

Econometria e Métodos de Modelização I

Licenciatura em Economia

REVISÃO DE ALGUNS CONCEITOS EM ESTATÍSTICA

Luís Filipe Martins

luis.martins@iscte.pt

<http://home.iscte.pt/~lfsm>

Departamento de Métodos Quantitativos,

ISCTE - Escola de Gestão

Lisboa, Janeiro de 2006

1 Variável Aleatória e Funções de Densidade e Probabilidade

- Uma variável aleatória X é a informação probabilística de uma realização aleatória. O conjunto de realizações é composto pelos potenciais acontecimentos mutuamente exclusivos do processo aleatório. Uma realização é aleatória porque está associada a uma probabilidade (proporção de vezes que ocorre no longo prazo) na experiência.

Example 1 $X = \#$ de caras quando se atira ao ar uma moeda válida por 10 vezes. O espaço probabilístico é $\{0, 1, \dots, 10\}$, uma particular realização é $x = 6$ e um particular evento é "obter um número par de caras".

- Variável aleatória Discreta versus Continua.

Example 2 Bernoulli e Poisson versus Normal and Chi-Quadrado.

- Função densidade probabilística discreta (pdf), $p_j = P(X = x_j) = f(x_j)$ onde a soma dos p'_j s é 1 e estes estão no intervalo entre 0 e 1.
- Função distribuição cumulativa (cdf), $F(x) = P(X \leq x)$. A área ou integral (caso contínuo) abaixo da pdf é 1; $F(x)$ é não decrescente em relação a x and está entre 0 e 1.

Para qualquer c , $P(X \geq c) = P(X > c) = 1 - F(c)$

Para qualquer $a < b$, $P(a < X \leq b) = F(b) - F(a)$.

- Função densidade (contínua) (pdf), $f(x_j) = \frac{\partial F(x)}{\partial x} |_{x = x_j}$.
- Pdf conjunta, $f_{X,Y}(x, y) = P(X = x, Y = y)$, para X, Y v.a. discretas; e $f_{X,Y}(x, y) = \frac{\partial^2 F_{X,Y}(x,y)}{\partial x \partial y}$.
- $\sum_{i,j} f_{X,Y}(x_j, y_i) = 1$; $\int \int f_{X,Y}(x, y) dx dy = 1$.
- Def: X, Y são independentes se e só se $f_{X,Y}(x, y) = f_X(x) f_Y(y)$, para todo x, y .

Pdf Marginal, $f_X(x)$. Para v.a. discreta, $f_X(x_j) = \sum_{i=1}^m f_{X,Y}(x_j, y_i)$; para contínua, $f_X(x) = \int f_{X,Y}(x, y) dy = \frac{\partial F_{X,Y}(x, \infty)}{\partial x} = \frac{\partial F_X(x)}{\partial x}$

- Pdf conditional, $f_{Y/X}(y/x) = \frac{f_{X,Y}(x,y)}{f_X(x)}$, para todo x em que $f_X(x) > 0$.

X, Y são independentes se $f_{Y/X}(y/x) = f_Y(y)$.

- $\int f_{Y/X}(y/x) dy = 1$; $F_{Y/X}(y/x) = \int_{-\infty}^y f_{Y/X}(z/x) dz$.

2 Valor Esperado e Variância

- Valor esperado $E(X) \equiv \mu$ como medida de tendência central.

$$E(X) = \sum_{j=1}^k x_j f(x_j) \text{ ou } E(X) = \int_{-\infty}^{+\infty} x f(x) dx.$$

$$\text{Para } X, Y \text{ disc., } E[g(X, Y)] = \sum_{j=1}^k \sum_{i=1}^m g(x_j, y_i) f_{X,Y}(x_j, y_i)$$

- Propriedades:

Para c, a, b e $\{a_1, \dots, a_n\}$ qq constantes e $\{X_1, \dots, X_n\}$ v.a.,

$$\text{M1: } E(c) = c$$

$$\text{M2: } E(aX + b) = aE(X) + b$$

$$\text{M3: } E\left(\sum_{i=1}^n a_i X_i\right) = \sum_{i=1}^n a_i E(X_i)$$

- Mediana $Med(X)$ como medida de tendência central.
- Distribuições (A)Simétricas.
- Variância $Var(X) \equiv \sigma^2$ como medida de variabilidade.

