretação é a distribuição de $X|\theta$ (X dado que θ assume o valor θ . Isto é, $\forall x \in \mathcal{X}$, isto é

$$f_{X|\theta}(x|\theta) = f_{X|H=\theta}(x|\theta)$$

em que: $H : \Omega \rightarrow \Theta$.

Introdução

- Além disso, $f_H(\theta) = \pi(\theta)$ é a distribuição a priori, enquanto que a distribuição de $H|X = x$, $\pi(\theta|x) = f_{X|X=x}(\theta|x)$ é a distribuição a posteriori. Das relações anteriores, temos que

$$\begin{aligned}\pi(\theta|x) &= f_{H|X=x}(\theta|x) = \frac{f_{X,H}(x,\theta)}{f_X(x)} = \frac{f_{X|H=\theta}(x|\theta)f_X(\theta)}{f_X(x)} \\ &= \frac{f(x|\theta)f(\theta)}{f_X(x)} = \frac{f(x|\theta)\pi(\theta)}{\int_{\Theta} f_{X|H=\theta}(x|\theta)f_X(\theta)d\theta} \\ &= \frac{f(x|\theta)\pi(\theta)}{\mathcal{E}_{\theta}(f(x|H))}\end{aligned}$$

Introdução

- Portanto, $\pi(\theta|x) \propto f(x|\theta)\pi(\theta)$, em que o símbolo “ \propto ” denota que os membros da relação acima são proporcionais em relação à θ . Isto é, \exists uma constante c que não depende de θ , tal que:

$$\begin{aligned}\pi(\theta|x) &= cf(x|\theta)\pi(\theta) \\ c &= \int_{\Theta} f(x|\theta)\pi(\theta)d\theta\end{aligned}$$

- Especificação do modelo bayesiano: $X|\theta \sim f_X(\cdot|\theta)$.

Introdução

- Exemplo: Seja $X|\theta \sim \text{Bernoulli}(\theta)$, $\theta \in (0, 1)$ e assuma $\theta \sim \text{beta}(\alpha, \beta)$, α e β conhecidos.
- A distribuição a posteriori é dada por:

$$\pi(\theta|x) = \frac{f(x|\theta)\pi(\theta)}{\int_{\Theta} f(x|\theta)\pi(\theta)d\theta}$$

Introdução

- Então,

$$\begin{aligned}\pi(\theta|x) &\propto \theta^x(1-\theta)^{1-x}\theta^{\alpha-1}(1-\theta)^{\beta-1}\mathbb{1}_{(0,1)}(\theta) \\ &= \theta^{x+\alpha-1}(1-\theta)^{\beta-x+1-1}\mathbb{1}_{(0,1)}(\theta)\end{aligned}$$

- Logo, $\theta|X = x \sim \text{beta}(\alpha + x, \beta - x + 1)$.
- Exemplo: Seja X_1, \dots, X_n uma aa de $X|\theta \sim \text{Bernoulli}(\theta)$, encontre a posteriori, sob $\theta \sim \text{beta}(\alpha, \beta)$. Temos que:

$$f_{\mathbf{X}}(\mathbf{x}; \theta) = \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n-\sum_{i=1}^n x_i} \prod_{i=1}^n \mathbb{1}_{\{0,1\}}(x_i)$$

Introdução

- Assim, vem que:

$$\begin{aligned}\pi(\theta|\mathbf{x}) &\propto f(\mathbf{x}|\theta)\pi(\theta) \\ &= \theta^{\sum_{i=1}^n x_i} (1-\theta)^{n-\sum_{i=1}^n x_i} \theta^{\alpha-1} (1-\theta)^{\beta-1} \mathbb{1}_{(0,1)}(\theta) \\ &= \theta^{\alpha+\sum_{i=1}^n x_i-1} (1-\theta)^{\beta+n-\sum_{i=1}^n x_i-1}\end{aligned}\quad (1)$$

que corresponde ao núcleo de uma distribuição (parte que depende de θ) $\text{beta}(\alpha + \sum_{i=1}^n x_i, \beta + n - \sum_{i=1}^n x_i)$. Logo,

$$\theta|\mathbf{x} \sim \text{beta}\left(\alpha + \sum_{i=1}^n x_i, \beta + n - \sum_{i=1}^n x_i\right).$$

Introdução

- Note, portanto, que o “estimador” bayesiano é a própria distribuição a posteriori.
- Por exemplo, dela podemos obter :
 - Estimativas pontuais (média, moda e mediana a posteriori).
 - Intervalo de credibilidade (quantis de interesse).
 - Calcular as probabilidades de ocorrência de hipóteses (testes de hipótese).

