

## Probabilidades e Estatística

**LEAN, LEGM, LEIC-A, LEMat, LMAC, MEAer, MEAmbi,  
MEBiol, MEBiom, MEC, MEEC, MEFT, MEMec MEQ**

1º semestre – 2011/2012

2/02/2012 – **11:30**

**2º TESTE** (Época Recurso)

Duração: 1 hora e 30 minutos

**Grupo I**

**2.0 + 4.0 + 4.0 = 10.0** valores

### Exercício 1

- **Estimador de  $\theta$  e suas propriedades**

$T$  é tal que  $E(T) = \theta$  e  $V(T) > 0$ .

- **Estimador de  $\theta^2$**

$T^2$

- **Estimador centrado de  $\theta^2$  ?**

$T^2$  é um estimador centrado de  $\theta^2$  sse  $E(T^2) = \theta^2, \forall \theta$ . Ora, como  $V(T) > 0$  tem-se

$$\begin{aligned} E(T^2) &= V(T) + E^2(T) \\ &> 0 + \theta^2 \\ &= \theta^2, \end{aligned}$$

para qualquer  $\theta$ . Assim, conclui-se que  $E(T^2) \neq \theta^2$ , logo  $T^2$  não é um estimador centrado de  $\theta^2$ .

### Exercício 2

- **V.a. de interesse**

$X$  = número de defeitos em cada produto

- **Distribuição**

$X \sim \text{Poisson}(\lambda)$

- **Parâmetro DESCONHECIDO**

$\lambda, \lambda > 0$

- **F.p.**

$$P(X = x) \stackrel{\text{form}}{=} \frac{e^{-\lambda} \lambda^x}{x!}, x = 0, 1, \dots$$

- **Amostra**

$\underline{x} = (x_1, \dots, x_n)$  amostra de dimensão  $n$  proveniente da população  $X$

- **Obtenção da estimativa de MV de  $\lambda$**

**Passo 1 — Função de verosimilhança**

$$\begin{aligned} L(\lambda | \underline{x}) &\stackrel{X_i \text{ indep}}{=} \prod_{i=1}^n P(X = x_i) \\ &\stackrel{X_i \sim X}{=} \prod_{i=1}^n \left( \frac{e^{-\lambda} \lambda^{x_i}}{x_i!} \right) \\ &= \frac{e^{-n\lambda} \lambda^{\sum_{i=1}^n x_i}}{\prod_{i=1}^n x_i!}, \lambda > 0 \end{aligned}$$

### Passo 2 — Função de log-verosimilhança

$$\ln L(\lambda|\underline{x}) = -n\lambda + \ln(\lambda) \sum_{i=1}^n x_i - \sum_{i=1}^n \ln(x_i!)$$

### Passo 3 — Maximização

A estimativa de MV de  $\lambda$  é aqui representada por  $\hat{\lambda}$  e

$$\begin{aligned}\hat{\lambda} &: \begin{cases} \frac{d \ln L(\lambda|\underline{x})}{d\lambda} \Big|_{\lambda=\hat{\lambda}} = 0 & (\text{ponto de estacionaridade}) \\ \frac{d^2 \ln L(\lambda|\underline{x})}{d\lambda^2} \Big|_{\lambda=\hat{\lambda}} < 0 & (\text{ponto de máximo}) \end{cases} \\ &\quad \begin{cases} -n + \frac{\sum_{i=1}^n x_i}{\hat{\lambda}} = 0 \\ -\frac{\sum_{i=1}^n x_i}{\hat{\lambda}^2} < 0 \end{cases} \\ &\quad \begin{cases} \hat{\lambda} = \frac{1}{n} \sum_{i=1}^n x_i \\ \text{Proposição verdadeira desde que } \sum_{i=1}^n x_i > 0 \end{cases}\end{aligned}$$

### Passo 4 — Estimativa de MV de $\lambda$

$$\begin{aligned}\hat{\lambda} &= \frac{1}{n} \sum_{i=1}^n x_i \\ &= \frac{10}{85} \\ &= \frac{2}{17}\end{aligned}$$