$$Var(X) = E[(X - \mu)^2] > 0, \text{ e desvio padrão } sd(X) \equiv \sigma = \sqrt{Var(X)}$$

$$\text{Facto: } \sigma^2 = E(X^2) - \mu^2.$$

- Propriedades:

$$\text{V1: } Var(X) = 0 \text{ se e só se } P(X = c) = 1$$

$$\text{V2: } Var(aX + b) = a^2 Var(X), sd(aX + b) = |a| sd(X).$$

- Variável aleatória Standardizada, $Z \equiv \frac{X - \mu}{\sigma}$.

3 Correlação, Independência e Momentos Condicionados

- Covariância $Cov(X, Y) \equiv \sigma_{XY}$ e Correlação $Corr(X, Y) \equiv \rho_{XY}$ como medidas de associação (linear).

$$Cov(X, Y) = E[(X - \mu_X)(Y - \mu_Y)], \quad Corr(X, Y) = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

$$\text{Facto: } \sigma_{XY} = E(XY) - \mu_X \mu_Y$$

- Propriedades:

C1: Se X, Y são independentes, então $Cov(X, Y) = 0$.

C2: $Cov(a_1X + b_1, a_2Y + b_2) = a_1a_2Cov(X, Y)$

C3: $|\sigma_{XY}| \leq \sigma_X \sigma_Y$ (desigualdade de Cauchy-Schwartz)

C4: $-1 \leq Corr(X, Y) \leq 1$

C5: $Corr(a_1X + b_1, a_2Y + b_2) = Corr(X, Y), a_1a_2 > 0;$

$Corr(a_1X + b_1, a_2Y + b_2) = -Corr(X, Y), a_1a_2 < 0.$

C6: $Var(aX + bY) = a^2Var(X) + b^2Var(Y) + 2abCov(X, Y)$

C7: Se $\{X_1, \dots, X_n\}$ são v.a. não autocorrelacionadas mutuamente, então $Var\left(\sum_{i=1}^n a_i X_i\right) = \sum_{i=1}^n a_i^2 Var(X_i).$

Caso contrário, $Var\left(\sum_{i=1}^n a_i X_i\right) = \sum_{i=1}^n a_i^2 Var(X_i) + 2 \sum_{i>j} a_i a_j Cov(X_i, X_j)$

- Valor esperado condicional de Y dado X , $E(Y/x) = \sum_{j=1}^m y_j f_{Y/X}(y_j/x)$ ou $E(Y/x) = \int_{-\infty}^{+\infty} y f_{Y/X}(y/x) dy$, é uma função de x .

- Propriedades:

Considere $g(X)$ e $h(X)$ qualquer duas funções.

$$\text{CE1: } E [g(X) / X] = g(X)$$

$$\text{CE2: } E [g(X) Y + h(X) / X] = g(X) E (Y/X) + h(X)$$

CE3: Se Y, X são independentes, então $E (Y/X) = E (Y)$. Se $E (Y/X) = E (Y)$, então $Cov(g(X), Y) = 0$.

$$\text{CE4: } E_X [E (Y/X)] = E (Y) \text{ (lei das expectativas iteradas)}$$

- Variância condicional de Y dado X , $Var (Y/x)$

$$\begin{aligned} Var (Y/X = x) &= E \left([Y - E (Y/X)]^2 / x \right) \\ &= \sum_{j=1}^m [y_j - E (Y/x)]^2 f_{Y/X} (y_j/x) \end{aligned}$$

$$Var (Y/X = x) = E(Y^2/x) - [E (Y/X)]^2$$

Se Y, X são independentes, então $Var (Y/X) = Var (Y)$.

4 Principais Distribuições

- Distribuição Normal, $X \sim N(\mu, \sigma^2)$ é simétrica em torno de μ e $0.95 = P(\mu - 1.96\sigma < X < \mu + 1.96\sigma)$

Tabelas: Normal Standard, $Z = \frac{X-\mu}{\sigma}$; $P(Z \leq z) = \Phi(z)$

$P(Z > z) = 1 - \Phi(z)$ e $P(a \leq Z \leq b) = \Phi(b) - \Phi(a)$

Qualquer combinação linear de *i.i.d.* N . tem uma distribuição N .

