

## Teoria da Decisão: NEYMAN-PEARSON e BAYES

### 1- Introdução

Teoria da Decisão é uma extensão das teorias de testes de hipóteses e estimação, e permite modelar situações nas quais as teorias clássicas são inadequadas.

Os elementos da Teoria da Decisão são muito semelhantes aos da teoria matemática dos jogos desenvolvida por Von Neumann e Morgenstern (1944) mas, para finalidades estatísticas, um dos “jogadores” é a própria natureza (ao invés de um “jogador” propriamente dito) e que “age” através de uma experiência aleatória.

A análise Bayesiana e a Teoria da Decisão fornecem visões unificadas da Estatística, e torna-se bastante natural pensar nas duas em conjunto. No entanto, grande parte das respectivas teorias desenvolveu-se em separado. No lado Bayesiano, houve a expansão da teoria de inferência estatística (subjéctiva e objectiva) e o reconhecimento de que a análise estatística deve ser encarada condicionalmente (ou seja, os dados observados devem ser tratados como **conhecidos**). Este desenvolvimento ocorreu mesmo sem a incorporação formal da função de perda à análise.

Por outro lado, existem contribuições importantes à teoria da decisão feitas por estatísticos frequentistas (por exemplo, Wald). Na Teoria da Decisão frequentista evita-se a utilização formal de distribuições a priori.

**Aqui adotaremos na maior parte do tempo o paradigma Bayesiano para introduzir as idéias de Teoria da Decisão.**

#### ***Quais os elementos fundamentais num problema de teoria de decisão?***

- 1) Um conjunto não vazio  $\Theta$  de possíveis estados da natureza  $\theta$  (o espaço paramétrico), a partir dos quais decisões devem ser tomadas;
- 2) Um conjunto não vazio  $A$  de TODAS as possíveis decisões que podem ser tomadas;
- 3) Uma função perda  $L$  que determina a perda  $L(\theta, a)$  sofrida pelo indivíduo quando ele toma a ação  $a$  (que é uma função do resultado observado da experiência aleatória) e do real estado da natureza  $\theta$ . Esta perda é expressa como um número real (cuja interpretação física é uma perda monetária).

Um **problema de decisão estatística** é um jogo  $(\Theta, A, L)$  acoplado a uma experiência aleatória cujo resultado  $x$  tem densidade  $p(x|\theta)$  que depende de um dos “estados da natureza”  $\theta$  no espaço paramétrico  $\Theta$ .

Em termos práticos, a ação( ou decisão)  $\underline{a}$  geralmente indica o valor da estimativa usada para o parâmetro  $\theta$ .

Suponha que, com base no resultado  $x$  da experiência aleatória, o estatístico escolha uma ação  $\underline{a}$ ,  $a = T(x)$ , que resulta numa perda  $L(\theta, a)$ .

### Definição 1.1.

Pode-se calcular o **valor esperado da função perda** sobre todos os resultados possíveis da experiência, o que nos dá:

$$R(\theta, T) = E\{L(\theta, T(x))\} = \int L(\theta, T(x))p(x|\theta)dx \quad (1)$$

A integral (1) depende do verdadeiro estado da natureza  $\theta$  e da forma da função  $T(x)$ , que serve para determinar que decisão será tomada uma vez observado o resultado da experiência aleatória.

$R(\theta, T)$  definido pela equação (1) é chamado de **função risco**.

### Um problema potencial...

- A integral (1) pode não existir, mas iremos ignorar este caso!
- Definiremos uma **regra de decisão** ou **função de decisão** como qualquer função  $T$  para a qual  $R(\theta, T)$  existe e é finita para todo  $\theta \in \Theta$ .

A escolha da função perda e, conseqüentemente, o cálculo do risco a ela associado é, até certo ponto arbitrária. Existem algumas escolhas “naturais” (ou, pelo menos, mais comuns), como as funções perda quadrática e erro absoluto. Entretanto, estas não são as únicas funções possíveis.