Introdução

- Por exemplo, $\hat{\theta}_{EAP} = \mathcal{E}(\theta|\mathbf{X}) = \frac{\alpha + \sum_{i=1}^n X_i}{\alpha + \beta + n}$. Suponha que observemos $x_1 = x_2 = x_3 = 0$ e $\alpha = \beta = 1$. Assim, teríamos $\tilde{\theta}_{MV} = 0$ e $\tilde{\theta}_{EAP} = 1/5$. Qual estimador é melhor?
- No exemplo vimos que $\text{priori}(\text{beta}(\alpha, \beta)) \rightarrow \text{posteriori}(\text{beta}(\alpha^*, \beta^*))$. Ou seja, a priori e a posterior pertencem à mesma família.
- Nesse caso, dizemos que o modelo Bernoulli (verossimilhança) é conjugado ao modelo beta.
- Isto ocorre, nesse caso, porque

$$L(\theta) \propto \theta^{\sum_{i=1}^n x_i} (1 - \theta)^{n - \sum_{i=1}^n x_i}$$

Introdução

- Suponha que a distribuição de \mathbf{X} é dada por:

$$f_{\mathbf{X}}(\mathbf{x}; \boldsymbol{\theta}) = h(\mathbf{x}) \exp \left\{ \sum_{j=1}^k c_j(\boldsymbol{\theta}) t_j + d(\boldsymbol{\theta}) \right\}, \boldsymbol{\theta} \in \Theta \subseteq \mathcal{R}^k$$

em que $\Omega = \{ \mathbf{t} \in \mathcal{R}^{k+1}, w(\mathbf{t}) < \infty \}$, $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)'$,

$\mathbf{t} = (t_1, \dots, t_{k+1})'$ e $w(\mathbf{t}) = \int \exp \left\{ \sum_{j=1}^k c_j(\boldsymbol{\theta}) t_j + t_{k+1} d(\boldsymbol{\theta}) \right\} d\boldsymbol{\theta}$.

Introdução

- Teorema: A família exponencial $k + 1$ paramétrica. Note que:

$$\pi(\boldsymbol{\theta}|\mathbf{t}) \approx \pi(\boldsymbol{\theta}) = \frac{1}{w(\mathbf{t})} \exp \left\{ \sum_{j=1}^k c_j(\boldsymbol{\theta})t_j + t_{k+1}d(\boldsymbol{\theta}) \right\}$$

à priori, é a distribuição conjugada de $f(\mathbf{x}|\boldsymbol{\theta})$ (dado anteriormente),
ou seja: $f(\mathbf{x}|\boldsymbol{\theta}) \rightarrow \pi(\boldsymbol{\theta}) \rightarrow \pi(\boldsymbol{\theta}|\mathbf{x})$

Cont.

- Exemplo: Seja $X|\theta \sim N(\theta, \sigma^2)$, σ^2 conhecido.

$$\begin{aligned}f(x|\theta) &= \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{x^2}{2\sigma^2}\right\} \exp\left\{\frac{\theta x}{\sigma^2} + \frac{\theta^2}{2/\sigma^2}\right\} \\ &= h(x) \exp c_1(\theta)t_1(x) + d(\theta)\end{aligned}$$

em que $c_1(\theta) = \frac{\theta}{\sigma^2}$, $t_1(x) = x$, $d(\theta) = -\frac{\theta^2}{2\sigma^2}$.

- Aplicando o resultado do teorema acima ($k=1$), temos que:

$$\begin{aligned}\pi(\theta|t_1, t_2) &= \frac{1}{w(t_1, t_2)} \exp\left\{\frac{\theta t_1}{\sigma^2} - \frac{\theta^2 t_2}{2\sigma^2}\right\} \\ &= \exp\left\{-\frac{t_2}{2\sigma^2} \left(\theta^2 - 2\frac{t_1}{t_2} \theta + \frac{t_1^2}{t_2}\right) + \frac{t_1^2}{2\sigma^2 t_2}\right\} \\ &\propto \exp\left\{-\frac{t_2}{2\sigma^2} \left(\theta - \frac{t_1}{t_2}\right)^2\right\}\end{aligned}$$

Cont.

- Assim,

$$\theta | t_1, t_2 \sim N\left(\frac{t_1}{t_2}, \frac{\sigma^2}{t_2}\right)$$

- Ou seja, nesse caso a família conjugada é $N(\eta, \sigma^2)$.
- Obs: a) O Teorema anterior também vale sob aa, ou seja, ou seja

$$f_{\mathbf{X}}(\mathbf{x}|\boldsymbol{\theta}) = h(\mathbf{x}) \exp \left\{ \sum_{j=1}^k c_j(\boldsymbol{\theta}) \sum_{i=1}^n t_j(x_i) + nd(\boldsymbol{\theta}) \right\}$$

- Então se,

$$\pi(\boldsymbol{\theta}|\mathbf{t}) = \frac{1}{w(\mathbf{t})} \exp \left\{ \sum_{j=1}^n c_j(\boldsymbol{\theta}) t_j + t_{k+1} d(\boldsymbol{\theta}) \right\}$$

é a distribuição a priori (família conjugada) de $\boldsymbol{\theta}$.

