

Modelos Estatísticos

Inferência - EST187

Profa. Denise Duarte

2020/01

- Seja Y uma v.a.com função de distribuição desconhecida $F(\cdot)$ e considere $y = (y_1, \dots, y_n)$ n realizações da v.a. Y .
- Objetivo: tirar informações sobre F com base nos valores observados de y .
- Obviamente, as informações sobre F estarão sujeitas a incerteza.
- Assim, devemos assegurar que:
 - o grau de incerteza é o menor possível, considerando a aleatoriedade de Y .
 - seja possível acessarmos o grau de incerteza em nossas decisões.
- A natureza física do problema que gera y , o esquema amostral, bem como outras possíveis informações adicionais, irão impor limites sobre as possíveis escolhas de F .

Definição

Modelo Estatístico: *é o conjunto \mathcal{F} formado por todas as possíveis candidatas a $F(\cdot)$.*

- A classe \mathcal{F} é muito grande, pois, em princípio, \mathcal{F} pode ser qualquer conjunto de funções de distribuições.
- Intuitivamente, nossas inferências serão mais acuradas se formos capazes de selecionar o conjunto \mathcal{F} de tal forma que ele tenha o menor tamanho possível.

Definição

Suporte: o suporte de uma v.a. Y corresponde ao conjunto

$$\mathcal{Y}_\theta = \{y : f(y; \theta) > 0\} \quad (1)$$

Definição

Modelo Paramétrico: é o conjunto \mathcal{F} formado por todas as funções da forma

$$\mathcal{F} = \{F(\cdot; \theta) : \theta \in \Theta \subset \mathbb{R}^k\}, \quad (2)$$

em que, para todo θ fixado, $F(\cdot; \theta)$ corresponde a uma função de distribuição cujo suporte é um subconjunto de \mathbb{R} , com k e n inteiros positivos. Alternativamente, poderíamos definir \mathcal{F} em termos de f.d.p.'s ou f.m.p.'s, isto é,

$$\mathcal{F} = \{f(\cdot; \theta) : \theta \in \Theta \subset \mathbb{R}^k\}. \quad (3)$$

Observações

- A quantidade θ é o parâmetro, que pode ser um vetor;
- Θ é o espaço paramétrico associado a θ ;
- \mathcal{F} definido em (2) ou (4) é chamada classe paramétrica ou modelo (estatístico) paramétrico;
- Note que os elementos de \mathcal{F} estão associados aos elementos de Θ .
- Nossas inferências serão sobre $\theta_* \in \Theta$, associado a F , chamado valor verdadeiro do parâmetro, a partir de uma amostra.

Definição

Espaço Amostral: *é o conjunto \mathcal{Y} formado por todos os possíveis resultados y (realizações da v.a. Y) compatíveis com um dado modelo paramétrico, ou seja,*

$$\mathcal{Y} = \cup_{\theta \in \Theta} \mathcal{Y}_{\theta}. \quad (4)$$

Em geral, \mathcal{Y}_{θ} é o mesmo para todo $\theta \in \Theta$ e $\mathcal{Y}_{\theta} = \mathcal{Y}$.

Exemplo

Assuma que $Y \sim U(0, \theta)$. Então

$$f(y|\theta) = \begin{cases} \frac{1}{\theta}, & \text{se } 0 < y < \theta, \\ 0, & \text{caso contrário.} \end{cases}$$

Podemos reescrever a densidade como

$$f(y|\theta) = \frac{1}{\theta} I_{(0, \theta)}(y),$$

onde

$$\begin{cases} 1, & \text{se } a < y < b; \\ 0, & \text{caso contrário.} \end{cases}$$

é a função indicadora do intervalo aberto (a, b) .

Logo, $\Theta = \{\theta : \theta > 0\}$. Note que, neste caso, o suporte da distribuição, \mathcal{Y}_θ , depende do espaço paramétrico Θ e $\mathcal{Y} = \cup_{\theta \in \Theta} \mathcal{Y}_\theta$.

Exemplo

Assuma que $Y \sim \text{Bin}(n, \theta)$. Então

$$f(y|\theta) = \binom{n}{y} \theta^y (1 - \theta)^{n-y}, \quad (5)$$

com $\Theta = \{\theta : 0 < \theta < 1\}$ e $\mathcal{Y} = \{y : y = 0, 1, \dots, n\}$, pois o suporte da distribuição \mathcal{Y}_θ não depende do espaço paramétrico Θ .

Exemplo

Se dois valores são amostrados independentemente de $N(\theta, 1)$, então

$y = (y_1, y_2)'$, com $y_i \in \mathbb{R}$ ($i = 1, 2$). Logo, $Y \sim N_2 \left(\begin{pmatrix} \theta \\ \theta \end{pmatrix}; I_2 \right)$, onde I_2 matriz identidade de ordem 2, e

$$\begin{aligned} f(y|\theta) &= \left[\frac{1}{\sqrt{2\pi}} \exp \left\{ -\frac{1}{2}(y_1 - \theta)^2 \right\} \right] \times \left[\frac{1}{\sqrt{2\pi}} \exp \left\{ -\frac{1}{2}(y_2 - \theta)^2 \right\} \right] \\ &= \frac{1}{2\pi} \exp \left\{ -\sum_{i=1}^2 \frac{1}{2}(y_i - \theta)^2 \right\} \end{aligned} \quad (6)$$

Neste caso, $\Theta = \{\theta : \theta \in \mathbb{R}\}$ e $\mathcal{Y} = \mathbb{R} \times \mathbb{R}$.

- Para evitar ambiguidade, é essencial que valores distintos de θ correspondam a distintas distribuições de probabilidade.
- Sem tal propriedade, poderiam existir 2 valores de θ , digamos θ' e θ'' , associados à mesma distribuição verdadeira F , o que tornaria impossível dizer qual valor (θ' ou θ'') é o verdadeiro.
- Neste sentido, dizemos que um modelo é identificável se existir pelo menos um conjunto B tal que, para $\theta' \in \Theta$ e $\theta'' \in \Theta$, com $\theta' \neq \theta''$, valer

$$P(Y \in B; \theta') \neq P(Y \in B; \theta''). \quad (7)$$

- A especificação de \mathcal{F} pode ser feita de diversas maneiras, de acordo com a parametrização adotada.
- Seja h uma função um a um de Θ para Ψ . Então podemos redefinir \mathcal{F} em (4) da seguinte forma

$$\begin{aligned}\mathcal{F} &= \{f(\cdot; \psi) : \psi = h(\theta) \in \Theta\} \\ &= \{f(\cdot; \psi) : \psi \in \Psi\},\end{aligned}$$

em que $\Psi = \{\psi : \psi = h(\theta) \in \Theta\}$.

- A parametrização a ser adotada depende do problema específico em estudo.
- Em geral, a parametrização é escolhida de tal forma a fornecer uma melhor interpretação física, embora em alguns casos a escolha da parametrização seja inteiramente arbitrária.

Exemplo

Seja Y a v.a. que representa o tempo entre ocorrências de um determinado evento de interesse. Assuma que $Y \sim \text{Exp}(\lambda)$, em que λ corresponde ao número esperado de eventos por unidade de tempo. Então

$$f(y|\lambda) = \lambda e^{-\lambda y}, \quad \lambda > 0, \quad y > 0. \quad (8)$$

Alternativamente, se definirmos $\theta = 1/\lambda$, então

$$f(y|\theta) = \frac{1}{\theta} e^{-\frac{1}{\theta}y}, \quad \theta > 0, \quad y > 0. \quad (9)$$

Neste caso, θ corresponde ao tempo médio entre duas ocorrências do evento de interesse.