Algumas escolhas usuais para a função perda são:

<b>Função perda quadrática</b>	$L(\theta, a) = (\theta - a)^2$
<b>Função perda erro absoluto</b>	$L(\theta, a) =  \theta - a $
<b>Função perda erro quadrático ponderado</b>	$L(\theta, a) = w(\theta).(\theta - a)^2$
<b>Função perda 0-1</b>	$L(\theta, a) = \begin{cases} 0 & \text{se } \theta = a \\ 1 & \text{se } \theta \neq a \end{cases}$

Agora suponha que temos crenças prévias sobre o estado da natureza, expressas na forma de uma distribuição a priori  $\pi(\theta)$ . O **risco de Bayes**  $r(T)$  da regra de

decisão  $T$  é definido como o valor esperado de  $R(\theta, T)$  para todos os possíveis estados da natureza  $\theta$ .

### Definição 1.2. (Risco de Bayes)

$$r(T) = E\{R(\theta, T)\} = \int R(\theta, T)\pi(\theta)d\theta$$

$r(T)$  é um número real, e portanto pode-se comparar dois estimadores com base nos seus respectivos riscos de Bayes, preferindo aquele com o menor risco, isto é, estabelecer uma regra de decisão.

#### Uma idéia....

#### Que tal minimizar as perdas através da minimização do risco de Bayes?

$$\begin{aligned} r(T) &= \iint L(\theta, T(x))p(x|\theta)\pi(\theta)dx d\theta = \iint L(\theta, T(x))p(x, \theta)dx d\theta = \\ &= \int \left\{ \int L(\theta, T(x))p(\theta|x)d\theta \right\} p(x)dx \end{aligned} \quad (2)$$

A **perda esperada a posteriori** de uma ação  $a$  é definida como:

$$\rho(a, x) = \int L(\theta, a)p(\theta|x)d\theta \quad (3)$$

Então, o **risco de Bayes é minimizado se a regra de decisão  $T$  é escolhida de tal forma que  $\rho(T(x), x)$  seja um mínimo para todo  $x$ .**

## 2- Estimação Pontual

Agora aplicamos a teoria bayesiana de decisão para encontrar estimadores pontuais de parâmetros de interesse.


Uma regra de decisão bayesiana neste contexto é chamada de **estimador de Bayes**. Deve ser óbvio da expressão (3) que os estimadores de Bayes dependem de qual função perda é usada !!!

Seja  $\tilde{X} = (X_1, X_2, \dots, X_n)$  uma amostra aleatória da densidade  $f(x, \theta)$ . Seja  $T(\tilde{X})$  um estimador para  $\theta$  e  $x$  o valor observado de  $\tilde{X}$ .

**O estimador de Bayes de  $\theta$  com respeito à função perda  $L(\theta, T)$  é aquele com o menor risco de Bayes.**

### 1) Função de perda quadrática

Se a função perda empregada é a quadrática, isto é,  $L(\theta, a) = (\theta - a)^2$ , então:  $\rho(a, x)$  reduz-se ao erro quadrático médio, e o estimador de Bayes é apenas a média da distribuição a posteriori de  $\theta$ .



### Exemplo 2.1.

#### (Estimador de Bayes para o parâmetro de uma distribuição de Bernoulli)

Sejam  $X_1, X_2, \dots, X_n \stackrel{iid}{\sim} \text{Bernoulli}(\theta)$ . Considere a priori  $\pi(\theta) = \text{Beta}(\alpha, \beta)$  onde  $\alpha$  e  $\beta$  são conhecidos. Suponha que usamos uma função de perda quadrática. Encontre o estimador de Bayes para  $\theta$ .

#### Solução

A distribuição a posteriori para  $\theta$  é uma  $\text{Beta}(\alpha + \sum X_i, \beta + n - \sum X_i)$ . A média desta posteriori é:

$$\frac{\alpha + \sum X_i}{\alpha + \sum X_i + \beta + n - \sum X_i} = \frac{\alpha + \sum X_i}{\alpha + \beta + n}$$

O estimador de Bayes usando uma função de perda quadrática é:

$$\Gamma^*(X) = \frac{\alpha + \sum X_i}{\alpha + \beta + n} = \frac{\alpha + n\bar{X}}{\alpha + \beta + n} = \frac{n}{\alpha + \beta + n} \bar{X} + \frac{(\alpha + \beta)}{\alpha + \beta + n} \left( \frac{\alpha}{\alpha + \beta} \right)$$

Note que  $\bar{X}$  é o estimador de máxima verossimilhança para  $\theta$ , e  $\alpha/(\alpha + \beta)$  é a média da priori. Assim, o estimador de Bayes é uma soma ponderada da média a priori e do estimador de máxima verossimilhança de  $\theta$ , e os pesos desta soma dependem dos parâmetros  $\alpha$  e  $\beta$  da priori e do número de observações na amostra ( $n$ ).