Cont.

- Logo, de acordo com o teorema, a distribuição a posteriori é dada por:

$$\pi(\theta|\mathbf{x}) = \pi\left(\theta \mid t_1 + \sum_{i=1}^n t_1(x_i), t_2 + \sum_{i=1}^n t_2(x_i), \dots, t_{k+1} + n\right)$$

- Exemplo: Seja X_1, \dots, X_n uma aa de $X|\mu \sim N(\mu, \sigma^2)$ com σ^2 , conhecido.
- Seguindo o exemplo anterior, temos que:

$$\pi(\theta|\mathbf{x}) = \pi(\theta \mid t_1 + \sum_{i=1}^n t_i, t_2 + n) \text{ (ou seja)}$$

$$\theta|\mathbf{X} = \mathbf{x} \sim N\left(\frac{t_1 + \sum_{i=1}^n x_i}{t_2 + n}, \frac{\sigma^2}{t_2 + n}\right)$$

Cont.

- Por exemplo,

$$\mathcal{E}(\theta|\mathbf{X}) = \frac{t_1 + \sum_{i=1}^n X_i}{t_2 + n} \text{ (estimador); } \mathcal{E}(\theta|\mathbf{X}) = \frac{t_1 + \sum_{i=1}^n x_i}{t_2 + n} \text{ (estimativa)}$$

- A priori de θ é $N(\eta, \tau^2)$, em que:

$$\eta = \frac{t_1}{t_2}; \tau^2 = \frac{\sigma^2}{t_2} \text{ ou } t_2 = \frac{\sigma^2}{\tau^2} \text{ ou } t_1 = \frac{\eta\sigma^2}{\tau^2}$$

- Dessa forma:

$$\begin{aligned} \mathcal{E}(\theta|\mathbf{X}) &= \frac{\frac{n\sigma^2}{\tau^2} + \sum_{i=1}^n x_i}{\frac{\sigma^2}{\tau^2} + n} = \frac{(\sigma^2/\tau^2)\eta + n\bar{x}}{\frac{\sigma^2}{\tau^2} + n} \\ &= \alpha\eta + \beta\bar{x}, \alpha + \beta = 1 \end{aligned}$$

Cont.

- Exemplo: Sejam X_1, \dots, X_n aa de $X|\sigma^2 \sim N(\theta, \sigma^2)$, θ conhecido. Assim:

$$f_{\mathbf{X}}(\mathbf{x}|\sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta)^2 \right\}$$

- Sejam $\psi = \sigma^2$ e $s = \sum_{i=1}^n (x_i - \theta)^2$. Assim

$$f(\mathbf{x}|\psi) \propto \exp \left\{ -\frac{s}{2\psi} \right\} \psi^{-n/2}$$

- Vamos considerar que a priori de ψ é dada por:

$$\pi(\psi) \propto \psi^{-k/2} \exp \left\{ -\frac{s_0}{2\psi} \right\}$$

em que k e s_0 são conhecidos.

Cont.

- Então se $\lambda = \frac{s_0}{\psi} \rightarrow \psi = \frac{s_0}{\lambda}$. Logo $\frac{d\psi}{d\lambda} = -\frac{s_0}{\lambda^2}$.
- Portanto,

$$\begin{aligned}\pi(\lambda) &\propto \left(\frac{s_0}{\lambda}\right)^{-k/2} e^{-\lambda/2} \frac{s_0}{\lambda^2} \\ &\propto \lambda^{k/2-2} e^{-\lambda/2} = \lambda^{(k-4)/2} e^{-\lambda/2}\end{aligned}$$

- Seja agora, $X \sim \text{gama}(\alpha, 1/\beta)$, $f_X(x) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\beta x}$.
- Se $\alpha = k/2$ e $\beta = 1/2$, então

$$f_x(x) = \frac{1}{2^k \Gamma(k/2)} x^{k/2-1} e^{-x/2}, X \sim \chi_k^2$$

Cont.