Example 3 Para $Y_i \sim N(\mu, \sigma^2)$, $i = 1, \dots, n$, então $\frac{1}{n} \sum_{i=1}^n Y_i \sim N\left(\mu, \frac{\sigma^2}{n}\right)$.

- Normal Bivariada, $N_2(\mu, \Omega)$

$$f_{X,Y}(x, y) = \frac{1}{2\pi\sigma_X\sigma_Y\sqrt{1-\rho_{XY}^2}} \exp\left[-\frac{1}{2}\left(\frac{Z_X^2 - 2\rho_{XY}Z_XZ_Y + Z_Y^2}{1-\rho_{XY}^2}\right)\right],$$

$$Z_X = \frac{x - \mu_X}{\sigma_X}; Z_Y = \frac{y - \mu_Y}{\sigma_Y}.$$

Se X, Y são $N_2(\mu, \Omega)$, então X, Y são independentes se e só se $Cov(X, Y) = 0$.

- Distribuição do Chi-Quadrado com n graus de liberdade, $X \sim \chi_{(n)}^2$ é assimétrica e X é não negativa c.p.1

$$E(X) = n, Var(X) = 2n$$

Se $Z_i \sim i.i.d.N(0, 1)$, $i = 1, \dots, n$, então $X = \sum_{i=1}^n Z_i^2 \sim \chi_{(n)}^2$

- Distribuição do t-Student com n graus de liberdade, $X \sim t_{(n)}$ é simétrica em torno de zero.

$E(X) = 0$, $n > 1$, $Var(X) = \frac{n}{n-2}$, $n > 2$ (para que exista - finito).

$t_{(n)}$ tem mais massa nas abas do que a $N(0, 1)$ e $t_{(\infty)}$ é igual a $N(0, 1)$ c.p.1

Se $Z \sim N(0, 1)$, $X \sim \chi_{(n)}^2$, Z, X independentes, então $T = \frac{Z}{\sqrt{\frac{X}{n}}} \sim t_{(n)}$.

- Distribuição do F-Snedcor com (k_1, k_2) graus de liberdade, $X \sim F_{(k_1, k_2)}$ é assimétrica e X é não negativa c.p.1

Se $X_1 \sim \chi_{(k_1)}^2$, $X_2 \sim \chi_{(k_2)}^2$, X_1, X_2 independentes, então $F = \frac{X_1/k_1}{X_2/k_2} \sim F_{(k_1, k_2)}$.

5 Estimação

- Processo de "aprendizagem" sobre a população (desconhecido) com o recurso à informação contida numa amostra disponível que é extraída da população. Estimação Pontual; Estimação de Intervalos e Ensaio de Hipóteses. Exemplo de um objecto de interesse: O valor esperado da população.
- Suponha que a pdf dos Y 's é dada por $f(y; \theta)$. Então, $\{Y_1, \dots, Y_n\}$ é uma amostra aleatória de $f(y; \theta)$ se $Y_i \sim i.i.d. f(y; \theta), i = 1, \dots, n$. Os dados $\{y_1, \dots, y_n\}$ são habitualmente diferentes para cada amostra distinta.
- Estimador Pontual para θ , $W = h(Y_1, \dots, Y_n)$ e estimativa $w = h(y_1, \dots, y_n)$
- Propriedade de Amostra Finita da distribuição da v.a. W :

W é centrado se $E(W) = \theta$. $Bias(W) = E(W) - \theta$.

$Var(W)$ (eficiência)

W_1 é eficiente relativamente a W_2 quando $Var(W_1) < Var(W_2)$, com W_1, W_2 centrados.

Mean squared error (erro quadrático médio) $MSE(W) = Var(W) + [Bias(W)]^2$.

Example 4 A média amostral \bar{Y} é um estimador para o valor esperado (média populacional) μ e a variância amostral $S^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2$ para a variância (populacional) σ^2 .