Ao escolher uma priori para  $\theta$  devemos nos preocupar não apenas com  $\alpha$  e  $\beta$  que nos dêem a média a priori desejada, mas também com o valor dos pesos a posteriori. A soma  $\alpha + \beta$  nos dá o peso equivalente ao de uma amostra de tamanho  $n$ .

Assim, se a nossa opinião a priori tem tanto peso quanto uma amostra de tamanho 20, e se a nossa média a priori é  $3/4$ , devemos escolher  $\alpha$  e  $\beta$  tais que:

$$\frac{\alpha}{\alpha + \beta} = \frac{3}{4} \text{ e } \alpha + \beta = 20 \Rightarrow \alpha = 15 \text{ e } \beta = 5$$

### Exemplo 2.2. (Estimador de Bayes para a média de uma Normal com perda quadrática)

Sejam  $X_1, X_2, \dots, X_n \stackrel{iid}{\sim} N(\theta, \sigma^2)$ , onde  $\sigma^2$  é conhecido. Considere a seguinte priori para  $\theta$ :

$\pi(\theta) = N(\mu_0, \sigma_0^2)$ , onde  $\mu_0, \sigma_0^2$  são conhecidos, e suponha que usamos uma função de perda quadrática. Encontre o estimador de Bayes para  $\theta$ .

#### Solução

O estimador de Bayes para  $\theta$  é  $\mu_p$ , a média a posteriori, isto é:

$$T^*(X) = \mu_p = \frac{\sigma^2 \mu_0 + n \sigma_0^2 \bar{X}}{\sigma^2 + n \sigma_0^2} = \frac{\pi_0}{\pi_p} \mu_0 + \frac{\pi_L}{\pi_p} \bar{X}$$

onde  $\pi_0, \pi_L, \pi_p$  são as precisões (recíprocos das variâncias).

## 2) Função de Perda Erro Absoluto

Também é usada com frequência na prática.


$$L(\theta, a) = |\theta - a|$$

Para qualquer valor observado  $\tilde{X}$ , o estimador de Bayes deve minimizar:

$$E[|\theta - a| | \tilde{X}] \text{ Pode-se mostrar que para qualquer distribuição para } \theta, \min E[|\theta - a| | \tilde{X}]$$

ocorre quando  $\underline{a}$  é a **mediana** da distribuição de  $\theta$ .

Logo, o **estimador de Bayes**  $T^*(X)$  para  $\theta$  usando a **perda erro absoluto** é a **mediana** da distribuição a posteriori de  $\theta$ .



### Exemplo 2.3. (Bernoulli)

Considere a mesma situação do exemplo 2.1., mas suponha que usamos a função perda erro absoluto. O estimador de Bayes para  $\theta$  é a mediana da posteriori, ou seja, a mediana de uma distribuição  $\text{Beta}(\alpha + \sum X_i, \beta + n - \sum X_i)$ . Não existe uma expressão simples para esta mediana, ela tem que ser obtida por métodos numéricos.

Em alguns casos simples é possível chegar a uma solução analítica do problema. Por exemplo, suponha que a priori para  $\theta$  é  $\text{Beta}(\alpha = 2, \beta = 1)$ , e que observamos  $n = 5$  repetições de Bernoulli que resultam em  $\sum X_i = 3$  sucessos.

A densidade a posteriori é  $\text{Beta}(\alpha + \sum X_i, \beta + n - \sum X_i) = \text{Beta}(5, 3)$ , e devemos descobrir a mediana  $m$  desta densidade. Note que  $m$  satisfaz:

$$\int_0^m \frac{\Gamma(8)}{\Gamma(3)\Gamma(5)} \theta^{5-1} (1-\theta)^{3-1} d\theta = 50\% = \frac{1}{2}$$

e  $m$  é um número no intervalo  $(0, 1)$ .