- Então, se $\nu = k - 2$, temos que:

$$\pi(\lambda) \propto \lambda^{k/2-1} e^{-\lambda/2} = \lambda^{\nu/2-1} e^{-\lambda/2}, \lambda \sim \chi_{\nu}^2$$

- Note que $\psi = \frac{s_0}{\lambda} \rightarrow \psi \sim \frac{s_0}{\chi_{\nu}^2}$.
- Assim,

$$\pi(\lambda) = f_{\lambda}(\lambda) \frac{d\lambda}{d\psi} \propto \psi^{-(\nu/2-1)} e^{-s_0/\psi}$$

- Ou seja

$$\pi(\psi) = c\psi^{-(\nu/2-1)}e^{-s_0/\psi}, c = \int_0^\infty \psi^{-(\nu/2-1)}e^{-s_0/\psi} d\psi$$

- Portanto, a distribuição a posteriori de ψ é dada por

$$\begin{aligned}\pi(\psi|\mathbf{x}) &\propto f(\mathbf{x}|\psi)\pi(\psi) \propto \psi^{-n/2}e^{-s/2\psi}\psi^{-(\nu/2-1)}e^{-s_0/2\psi} \\ &= \psi^{-(n+\nu)/2-1}e^{-(\psi/2)(s+s_0)}\end{aligned}$$

- Dessa forma: $\psi|\mathbf{X} = \mathbf{x} \sim \frac{s+s_0}{\chi_{n+\nu}^2}$

Cont.

- Logo,

$$\begin{aligned}\mathcal{E}(\psi|\mathbf{X}) &= \frac{s_0 + s}{n + \nu - 2} = \frac{s_0 + \sum_{i=1}^n (x_i - \theta)^2}{n + \nu - 2} \\ &= \frac{s_0}{n + \nu - 2} + \frac{n}{n + \nu - 2} \tilde{\sigma}^2\end{aligned}$$

- em que $\tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \theta)^2$
- Exercício: No exemplo anterior, usando o teorema visto, obtenha a distribuição a priori de σ^2 que seja conjugada com respeito à $N(\theta, \sigma^2)$

Introdução à Teoria da Decisão

- Seja $\mathbf{X} = (X_1, \dots, X_n)'$ um vetor aleatório com fdp $f_{\mathbf{X}}(\cdot|\boldsymbol{\theta})$, $\boldsymbol{\theta} \in \Theta \subseteq \mathcal{R}^k$.
- 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 $d : \mathcal{X} \rightarrow \mathcal{A}$, ($\mathbf{x} \rightarrow d(\mathbf{x})$) que é formulada para se obter informações sobre $\boldsymbol{\theta}$. 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

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

$$\begin{aligned}L(d, \theta) &= L(d(\mathbf{x}), \theta) \\ (\mathcal{D}, \Theta) &\rightarrow \mathcal{R}^+\end{aligned}$$

satisfazendo as seguintes propriedades:

- a) $L(\theta, d) \geq 0, \forall d \in \mathcal{D}, \theta \in \Theta$.
 - a) $L(\theta, d) = 0$, se $d = \theta$.
- Note que considerarmos $d = d(\mathbf{X})$ então $L(d(\mathbf{X}), \theta)$ é uma va.

Exemplos de função de perda

- $L_1 = (d - \theta)^2$ (perda quadrática).
- $L_2 = |d - \theta|$ (perda modular ou perda absoluta).
- $L_3 = \begin{cases} 1, & \text{se } |d - \theta| > \epsilon, \epsilon > 0 \\ 0, & \text{se } |d - \theta| \leq \epsilon \end{cases}$ (perda (0-1)).
- $L_4 = \begin{cases} A, & \text{se } |d - \theta| > \epsilon, \epsilon > 0 \\ 0, & \text{se } |d - \theta| \leq \epsilon \end{cases}$ (perda (0 - A)).
- $L_5 = \rho(\theta)|d - \theta|^r, \rho(\theta) \geq 0, \forall \theta, r > 0$ (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

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

- Exemplo [Erro quadrático médio (frequentista)]: $\mathcal{E}_{\mathbf{X}|\theta}[(d(\mathbf{X}) - \theta)^2]$.
- Em geral, na inferência frequentista, busca-se o estimador que minimiza o risco acima definido (restrito à uma determinada subclasse de estimadores).