6 Intervalo de Confiança

- Estimação de Intervalos e Intervalo de Confiança para o exemplo $Y \sim N(\mu, 1)$. Neste caso, $\bar{Y} \sim N\left(\mu, \frac{1}{n}\right)$.

$$(IC) P\left(\bar{Y} - \frac{1.96}{\sqrt{n}} < \mu < \bar{Y} + \frac{1.96}{\sqrt{n}}\right) = 0.95$$

(IE) $\bar{Y} - \frac{1.96}{\sqrt{n}} < \mu < \bar{Y} + \frac{1.96}{\sqrt{n}}$ é um intervalo aleatório

$$P\left(\bar{y} - \frac{1.96}{\sqrt{n}} < \mu < \bar{y} + \frac{1.96}{\sqrt{n}}\right) = 0 \text{ ou } 1$$

- Outros resultados importantes para o parâmetro de interesse μ :

(σ conhecido) $\left[\bar{y} - 1.96\frac{\sigma}{\sqrt{n}}, \bar{y} + 1.96\frac{\sigma}{\sqrt{n}}\right]$ porque $\frac{\bar{Y}-\mu}{\sigma/\sqrt{n}} \sim N(0, 1)$.

(σ desconhecido, $s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2}$). Porque $\frac{\bar{Y}-\mu}{S/\sqrt{n}} \sim t_{(n-1)}$ então, o IC a $100(1 - \alpha)\%$ é dado por $\left[\bar{y} - c_{(n-1, \alpha/2)}\frac{s}{\sqrt{n}}, \bar{y} + c_{(n-1, \alpha/2)}\frac{s}{\sqrt{n}}\right]$. Lembrar que para $\alpha = 0.05$, $c_{(n-1, \alpha/2)}$ tende para 1.96 (aprox. 2) quando n tende para infinito.

Quando, Y NÃO é normalmente distribuído, desde que n é suficientemente elevado, pelo TLC (CLT), pode-se usar a APROXIMAÇÃO a 95% IC $\left[\bar{y} - 1.96\frac{s}{\sqrt{n}}, \bar{y} + 1.96\frac{s}{\sqrt{n}}\right]$.

- Em relação ao parâmetro de interesse σ^2 , usar o resultado $\frac{(n-1)S^2}{\sigma^2} \sim \chi_{(n-1)}^2$ onde $Y \sim N(\mu, \sigma^2)$.

7 Inferência

- Passos num Ensaio de Hipóteses:

- (1) Definir a hipótese nula H_0 e hipótese alternativa H_1 em relação ao parâmetro (por exemplo) de interesse, que é desconhecido e do qual se procura inferir (ex: $H_0 : \mu = 1$ vs $H_1 : \mu \neq 1$)
- (2) Selecionar a estatística de teste apropriada T (ex: $T = \bar{Y}$)
- (3) Determinar a distribuição da estatística de teste T (ex: $\bar{Y} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$)
- (4) Escolher o nível de significância do teste $\alpha = P(\text{Re } jH_0/H_0)$ (erro do tipo I). Default: $\alpha = 0.05$. Com base em α , e sob H_0 , obter o(s) valor(es) crítico(s) vc :
 - (a) H_1 Unilateral: $P_{H_0}(T > vc) = \alpha$, para $H_1 : \theta > \theta_0$, OU $P_{H_0}(T < vc) = \alpha$, para $H_1 : \theta < \theta_0$.
 - (b) $H_1 : \theta \neq \theta_0$ Bilateral (normalmente): $P_{H_0}(|T| > vc) = \alpha$, se simétrica OU $P_{H_0}(T > vc_1) = \frac{\alpha}{2}$, $P_{H_0}(T < vc_2) = \frac{\alpha}{2}$ se não é simétrica.
- (5) Definir a regra de decisão (intervalos para T_{obs} delimitados com base no(s) vc) e as correspondentes regiões crítica e de aceitação. Decidir em relação ao teste vendo em que região "cai" T_{obs} . Este procedimento é equivalente à análise do IC a $100(1 - \alpha)\%$ da distribuição em 3., sob H_0 .

- Potência do teste $\pi(\theta) = 1 - P_{H_1}(AcH_0)$
- $p - value$ é o maior valor para α para o qual ainda não se rejeita H_0 :
 - (a) H_1 Unilateral: $p = P_{H_0}(T > T_{obs})$, para $H_1 : \theta > \theta_0$.
 - (b) $H_1 : \theta \neq \theta_0$ Bilateral: $p = P_{H_0}(|T| > |T_{obs}|)$ se simétrica.