Ou seja:

$$\frac{7!}{2!4!} \int_0^m \theta^4 (1-\theta)^2 d\theta = \frac{1}{2}$$

$$\frac{5040}{2(24)} \int_0^m \theta^4 (1 - 2\theta + \theta^2) d\theta = \frac{1}{2}$$

$$210 \int_0^m (\theta^4 - 2\theta^5 + \theta^6) d\theta = 1$$

$$210 \left[ \frac{m^5}{5} - \frac{2m^6}{6} + \frac{m^7}{7} \right] = 1$$

$$210 \left[ \frac{42m^5 - 70m^6 + 30m^7}{210} \right] = 1$$

$$42m^5 - 70m^6 + 30m^7 = 1$$

$30m^7 - 70m^6 + 42m^5 - 1 = 0$  é a equação a ser resolvida.

A solução desta equação é:  $m = 0.6359$  e é este o valor do estimador de Bayes usando a perda erro absoluto.

Se tivéssemos usado a função perda quadrática, o estimador de Bayes seria apenas a média da posteriori que é:

$$\frac{\alpha + \sum X_i}{\alpha + \sum X_i + \beta + n - \sum X_i} = \frac{2 + 3}{5 + 1 + 5 + 3} = \frac{5}{8} = 0.625$$

A moda da densidade a posteriori é a moda de uma densidade Beta(5, 3), que é o ponto tal que:  $\frac{\Gamma(8)}{\Gamma(3)\Gamma(5)} \theta^{5-1} (1-\theta)^{3-1}$  seja máximo. Se notarmos que o logaritmo desta

posteriori tem o mesmo máximo que a densidade, podemos derivar o logaritmo desta densidade com relação a  $\theta$  e igualar a zero para encontrar:  $4 \cdot (1/\theta) + 2 \cdot \{-1/(1-\theta)\} = 0$  e assim  $\theta = 2/3$ .

Logo, neste caso 3 estimadores possíveis são:

média	0.625
mediana	0.6359
moda	$2/3 = 0.666$

Em todos os exemplos já exibidos aqui, é importante ressaltar uma característica fundamental da análise bayesiana de qualquer problema: aqui, ao contrário do que ocorre quando adotamos uma solução freqüentista, a “solução” do problema é uma distribuição de probabilidade, e não apenas uma estimativa pontual. Na verdade, o paradigma bayesiano fornece uma “resposta” ao problema de estimação pontual muito mais completo que a obtida através da solução clássica, pois nos permite visualizar “por inteiro” a distribuição a posteriori.

### Exemplo 2.4. (Normal) – perda erro absoluto

Considere a situação do exemplo 2.2. mas suponha que usamos a função perda erro absoluto. O estimador de Bayes  $T^*(X)$  é agora a mediana da posteriori. Mas, a densidade a posteriori é Normal, e neste caso a média e a mediana coincidem, e assim o estimador de Bayes é o mesmo usando-se a perda quadrática ou a perda erro absoluto.

## 3- Limitações

Muitos estatísticos bayesianos têm sérias restrições contra toda a idéia de estimação pontual. Alguns pontos que foram apresentados são realmente questionáveis, por exemplo:

- Num caso específico, por que uma determinada função perda deve representar as “reais” penalidades econômicas incorridas ao tomar uma decisão incorreta?
- Certamente a mesma função perda não deve ser válida em todos os casos.
- Muitas vezes o erro quadrático médio é infinito, mesmo quando empregamos o estimador mais razoável, o que nos leva a “mágicas” para garantir que as integrais convirjam... (“adhockery” segundo Lindley)
- Se a distribuição a posteriori é bimodal, não faz muito sentido falar em um único estimador pontual....

## 4- Inferência e Teoria de Decisão

O problema de inferência discutido aqui é básico para qualquer problema de decisão, pois este último só poderá ser resolvido a partir da correta especificação do conhecimento sobre o estado da natureza  $\theta$ . Mas, o papel da inferência estatística é EXATAMENTE prover o conhecimento sobre  $\theta$  que permita a tomada de decisões, através do fornecimento da distribuição a posteriori (ou de um sumário apropriado). *Os problemas de decisão e inferência são, a princípio, dissociados, e não precisam ser resolvidos pelo mesmo indivíduo – por exemplo, (Lindley), um cientista não considera as decisões que deverão ser tomadas a partir de suas descobertas; sua tarefa é descrever de maneira precisa os parâmetros da sua experiência.*

## 5- Relação entre Teoria da Decisão e Testes de Hipóteses Clássicos

É possível reformular os testes de hipótese na linguagem da teoria de decisão.

