


Influência subjetiva

Motivação nas Exatas: (Teorema de Bayes) : Sejam A e B dois eventos desde a identidade $P(A)P(B/A) = P(B)P(A/B)$ resulta a forma

$$P(B/A) = \frac{P(A/B) \cdot P(B)}{P(A)} \quad \& \quad P(A) > 0.$$

Interpretação : Se B é o evento de interesse ; B tem uma probabilidade de acontecer : $P(B)$. Numo segundo etapa : A acontece com probabilidade $P(A)$ então a probabilidade de acontecer B (evento de interesse) muda para $P(B/A)$



O teorema de Bayes pode ser interpretado como um mecanismo de atualização de probabilidades, conforme a mudança de informação.

Observação : a probabilidade ^{atual} de acontecer de B : $P(B/A)$ cresce em relação à probabilidade _{antiga} de acontecer de B : $P(B)$

Sempre que $P(A/B) > P(A)$.

Generalizando o teorema de Bayes:

Sejam B_1, B_2, \dots eventos mutuamente exclusivos e exaustivos

Então $P(B_r|A) = \frac{P(A|B_r) \cdot P(B_r)}{P(A)}$

$$P(B_r|A) = \frac{P(A|B_r)}{\sum_{s=1}^{\infty} P(A|B_s) \cdot P(B_s)} \cdot P(B_r)$$

Ja que $P(A) = \sum_{s=1}^{\infty} P(A|B_s) P(B_s)$ (Teorema da probabilidade total).

Observação: a probabilidade $P(B_r|A)$ (logo de A ter acontecido com probabilidade $P(A)$) cresce em relação a $P(B_r)$ sempre q'

$$P(A|B_r) > \sum_{s=1}^{\infty} P(A|B_s) P(B_s)$$

— o —

Verossimilhança : lembrando o teorema de Bayes: $P(B|A) = \frac{P(A|B)}{P(A)} P(B)$
Sabendo q' o evento de interesse e' B, a probabilidade $P(A|B)$ e' conhecida como Verossimilhança de B dado A

Priori : corresponde ao valor $P(B)$ ou assignação de probabilidades feita sem vinculo ao evento A.

Posteriori : representada pelo valor $P(B|A)$. Atualização de probabilidades logo de ter sido incorporado o evento A.

desde o Teorema de Bayes: se desejamos fazer inferências de θ , baseados na informação do dado x

$$dF(x) dF(\theta|x) = dF(x; \theta) = dF(\theta) dF(x|\theta)$$

$$dF(\theta|x) = \frac{dF(x|\theta)}{dF(x)} \cdot dF(\theta)$$

logo tendo as distribuições (contínuas ou discretas) correspondentes, resulta

$$f(\theta|x) = \frac{f(x|\theta) \cdot f(\theta)}{f(x)}$$

$$f(\theta|x) = \frac{f(x|\theta) \cdot f(\theta)}{\int f(\theta) f(x|\theta) d\theta}$$

Em geral como o dado x é conhecido então $f(x)$ é cte logo utilizamos a notação

$$f(\theta|x) \propto f(x|\theta) f(\theta)$$

onde f pode denotar uma densidade ou uma probabilidade pontual.

Exemplo: Seja x o número de sucessos numa série de n realizações com probabilidade de sucesso θ em cada uma delas. Isto é, x possui densidade binomial dado θ .

$$f(x|\theta) = \binom{n}{x} \theta^x (1-\theta)^{n-x} \quad x=0, 1, \dots, n$$

lembre q' dado x é fixo, ou seja x é igual a algum dos valores $0, 1, \dots, n$. (Na realização do experimento)

$f(x|\theta)$ é a verossimilhança de θ dado o x .

Consideremos θ com uma distribuição beta (p, q)

$$f(\theta) = \frac{1}{B(p, q)} \theta^{p-1} (1-\theta)^{q-1} \quad ; \quad 0 \leq \theta \leq 1$$

p e q são conhecidos (> 0)
 e $B(p, q) = \int_0^1 \theta^{p-1} (1-\theta)^{q-1} d\theta$.

$f(\theta)$ é a priori para θ .