- **Outro parâmetro DESCONHECIDO**

$$\begin{aligned}h(\lambda) &= P(X \geq 1) \\ &= 1 - P(X = 0) \\ &= 1 - e^{-\lambda}\end{aligned}$$

- **Estimativa de MV de  $h(\lambda)$**

Invocando a propriedade de invariância dos estimadores de máxima verosimilhança, pode concluir-se que a estimativa de MV de  $h(\lambda) = 1 - e^{-\lambda}$  é igual a

$$\begin{aligned}\widehat{h(\lambda)} &= h(\hat{\lambda}) \\ &= 1 - e^{-\hat{\lambda}} \\ &= 1 - e^{-\frac{2}{17}} \\ &\simeq 0.110990.\end{aligned}$$

### Exercício 3

- **V.a. de interesse**

$X$  = aumento de peso em porcos alimentados com a ração  $A$  durante 20 semanas

$Y$  = aumento de peso em porcos alimentados com a ração  $B$  durante 20 semanas

- **Situação**

$X \sim \text{Normal}(\mu_X, \sigma_X^2) \perp\!\!\!\perp Y \sim \text{Normal}(\mu_Y, \sigma_Y^2)$

$(\mu_X - \mu_Y)$  DESCONHECIDO

$\sigma_X^2$  e  $\sigma_Y^2$  desconhecidos, no entanto, assume-se que são IGUAIS:  $\sigma_X^2 = \sigma_Y^2 = \sigma^2$

$n_X \leq 30$  ou  $n_Y \leq 30$

- **Hipóteses**

$$H_0 : \mu_X - \mu_Y = \mu_0 = 0$$

$$H_1 : \mu_X - \mu_Y > \mu_0$$

- **Nível de significância**

$$\alpha_0 = 10\%$$

- **Estatística de teste**

$$T = \frac{(\bar{X} - \bar{Y}) - \mu_0}{\sqrt{\frac{(n_X-1)S_X^2 + (n_Y-1)S_Y^2}{n_X+n_Y-2} \times \left(\frac{1}{n_X} + \frac{1}{n_Y}\right)}} \sim_{H_0} t_{(n_X+n_Y-2)}$$

dado que se pretende efectuar um teste sobre a diferença de valores esperados de duas populações normais independentes, com variâncias desconhecidas mas que se assume serem iguais.

- **Região de rejeição de  $H_0$**  (para valores da estatística de teste)

Estamos a lidar com um teste unilateral superior ( $H_1 : \mu_X - \mu_Y > \mu_0$ ), logo a região de rejeição de  $H_0$  (para valores da estatística de teste) é um intervalo do tipo  $W = (c, +\infty)$ , onde  $c : P(\text{Rejeitar } H_0 | H_0) = \alpha_0$ , i.e.,

$$\begin{aligned} c &= F_{t_{(n_X+n_Y-2)}}^{-1}(1 - \alpha_0) \\ &= F_{t_{(6+7-2)}}^{-1}(1 - 0.10) \\ &= F_{t_{(11)}}^{-1}(0.9) \\ &\stackrel{\text{tabela}}{=} 1.363. \end{aligned}$$

- **Decisão**

Atendendo a que  $\sum_{i=1}^7 x_i = 490$ ,  $\sum_{i=1}^7 x_i^2 = 34\,432$ ,  $\sum_{i=1}^6 y_i = 384$  e  $\sum_{i=1}^6 y_i^2 = 24\,790$ , segue-se:

$$\circ n_X = 6$$

$$\bar{x} = \frac{1}{n_X} \sum_{i=1}^{n_X} x_i = \frac{490}{7} = 70$$

$$s_X^2 = \frac{1}{n_X-1} \left[ \left( \sum_{i=1}^{n_X} x_i^2 \right) - n_X (\bar{x})^2 \right] = \frac{1}{7-1} (34\,432 - 7 \times 70^2) = 22$$

$$n_Y = 6$$

$$\bar{y} = \frac{1}{n_Y} \sum_{i=1}^{n_Y} y_i = \frac{384}{6} = 64$$

$$s_Y^2 = \frac{1}{n_Y-1} \left[ \left( \sum_{i=1}^{n_Y} y_i^2 \right) - n_Y (\bar{y})^2 \right] = \frac{1}{6-1} (24\,790 - 6 \times 64^2) = 42.8.$$