Perda esperada (risco frequentista)

- Obs: Se $L(\theta, d) = (\theta - d)^2$, então

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

- Exemplo: Seja X_1, \dots, X_n uma aa de $X \sim N(\mu, \sigma^2)$ e considere a classe de estimadores de σ^2 dada por $d_b(\mathbf{X}) \equiv \hat{S}_b = bS^2$, em que $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ e b é constante.
- Temos que: $\mathcal{E}(S^2) = \sigma^2$, $\mathcal{V}(S^2) = \frac{2\sigma^4}{n-1}$. Seja

$$\begin{aligned}R(\theta, \hat{S}_b) &= R(\sigma^2, \hat{S}_b) = \mathcal{V}_{\sigma^2}(\hat{S}_b) + \left[\mathcal{E}_{\sigma^2}(\hat{S}_b - \sigma^2)^2 \right] \\ &= \frac{2b^2\sigma^4}{n-1} + (b\sigma^2 - \sigma^2)^2 = \frac{2b^2\sigma^4}{n-1} + (b-1)^2\sigma^4 = g(b)\end{aligned}$$

Perda esperada (risco frequentista)

- Portanto, o estimador da classe \hat{S}_b que tem menor risco (considerando perda quadrática) é dado por:

$$\hat{S}_b = \frac{n-1}{n+1} S^2 = \frac{1}{n+1} \sum_{i=1}^n (X_i - \bar{X})^2$$

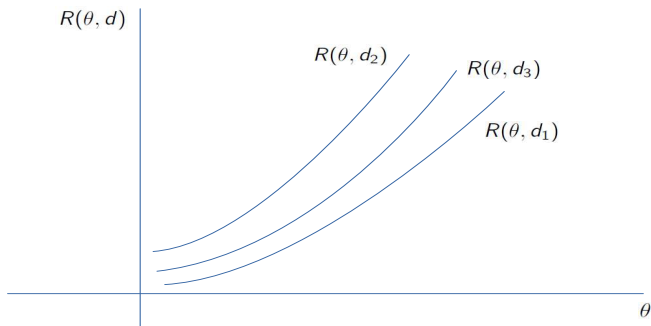
- Obs: considere as decisões:

$$d_1(\mathbf{X}) = \frac{n-1}{n+1} S^2(R(\theta, d_1)),$$

$$d_2(\mathbf{X}) = S^2(R(\theta, d_2)),$$

$$d_3(\mathbf{X}) = \hat{\sigma}^2(R(\theta, d_3))$$

Compar. de riscos (n=5, veja também Casella & Berger (2006))



Perda esperada (risco frequentista)

- Considere agora a função perda (Exercício: mostre que é uma função perda):

$$L(\theta, d) = \frac{d}{\sigma^2} - 1 - \ln\left(\frac{d}{\sigma^2}\right)$$

- Então

$$\begin{aligned}R(\sigma^2, \hat{S}_b) &= \mathcal{E}_{\mathbf{X}|\sigma^2} \left(\frac{\hat{S}_b}{\sigma^2} - 1 - \ln \frac{\hat{S}_b}{\sigma^2} \right) \\&= \frac{b}{\sigma^2} \mathcal{E}_{\mathbf{X}|\sigma^2}(S^2) - 1 - \ln(b) + \mathcal{E} \left(-\ln \frac{S^2}{\sigma^2} \right) \\&\rightarrow g(b) = b - 1 - \ln(b) + \mathcal{E} \left(-\ln \frac{S^2}{\sigma^2} \right) \\&\rightarrow \frac{\partial g(b)}{\partial b} = 1 - \frac{1}{b} = 0 \leftrightarrow b = 1\end{aligned}$$

Perda esperada (risco frequentista)

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

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

$R(\theta, d_1) < R(\theta, d_2)$, 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

- O risco de Bayes é definido como a perda média do risco frequentista, à priori, em relação à θ , ou seja

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

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

Risco de Bayes (cont.)

- Note que

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

Risco à posteriori (ou integrado)

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

$$r(\pi, d^\pi) = \inf_{d \in \mathcal{D}} r(\pi, d) \quad (2)$$

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

Risco à posteriori

- Obs: Segundo a definição acima, pode ocorrer que:
 - Não exista d^π em \mathcal{D} que satisfaça (2).
 - Pode existir mais de um estimador de Bayes.
- A priori não precisa ser uma distribuição de probabilidade, tampouco ser própria ($\int_{\Theta} \pi(\theta) d\theta = \infty$).

Estimadores Bayesianos associados à funções de perda específicas

- O estimador EAP é o estimador de Bayes para a função de perda $L_1 = (d - \theta)^2$.
- O estimador MeAP (mediana a posteriori) é o estimador de Bayes para a função de perda $L_2 = |d - \theta|$, em que A é uma constante.
- O estimador MAP (moda a posteriori) é o estimador de Bayes para a função de perda $L_4 = \begin{cases} A, & \text{se } |d - \theta| > \epsilon, \epsilon > 0 \\ 0, & \text{se } |d - \theta| \leq \epsilon \end{cases}$

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

- Queremos minimizar $g(d) = \int_{\Theta} (d - \theta)^2 \pi(\theta|\mathbf{x}) d\theta$ em relação à d .
Por outro lado, note que:

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

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

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

- Obs: Se $\tau(\theta)$ é uma função de θ com distribuição a priori $\pi(\cdot)$, então, sob perda quadrática, o estimador de Bayes é

$$d^\pi(\mathbf{X}) = \mathcal{E}(\tau(\theta)|\mathbf{X} = \mathbf{x}).$$

Exemplo

- Seja X_1, \dots, X_n uma aa de $X|\theta \sim \text{Poisson}(\theta)$, com $\theta \sim \text{gamma}(a, 1/b)$ (família conjugada).
- Temos que

$$\begin{aligned}\pi(\theta|\mathbf{x}) &\propto f(\theta|\mathbf{x})\pi(\theta) \\ &= e^{-n\theta} \theta^{n\bar{x}} \theta^{a-1} e^{-b\theta} \\ &= \theta^{\sum_{i=1}^n x_i + a - 1} e^{-(n+b)\theta} \mathbf{1}_{(0, \infty)}(\theta)\end{aligned}$$

- Assim, $\theta|\mathbf{X} = \mathbf{x} \sim \text{gama}(\sum_{i=1}^n x_i + a, 1/(n + b))$. Logo,

$$\mathcal{E}(\theta|\mathbf{X}) = \frac{n\bar{X}}{b+n} + \frac{a}{b+n}$$

Exemplo

- Qual seria o estimador de Bayes, de $\tau(\theta) = \theta^2$, sob perda quadrática? Temos que

$$\begin{aligned}\mathcal{E}(\theta^2|\mathbf{X}) &= \mathcal{V}(\theta|\mathbf{X}) + E^2(\theta|\mathbf{X}) \\ &= \frac{\sum_{i=1}^n X_i + a}{(n+b)^2} + \left[\frac{n\bar{X}}{b+n} + \frac{a}{b+n} \right]^2 \\ &= \frac{\sum_{i=1}^n X_i + a}{(n+b)^2} \left(1 + \sum_{i=1}^n X_i + a \right)\end{aligned}$$

Exemplo

- Função de Risco frequentista. Temos que : $d^\pi(\mathbf{X}) = \frac{\sum_{i=1}^n X_i + a}{(b+n)}$ (sob perda quadrática). Assim

$$\begin{aligned}R(\theta, d^\pi) &= \mathcal{E} \left[\left(\frac{\sum_{i=1}^n X_i + a}{b+n} - \theta \right)^2 \right] \\&= \mathcal{V} \left(\frac{\sum_{i=1}^n X_i + a}{b+n} \right) + \left[\mathcal{E} \left(\frac{\sum_{i=1}^n X_i + a}{b+n} \right) - \theta \right]^2 \\&= \frac{n\theta}{(n+b)^2} + \left(\frac{a-b\theta}{b+n} \right)^2 = \frac{n\theta + a^2 - 2ab + b^2 - \theta^2}{(n+b)^2} \\&= \frac{1}{(n+b)^2} [a^2 + b^2\theta^2 + (n-2ab)\theta]\end{aligned}$$

Exemplo

- Cont.:

$$\begin{aligned} R(\theta, d^\pi) &= \mathcal{E}QM_\theta(d^\pi) = \frac{1}{(n+b)^2/n} \left[\frac{a^2}{n} + \frac{b^2\theta^2}{n} + \frac{(1-2ab)\theta}{n} \right] \\ &= \frac{1}{\left(\frac{b}{\sqrt{n}} + \sqrt{n}\right)^2} \left[\frac{a^2}{n} + \frac{b^2\theta^2}{n} + \frac{(1-2ab)\theta}{n} \right] \end{aligned}$$

- Logo, $\lim_{n \rightarrow \infty} R(\theta, d^\pi) = 0$.
- Assim, $d^\pi(\mathbf{X})$ é um estimador consistente.

Exemplo

- Risco de Bayes: temos que:

$$\begin{aligned}r(\pi, d^\pi) &= \int_{\Theta} R(\theta, d^\pi) \pi(\theta) d\theta = \mathcal{E}_\theta (R(\theta, d^\pi)) \\ &= \frac{1}{(b+n)^2} (a^2 + b^2 \mathcal{E}(\theta^2) + (n-2ab) \mathcal{E}(\theta)) \\ &= \frac{1}{(b+n)^2} \left(a^2 + b^2 \left(\frac{a}{b^2} + \frac{a^2}{b^2} \right) + (n-2ab) \frac{a}{b} \right) \\ &= \frac{a}{(b+n)^2} \left(1 + \frac{n}{b} \right) = \frac{a}{b(b+n)}\end{aligned}$$