Pelo teorema de Bayes $f(\theta/x) = \frac{f(x|\theta) \cdot f(\theta)}{f(x)}$ onde

$$f(x) = \int f(x|\theta) f(\theta) d\theta$$

Calculando $f(x) = \int f(x|\theta) f(\theta) d\theta = \int_0^1 \binom{n}{x} \theta^x (1-\theta)^{n-x} \cdot \frac{1}{B(p, q)} \theta^{p-1} (1-\theta)^{q-1} d\theta$

$$= \binom{n}{x} \frac{1}{B(p, q)} \int_0^1 \theta^{p+x-1} (1-\theta)^{n+q-x-1} \cdot d\theta$$

$$f(x) = \binom{n}{x} \frac{1}{B(p, q)} \cdot B(p+x; n+q-x)$$

finalmente $f(\theta/x) = \frac{f(x|\theta) f(\theta)}{f(x)} = \frac{\binom{n}{x} \theta^x (1-\theta)^{n-x}}{\binom{n}{x} \frac{B(p+x; n+q-x)}{B(p, q)}} \cdot \frac{1}{B(p, q)} \theta^{p-1} (1-\theta)^{q-1}$

$$= \frac{\theta^x (1-\theta)^{n-x} \cdot \theta^{p-1} (1-\theta)^{q-1}}{B(p+x; n+q-x)}$$

$$f(\theta/x) = \frac{\theta^{p+x-1} (1-\theta)^{n+q-x-1}}{B(p+x; n+q-x)}$$

logo $f(\theta/x)$ é uma beta $(p+x; n+q-x)$

Inferência : θ tinha uma densidade Beta (p, q) p e q contados > 0 .
 uma experiência foi desenvolvida. e θ a posteriori (da experiência) tem
 uma densidade Beta ($p+x; n+q-x$)

* Verossimilhança: $\frac{\partial}{\partial \theta} \ln f(x|\theta) \propto \frac{\partial}{\partial \theta} \left\{ \ln(\theta^x) + \ln((1-\theta)^{n-x}) \right\}$

$$= \frac{x}{\theta} - \frac{(n-x)}{1-\theta} = \frac{x - x\theta - n\theta + x\theta}{\theta(1-\theta)}$$

$$= \frac{x - n\theta}{\theta(1-\theta)} = 0 \quad \text{se } x = n\theta$$

ou $\hat{\theta}_{MV} = \frac{x}{n}$

a Verossimilhança fornece ao valor de θ : $\hat{\theta}_{MV} = \frac{x}{n}$

* Priori : $f(\theta) \propto \theta^{p-1} (1-\theta)^{q-1}$: cálculo do valor de maior densidade

$$\frac{\partial f(\theta)}{\partial \theta} \propto (p-1)\theta^{p-2} \cdot (1-\theta)^{q-1} + \theta^{p-1} \cdot (q-1)(1-\theta)^{q-2} \cdot (-1)$$

$$= \theta^{p-2} \cdot (1-\theta)^{q-2} \cdot \left\{ (p-1)(1-\theta) - (q-1)\theta \right\} = 0 \quad \text{não trivial } (\theta \neq \frac{0}{1})$$

se $(p-1)(1-\theta) = (q-1)\theta$

$$(p-1) - \theta(p-1) = (q-1)\theta$$

$$p-1 = (q-1 + p-1)\theta$$

$$p-1 = (q+p-2)\theta$$

$$\theta_{Pri} = \frac{p-1}{q+p-2} \quad \text{Modo da priori}$$

a priori fornece ao valor $\theta = \frac{p-1}{q+p-2}$

* posteriori : $f(\theta/x)$ e' beta ($p+x ; n+q-x$)


por analogia com a conta anterior ; a moda neste caso e'

$$\theta = \frac{p+x-1}{p+x+n+q-x-2} = \frac{p+x-1}{n+p+q-2} = \theta_{pos}$$

Moda da posteriori.

$$\theta_{pos} = a \cdot \hat{\theta}_{MV} + (1-a) \theta_{pri} \quad \text{onde } a = \frac{n}{n+p+q-2}$$


Em relação ao θ a distribuição à posteriori tem toda a informação necessária para fazer algum tipo de inferência de θ : resumos como a média, moda (θ_{pos}), variância servem para recuperar a informação em si "codificada" pela posteriori $f(\theta/x)$.