O valor observado da estatística de teste é igual a

$$\begin{aligned} t &= \frac{(\bar{x} - \bar{y}) - \mu_0}{\sqrt{\frac{(n_X-1)s_X^2 + (n_Y-1)s_Y^2}{n_X+n_Y-2} \times \left(\frac{1}{n_X} + \frac{1}{n_Y}\right)}} \\ &= \frac{(70 - 64) - 0}{\sqrt{\frac{(7-1) \times 22 + (6-1) \times 42.8}{7+6-2} \left(\frac{1}{7} + \frac{1}{6}\right)}} \\ &\simeq 1.923. \end{aligned}$$

Como  $t = 1.923 \in W = (1.363, +\infty)$ , devemos rejeitar  $H_0$  a qualquer n.s.  $\alpha \geq 10\%$ .

**Exercício 1**

- **V.a. de interesse**

$X$  = classificação de uma criança quanto ao género e à PHDA

- **Hipóteses**

Sejam

$$\begin{aligned} p_i &= P(X = i) \\ &= \begin{cases} \theta/2, & i = 1 \\ (1 - \theta)/2, & i = 2 \\ \theta(2 - \theta)/2, & i = 3 \\ (1 - \theta)^2/2, & i = 4 \end{cases} \\ p_i^0 &\stackrel{\theta=0.9}{=} \begin{cases} 0.9/2, & i = 1 \\ (1 - 0.9)/2, & i = 2 \\ 0.9 \times (2 - 0.9)/2, & i = 3 \\ (1 - 0.9)^2/2, & i = 4. \end{cases} \end{aligned}$$

Então confrontar-se-ão as seguintes hipóteses:

$$H_0 : p_i = p_i^0, i = 1, \dots, 4$$

$$H_1 : \exists i : p_i \neq p_i^0$$

- **Estatística de Teste**

$$T = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \stackrel{a}{\sim}_{H_0} \chi_{(k-\beta-1)}^2,$$

onde:

$$k = \text{No. de classes} = 4$$

$$O_i = \text{Frequência absoluta observável da classe } i$$

$$E_i = \text{Frequência absoluta esperada, sob } H_0, \text{ da classe } i$$

$$\beta = \text{No. de parâmetros a estimar} = 0.^1$$

- **Região de rejeição de  $H_0$  (para valores de  $T$ )**

A região de rejeição de  $H_0$  escrita para valores de  $T$  é um intervalo à direita  $W = (c, +\infty)$ .

- **Frequências absolutas esperadas sob  $H_0$**

Atendendo a que, sob  $H_0$ ,  $p_i = p_i^0$ , as frequências absolutas esperadas sob  $H_0$  são iguais a

$$\begin{aligned} E_i &= n \times p_i^0 \\ &= \begin{cases} 2000 \times \frac{0.9}{2} = 900, & i = 1 \\ 2000 \times \frac{1-0.9}{2} = 100, & i = 2 \\ 2000 \times \frac{0.9 \times (2-0.9)}{2} = 990, & i = 3 \\ 2000 \times \frac{(1-0.9)^2}{2} = 10, & i = 4. \end{cases} \end{aligned}$$

[Importa notar que não é necessário qualquer agrupamento de classes uma vez que em pelo menos 80% das classes se verifica  $E_i \geq 5$ .]

- **Decisão**

No cálculo do valor observado da estatística de teste convém adiantar a seguinte tabela auxiliar:

---

<sup>1</sup>Dado que a distribuição conjecturada em  $H_0$  está completamente especificada, i.e.,  $H_0$  é uma hipótese simples.