Teorema

- Seja \mathbf{X} um vev com fdp $f_{\mathbf{X}}(\cdot) | \theta, \theta \in \Theta \subseteq \mathcal{R}^k$ e \mathbf{T} uma estatística suficiente para θ . Se $\pi(\cdot)$ é a priori para θ , o estimador de Bayes de θ é função de \mathbf{t} , isto é:

$$d^\pi = G(\mathbf{T}(\mathbf{X}))$$

- Exercício: demonstre que a posteriori também depende de \mathbf{T} .
- Exemplo: Seja X_1, \dots, X_n uma aa de $X \sim N(\theta, \sigma^2)$ e $\theta \sim N(\mu, \tau^2)$, com σ^2, μ, τ^2 conhecidos. Considerando perda quadrática, temos que:

$$d^\pi(\mathbf{X}) = \mathcal{E}(\theta | \mathbf{X}) = \frac{\tau^2}{\tau^2 + \frac{\sigma^2}{n}} \bar{X} + \mu$$

Procedimento Minimax

- Dizemos que d^* é uma regra (estimador) minimax se

$$\sup_{\theta \in \Theta} R(\theta, d^*) = \inf_{d \in \mathcal{D}} \sup_{\theta \in \Theta} R(\theta, d) \text{ ou}$$

$$\sup_{\theta \in \Theta} R(\theta, d^*) \leq \sup_{\theta \in \Theta} R(\theta, d), \forall d \in \mathcal{D}$$

- Teorema: Suponhamos que d^π é um estimador de Bayes e

$$R(\theta, d^\pi) \leq r(\pi, d^\pi), \forall \theta \in \Theta.$$

Então d^π é uma regra (estimador) minimax.

- Teorema: Seja π uma priori para θ e d^π o estimador de Bayes tal que $R(\theta, d^\pi)$ não depende de θ . Então d^π é um estimador minimax.

Procedimento Minimax

- Exemplo: Seja X_1, \dots, X_n uma aa de $X \sim \text{Bernoulli}(\theta)$, $\theta \sim \text{beta}(a, b)$ (a, b) conhecidos e considere a perda quadrática. Obtenha o estimador minimax.
- Temos que (estimador de Bayes):

$$d^\pi = \frac{n\bar{X} + a}{n + a + b}$$

Procedimento Minimax

- Neste caso, temos que

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

Procedimento Minimax

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

$$R(\theta, d^\pi) = \frac{1}{4(1 + \sqrt{n})^2} e$$
$$d^\pi = \frac{n\bar{X} + \sqrt{n}/2}{n + \sqrt{n}}$$

Conjuntos (intervalos) de credibilidade

- Def: um conjunto de credibilidade de nível $\gamma = 1 - \alpha$ é um subconjunto C de Θ , ($C \subseteq \Theta$), tal que:

$$P(\theta \in C | \mathbf{x}) \geq 1 - \alpha$$

em que

$$P(\theta \in C | \mathbf{x}) = \begin{cases} \sum_{\theta \in C} \pi(\theta | \mathbf{x}), & \text{se } \theta \text{ for discreto} \\ \int_C \pi(\theta | \mathbf{x}) d\theta, & \text{se } \theta \text{ for contínuo} \end{cases}$$

- Seja $\Theta \subseteq \mathcal{R}^k$, então um “boa” região de credibilidade é um subconjunto C de Θ que tem o menor “tamanho” (comprimento, área, volume). Por exemplo, se $\Theta \subseteq \mathcal{R}$ e $C = [L, S]$, então C é um “bom” intervalo de credibilidade se tiver menor comprimento possível.

Conjuntos (intervalos) de credibilidade

- Se $\Theta \subseteq \mathcal{R}$, então podemos ter as seguintes situações:
 - i) $C = [L, S]$.
 - ii) $C = [a, S]$.
 - iii) $C = [L, b]$.

em que a e b são, respectivamente, o limite inferior e superior do espaço paramétrico.

- Usualmente, no caso acima, calculamos

$$P(t_1(\mathbf{x}) \leq \theta \leq t_2(\mathbf{x}) | \mathbf{x}) \geq \gamma$$

- Exemplo: Seja X_1, \dots, X_n uma aa de $X \sim \text{Poisson}(\theta)$ e $\theta \sim \text{gama}(a, 1/b)$. Então $\theta | \mathbf{x} \sim \text{gama}(a + \sum_{i=1}^n x_i, 1/(n + b))$ (exercício).