A distribuição à posteriori contém toda a informação relativa ao θ . Resumidos simples média, mediana, moda, ... poderão responder (pontualmente) perguntas pontuais.

informação vs dispersão

dispersão grande \rightarrow informação fraca
" pequena \rightarrow " forte



Procuramos q' os dados permitam fabricar uma posteriori de dispersão pequena (redução da incerteza)

Força da informação = $\frac{1}{Var}$ = precisão

(de a precisão é grande a Var é pequena logo a informação forte)

Quando a Inf Bayesiana é simples e qdo não:

a) facil: a) ponto $x_1 \dots x_n \sim N(\mu, \sigma^2)$
 μ desconhecido, σ^2 conhecido.

$$f(x_i | \mu) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma^2}\right)$$

$$L = \prod_{i=1}^n f(x_i | \mu) = \frac{1}{(2\pi)^{n/2} \cdot \sigma^{n \cdot 2}} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right\}$$

$$= \frac{1}{(2\pi)^{n/2} \cdot \sigma^{2n}} \exp\left\{-\frac{1}{2\sigma^2} \left[\sum_{i=1}^n x_i^2 - 2\mu \sum_{i=1}^n x_i + n\mu^2\right]\right\}$$

$$= \frac{1}{(2\pi)^{n/2} \cdot \sigma^{2n}} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n x_i^2 + \frac{2\mu}{2\sigma^2} \sum_{i=1}^n x_i - \frac{\mu^2 n}{2\sigma^2}\right\}$$

(σ^2 conhecido)

$$\propto \exp\left\{\frac{\mu}{\sigma^2} n\bar{x} - \frac{\mu^2 n}{2\sigma^2}\right\} = \exp\left\{-\frac{n}{2\sigma^2} (\mu^2 - 2\mu\bar{x})\right\}$$

veja que $(\mu - \bar{x})^2 = \mu^2 - 2\mu\bar{x} + \bar{x}^2$

$$\propto \exp\left\{-\frac{n}{2\sigma^2} (\mu^2 - 2\mu\bar{x} + \bar{x}^2)\right\} = \exp\left\{-\frac{n}{2\sigma^2} (\mu - \bar{x})^2\right\}$$

ie $f(x_1, \dots, x_n | \mu) \propto \exp\left(-\frac{n}{2\sigma^2} [\mu - \bar{x}]^2\right)$

se consideramos a priori $f(\mu) \propto \exp\left\{-\frac{1}{2\gamma}(\mu-m)^2\right\}$

$$\Rightarrow \Pi(\mu | x_1, \dots, x_n) \propto \exp\left\{-\frac{1}{2\gamma}(\mu-m)^2 - \frac{n}{2\sigma^2}(\mu-\bar{x})^2\right\}$$

temos

$$-\frac{1}{2\gamma}[\mu^2 - 2\mu m + m^2] - \frac{n}{2\sigma^2}[\mu^2 - 2\mu\bar{x} + \bar{x}^2] \propto$$

$$= \left(\frac{1}{2\gamma} + \frac{n}{2\sigma^2}\right)\mu^2 + 2 \cdot \mu \left[\frac{m}{2\gamma} + \frac{n\bar{x}}{2\sigma^2}\right]$$

$$= -\frac{1}{2} \left[\frac{1}{\gamma} + \frac{n}{\sigma^2}\right]\mu^2 + 2 \cdot \frac{1}{2} \mu \left[\frac{m}{\gamma} + \frac{n\bar{x}}{\sigma^2}\right]$$

$$= -\frac{1}{2} \left[\frac{1}{\gamma} + \frac{n}{\sigma^2}\right] \left\{ \mu^2 - 2\mu \cdot \frac{\left(\frac{m}{\gamma} + \frac{n\bar{x}}{\sigma^2}\right)}{\left(\frac{1}{\gamma} + \frac{n}{\sigma^2}\right)} \right\}$$

$$V^* = \left(\frac{1}{\gamma} + \frac{n}{\sigma^2}\right)^{-1}; \quad m^* = \frac{\left(\frac{m}{\gamma} + \frac{n\bar{x}}{\sigma^2}\right)}{\left(\frac{1}{\gamma} + \frac{n}{\sigma^2}\right)}$$

posteriori com medio m^* e Var V^* .

Ver que ocorre qdo $n \rightarrow \infty$ com m^*

$$V^* = \frac{1}{\frac{1}{\gamma} + \frac{n}{\sigma^2}} \xrightarrow[n \rightarrow \infty]{} 0; \quad \left(\text{L'Hopital em } m^*\right) m^* \xrightarrow[n \rightarrow \infty]{} \frac{\bar{x}/\sigma^2}{1/\sigma^2} = \bar{x}$$

b). modulado:

Considere a priori no problema anterior logística

$$f(\mu) \propto \exp(p \cdot \mu) \cdot (1 + \exp(\mu))^{-p+q}$$

ie $\pi(\mu/x)$ não tem forma fechada.

obs
 → por x tratar de μ por um μ
 basta a integração numérica.