<i>i</i>	Classe <i>i</i>	Freq. abs. obs. <i>o<sub>i</sub></i>	Freq. abs. esper. sob <i>H</i> <sub>0</sub> <i>E<sub>i</sub></i> = <i>n</i> × <i>p<sub>i</sub></i> <sup>0</sup>	Parcelas valor obs. estat. teste $\frac{(o_i - E_i)^2}{E_i}$
1	{1}	884	900	$\frac{(884 - 900)^2}{900} \simeq 0.284$
2	{2}	86	100	1.96
3	{3}	1018	990	0.792
4	{4}	12	10	0.4
$\sum_{i=1}^k o_i = n = 2000$		$\sum_{i=1}^k E_i = n = 2000$	$t = \sum_{i=1}^k \frac{(o_i - E_i)^2}{E_i} \simeq 3.436$	

• **Decisão (cont.) e intervalo para o p-value**

Dado que a região de rejeição deste teste é um intervalo à direita, tem-se:

$$\begin{aligned} p-value &= P(T > t | H_0) \\ &= P(T > 3.436 | H_0) \\ &\simeq 1 - F_{\chi^2_{(4-1-0)}}(3.436) \end{aligned}$$

Recorrendo às tabelas de quantis da distribuição do qui-quadrado podemos adiantar um intervalo para o *p-value*. Com efeito,

$$\begin{aligned} F_{\chi^2_{(3)}}^{-1}(0.600) &= 2.946 < 3.436 < 3.665 = F_{\chi^2_{(3)}}^{-1}(0.700) \\ 0.600 &< F_{\chi^2_{(3)}}(3.436) < 0.700 \\ 0.300 = 1 - 0.700 &> 1 - F_{\chi^2_{(3)}}(3.436) < 1 - 0.600 = 0.400. \end{aligned}$$

Deste modo, o intervalo aproximado para o *p-value* é (0.300, 0.400), pelo que

- não rejeitar *H*<sub>0</sub> a qualquer n.s.  $\alpha_0 \leq 30\%$ , nomeadamente aos níveis usuais de significância de 1%, 5% e 10%;
- devemos rejeitar *H*<sub>0</sub> a qualquer n.s.  $\alpha_0 \geq 40\%$

• **Decisão (cont.) e obtenção do p-value usando máquina de calcular**

Uma vez que a região de rejeição deste teste é um intervalo à direita, tem-se:

$$\begin{aligned} p-value &= P(T > t | H_0) \\ &= P(T > 3.436 | H_0) \\ &\simeq 1 - F_{\chi^2_{(3)}}(3.436) \\ &\simeq 0.329158, \end{aligned}$$

pelo que

- não devemos rejeitar *H*<sub>0</sub> a qualquer n.s.  $\alpha_0 \leq 32.9158\%$ , nomeadamente aos níveis usuais de significância de 1%, 5% e 10%;
- rejeitar *H*<sub>0</sub> a qualquer n.s.  $\alpha_0 > 32.9158\%$ .

## Exercício 2

- (a) • [Modelo de RLS

$$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i$$

*Y<sub>i</sub>* = resultado da medição da *i* – ésima concentração conhecida

*x<sub>i</sub>* = valor da *i* – ésima concentração conhecida

*ε<sub>i</sub>* = erro aleatório associado à medição da *i* – ésima concentração conhecida

• Hipóteses de trabalho

$\epsilon_i \sim_{i.i.d.} \text{Normal}(0, \sigma^2)$ ,  $i = 1, \dots, n$  (hipótese de trabalho)

$\beta_0, \beta_1, \sigma^2$  DESCONHECIDOS]

• Estimativas de  $\beta_0$  e  $\beta_1$

Uma vez que

- o  $n = 5$
- o  $\sum_{i=1}^5 x_i = 50$
- $\bar{x} = 10$
- $\sum_{i=1}^n x_i^2 = 540$
- $\sum_{i=1}^n x_i^2 - n(\bar{x})^2 = 540 - 5 \times 10^2 = 40$
- o  $\sum_{i=1}^5 y_i = 150$
- $\bar{y} = 30$
- $\sum_{i=1}^n y_i^2 = 4676$
- $\sum_{i=1}^n y_i^2 - n(\bar{y})^2 = 4676 - 5 \times 30^2 = 176$
- o  $\sum_{i=1}^n x_i y_i = 1582$
- $\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} = 1582 - 5 \times 10 \times 30 = 82,$

as estimativas de  $\beta_1$  e  $\beta_0$  são, para este modelo, iguais a:

$$\begin{aligned}\hat{\beta}_1 &= \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n (\bar{x})^2} \\ &= \frac{82}{40} \\ &= 2.05 \\ \hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \times \bar{x} \\ &= 30 - 2.05 \times 10 \\ &= 9.5\end{aligned}$$