Conjuntos (intervalos) de credibilidade

- Portanto, $2(n+b)\theta | \mathbf{x} \sim \chi^2_{2(a+\sum_{i=1}^n x_i)}$.
- Desse modo temos que:

$$P(q_1 \leq 2(n+b)b\theta \leq q_2) = 1 - \alpha = \gamma$$
$$P\left(\frac{q_1}{2(n+b)} \leq \theta \leq \frac{q_2}{2(n+b)}\right) = 1 - \alpha = \gamma$$

- Portanto, $IC_B[\theta, \gamma] = \left[\frac{q_1}{2(n+b)}, \frac{q_2}{2(n+b)}\right]$, em que $P(Y < q_1) = \frac{\alpha}{2}$, $P(Y > q_2) = \frac{\alpha}{2}$, $Y \sim \chi^2_{2(a+\sum_{i=1}^n x_i)}$.

Testes de hipótese

- Considere as hipóteses $H_0 : \theta \in \Theta_0$ vs $H_1 : \theta \in \Theta_1 = \Theta_0^c$. Então, do ponto de vista clássico (frequentista), a mensuração da qualidade é feita em termos dos erros do tipo I e II e a decisão é tomada de acordo com as prioridades da região crítica (embora também se possa avaliar a qualidade dos testes bayesianos através de critérios frequentistas).
- Do ponto de vista Bayesiano, temos que decidir entre H_0 e H_1 considerando as informações a priori de $\theta(\pi(.))$ e a distribuição a posteriori $\theta(\pi(.|\mathbf{x}))$.
- Dada a distribuição a posteriori, podemos calcular, por exemplo:

$$P(H_0|\mathbf{x}) = P(\theta \in \Theta_0|\mathbf{x}) = P(H_0 \text{ é verdadeira}|\mathbf{x})$$

$$P(H_1|\mathbf{x}) = P(\theta \in \Theta_1|\mathbf{x}) = P(H_1 \text{ é verdadeira}|\mathbf{x})$$

Testes de hipótese

- Podemos, assim, rejeitar H_0 se $\frac{P(H_1|\mathbf{x})}{P(H_0|\mathbf{x})} \geq c$, $c \in (0, \infty)$, em que c deve ser escolhido de forma conveniente.
- Em termos dos conceitos de testes de hipóteses frequentistas a RC é da forma

$$RC = \{\mathbf{x} \in \mathcal{X} : P(\theta \in \Theta_0^c | \mathbf{x}) \geq c\}$$

- Consequentemente, $RC^c = \{\mathbf{x} \in \mathcal{X} : P(\theta \in \Theta_0^c | \mathbf{x}) < c\}$
- Essencialmente, a abordagem acima é útil para testar hipóteses do tipo $\theta \leq (<) \theta_0$, $\theta \geq (>) \theta_0$, $\theta \in (\theta_0, \theta_1)$, $\theta \leq (<) \theta_0$ ou $\theta \geq (>) \theta_1$.

Testes de hipótese

- Para outras formas de testar hipóteses (do ponto de vista bayesiano) e para hipóteses precisas ($\theta = \theta_0$) veja [aqui](#).
- Exemplo: Seja X_1, \dots, X_n uma aa de $X \sim N(\theta, \sigma^2)$ e $\theta \sim N(\mu, \tau^2)$, com μ, τ^2, σ^2 conhecidos. Considere as hipóteses: $H_0 : \theta \leq \theta_0$ vs $H_1 : \theta > \theta_0$.
- Neste caso, temos que: $\theta | \mathbf{X} = \mathbf{x} \sim N((1 - \eta)\bar{x} + \eta\mu, \eta\tau^2)$,
$$\eta = \frac{\sigma^2}{\eta\tau^2 + \tau^2}.$$

Testes de hipótese

- Por outro lado, não se rejeita H_0 se

$$\begin{aligned}P(\theta \in \Theta_0 | \mathbf{x}) \geq c &= P(\theta \leq \theta_0 | \mathbf{x}) \geq c \\&= \Phi\left(\frac{\theta_0 - (1 - \eta)\bar{x} - \eta\mu}{\sqrt{n\tau}}\right) \geq c \\&= \frac{\theta_0 - (1 - \eta)\bar{x} - \eta\mu}{\sqrt{n\tau}} \geq \Phi^{-1}(c) \\&= -\bar{x} \geq \frac{-\theta_0 + \eta\mu}{1 - \eta} + \Phi^{-1}(c) \\&\rightarrow \bar{x} \leq \frac{\theta_0 - \eta\mu}{1 - \eta} + \Phi^{-1}(c)\end{aligned}$$

- Assim, a RC é dado por:

$$RC = \left\{ \mathbf{x} \in \mathcal{R}^n : \bar{x} > \frac{\theta_0 - \eta\mu}{1 - \eta} + \Phi^{-1}(c) \right\}$$