Suponha que desejamos testar  $H_0: \theta \in \Theta_0$  versus  $H_1: \theta \in \Theta_1$ . Existem duas decisões possíveis, a saber:



$a_0 \Rightarrow$  aceitar  $H_0$

$a_1 \Rightarrow$  aceitar  $H_1$  (rejeitar  $H_0$ )

Sejam  $\pi_0$  e  $\pi_1$  as probabilidades a priori para  $H_0$  e  $H_1$  respectivamente, e  $p_0, p_1$  as probabilidades a posteriori.

O **fator de Bayes** é definido como:

$$B = \frac{(p_0 / p_1)}{(\pi_0 / \pi_1)}$$

Sejam:

$$\rho_0(\theta) = \pi(\theta) / \pi_0 \text{ e}$$

$$\rho_1(\theta) = \pi(\theta) / \pi_1$$

onde  $\pi(\theta)$  é a densidade a priori.

Suponha que existe uma função perda  $L(\theta, a)$  definida como:

$a \theta$	$\theta \in \Theta_0$	$\theta \in \Theta_1$
$a_0$	0	1
$a_1$	1	0

Então o uso de uma regra de decisão  $T(x)$  resulta numa função perda esperada a posteriori:

$$\rho(a_0, x) = p_1$$

$$\rho(a_1, x) = p_0$$

**Assim, uma decisão  $T(x)$  que minimiza a perda esperada a posteriori é apenas uma decisão que ACEITA a hipótese com MAIOR PROBABILIDADE A POSTERIORI. Mas, esta era exatamente a forma de escolher entre hipóteses quando a idéia de testes de hipóteses foi originalmente concebida.**

De forma mais geral, se a função perda é uma função “0- $K_i$ ”, isto é:

$a \theta$	$\theta \in \Theta_0$	$\theta \in \Theta_1$
$a_0$	0	$K_0$
$a_1$	$K_1$	0

As perdas esperadas a posteriori das duas decisões são:

$$\rho(a_0, x) = p_1 \cdot K_0$$

$$\rho(a_1, x) = p_0 \cdot K_1$$

Uma regra de decisão de Bayes resulta na **rejeição da hipótese nula** se, e somente se:  $p_0 \cdot K_1 < p_1 \cdot K_0$ , ou seja, se a **perda esperada da decisão  $a_1$  é menor que a perda esperada da decisão  $a_0$** .

Ou seja, em termos do fator de Bayes:

$$B = \frac{(p_0 / p_1)}{(\pi_0 / \pi_1)} < \frac{(k_0 / k_1)}{(\pi_0 / \pi_1)}$$

Na terminologia da estatística clássica, isto corresponde ao uso da região crítica:

$$R = \left\{ x : B < \frac{(k_0 / k_1)}{(\pi_0 / \pi_1)} \right\}$$


No caso de duas hipóteses simples  $\Theta_0 = \{\theta_0\}$  e  $\Theta_1 = \{\theta_1\}$ , o teorema de Bayes implica em:

$$B = \frac{p(x|\theta_0)}{p(x|\theta_1)}, \text{ a razão das verossimilhanças e a região crítica toma a forma:}$$

$$R = \left\{ x : \frac{p(x|\theta_0)}{p(x|\theta_1)} < \frac{(k_0 / k_1)}{(\pi_0 / \pi_1)} \right\} \text{ que é o teste de razão de verossimilhança sugerido pela}$$

teoria de Neyman e Pearson. A diferença é que, na teoria de Neyman e Pearson, o “valor crítico” da região de rejeição é determinado fixando-se  $\alpha$ , ou seja, pela probabilidade de  $x$  cair na região de rejeição se a hipótese nula for verdadeira.

Ao contrário, na abordagem da teoria de decisão, o valor crítico é fixado em termos da função perda e das probabilidades a priori.



---

## Referências

Bickel, P. & Doksum, K. (1977) – Mathematical Statistics: Basic Ideas and Selected Topics, Holden Day, Oakland.

Lee, P. M. (1989) – Bayesian Statistics: An Introduction, Oxford University Press, London.

Lindley, D.V. (1970) – Introduction to Probability and Statistics from a Bayesian Viewpoint – part 2 – Inference, Cambridge University Press, London.

Mood, A.M., Graybill, F.A. & Boes, D.C. (1974) – Introduction to the Theory of Statistics, 3rd Edition, McGraw-Hill, New York.