- **Recta de regressão**

$$\hat{E}(Y|x) = \hat{\beta}_0 + \hat{\beta}_1 \times x = 9.5 + 2.05 \times x, x \in [\min x_i, \max x_i]$$

- (b)    • **Passo 1 — Selecção da v.a. fulcral para  $\beta_1$**

$$Z = \frac{\hat{\beta}_1 - \beta_{1,0}}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}}} \sim t_{(n-2)}$$

- **Passo 2 — Obtenção dos quantis de probabilidade**

Ao ter em conta que, neste caso,  $n = 5$  e  $(1 - \alpha) \times 100\% = 95\%$ , i.e.,  $\alpha = 0.05$ , usaremos os quantis de probabilidade:

$$\begin{cases} a_\alpha = -F_{t_{(n-2)}}^{-1}(1 - \alpha/2) = -F_{t_{(3)}}^{-1}(0.975) \stackrel{\text{tabela}}{=} -3.182 \\ b_\alpha = F_{t_{(n-2)}}^{-1}(1 - \alpha/2) = F_{t_{(3)}}^{-1}(0.975) \stackrel{\text{tabela}}{=} 3.182 \end{cases}$$

- **Passo 3 — Inversão da desigualdade  $a_\alpha \leq Z \leq b_\alpha$**

$$P(a_\alpha \leq Z \leq b_\alpha) = 1 - \alpha$$

...

$$P\left[\hat{\beta}_1 - F_{t_{(n-2)}}^{-1}(1 - \alpha/2) \times \sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}} \hat{\beta}_1 + F_{t_{(n-2)}}^{-1}(1 - \alpha/2) \times \sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}}\right] = 1 - \alpha.$$

- **Passo 4 — Concretização**

Atente-se que

- o  $\hat{\beta}_1 = 2.05$
- o  $F_{t_{(n-2)}}^{-1}(1 - \alpha/2) = 3.182$
- o  $\sum_{i=1}^n x_i^2 - n(\bar{x})^2 = 40$ .

Se a isto acrescentarmos que

$$\begin{aligned}
 \hat{\sigma}^2 &= \frac{1}{n-2} \left[ \left( \sum_{i=1}^n y_i^2 - n \bar{y}^2 \right) - (\hat{\beta}_1)^2 \left( \sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \right] \\
 &= \frac{1}{5-2} (176 - (2.05)^2 \times 40) \\
 &\simeq 2.633 \\
 IC_{(1-\alpha) \times 100\%}(\beta_1) &= \left[ \hat{\beta}_1 \pm F_{t(n-2)}^{-1}(1 - \alpha/2) \times \sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}} \right]
 \end{aligned}$$

temos:

$$\begin{aligned}
 IC_{95\%}(\beta_1) &\simeq \left[ 2.05 \pm 3.182 \times \sqrt{\frac{2.633}{40}} \right] \\
 &\simeq [2.05 \pm 0.7955] \\
 &= [1.2545, 2.8455].
 \end{aligned}$$

(c) • **Significância da regressão**

Pretende testar-se  $H_0 : \beta_1 = \beta_{1,0} = 0$  (regressão não é significativa, i.e., a variável resposta  $Y$  não depende da variável explicativa  $x$ ) contra  $H_0 : \beta_1 = \beta_{1,0} \neq 0$  (regressão é significativa).

Invocando a relação entre intervalos de confiança e testes de hipóteses e dado que

$$\beta_{1,0} = 0 \notin IC_{95\%}(\beta_1) = [1.2545, 2.8455],$$

a hipótese  $H_0$  deve ser rejeitada ao nível de significância  $\alpha = 100\% - 95\% = 5\%$ .<sup>2</sup>

---

<sup>2</sup>Mais, devemos rejeitar  $H_0$  a qualquer n.s.  $\alpha_0 \geq 5\%$ .