

Amostras da Distribuição Normal p-variada e estimadores de Máxima Verossimilhança

$\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n$ vetores aleatórios p-dimensionais, constituindo uma amostra aleatória de uma distribuição normal com vetor de médias μ e matriz de covariância Σ .

Densidade de $\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n$

$$\prod_{i=1}^n \frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}} \exp \left\{ -\frac{1}{2} (\tilde{x}_i - \mu)' \Sigma^{-1} (\tilde{x}_i - \mu) \right\}$$

Problema:

μ e Σ desconhecidos, tomar essa função como função de μ e Σ e estimar μ e Σ por máxima verossimilhança.

$$L(\mu, \Sigma) = \frac{1}{(2\pi)^{np/2} |\Sigma|^{n/2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n (\tilde{x}_i - \mu)' \Sigma^{-1} (\tilde{x}_i - \mu) \right\}$$

$L(\mu, \Sigma)$ é a função de verossimilhança.

$$\text{Sejam } \bar{X} = \frac{1}{n} \sum_{i=1}^n \tilde{x}_i \text{ e } S = \frac{1}{n} \sum_{i=1}^n (\tilde{x}_i - \bar{X})(\tilde{x}_i - \bar{X})'$$

Resultado

Seja A matriz simétrica $p \times p$ e x um vetor $p \times 1$.

Então

$$x' A x = \text{tr} \left(\underbrace{x' A x}_{p \times p} \right) = \text{tr} (A x x')$$

a) $x' A x = \text{tr} (x' A x)$ porque $x' A x$ é um escalar.

b) ~~$B_{m \times k} C_{k \times n} \Rightarrow \text{tr}(BC) = \text{tr}(CB)$~~

Tomando $B = x'$ e $C = Ax \Rightarrow \text{tr}(x' A x) = \text{tr}(A x x')$

Cálculo dos Estimadores de máxima Verossimilhança
de μ e Σ .

$$(x - \mu)' \Sigma^{-1} (x - \mu) = \text{tr} \left[(x - \mu)' \Sigma^{-1} (x - \mu) \right] \\ = \text{tr} \left[\Sigma^{-1} (x - \mu)' (x - \mu) \right] * \underset{\uparrow}{①}$$

i.

$$\sum_{i=1}^n (x_i - \mu)^T \Sigma^{-1} (x_i - \mu) = \sum_{i=1}^n \text{tr} \left[\underbrace{\Sigma^{-1} (x_i - \mu) (x_i - \mu)^T}_{p \times p} \right]$$

$$= \text{tr} \left[\Sigma^{-1} \left(\sum_{i=1}^n (x_i - \mu) (x_i - \mu)^T \right) \right] \quad \# \textcircled{2}$$

$$\rightarrow \text{tr} \left(\sum_{i=1}^n A_i \right) = \sum_{i=1}^n \text{tr}(A_i)$$

Aleim disso

$$\sum_{i=1}^n (x_i - \mu) (x_i - \mu)^T \stackrel{\textcircled{3}}{=} \sum_{i=1}^n (x_i - \bar{x} + \bar{x} - \mu) (x_i - \bar{x} + \bar{x} - \mu)^T$$

$$= \sum_{i=1}^n (x_i - \bar{x}) (x_i - \bar{x})^T + \underbrace{\sum_{i=1}^n (x_i - \bar{x}) (\bar{x} - \mu)^T}_{\left[\sum_{i=1}^n (x_i - \bar{x}) \right] (\bar{x} - \mu)^T} + \underbrace{\sum_{i=1}^n (\bar{x} - \mu) (x_i - \bar{x})^T}_{(\bar{x} - \mu) \sum_{i=1}^n (x_i - \bar{x})^T}$$
$$+ \sum_{i=1}^n (\bar{x} - \mu) (\bar{x} - \mu)^T =$$

$$= \sum_{i=1}^n (x_i - \bar{x}) (x_i - \bar{x})^T + n (\bar{x} - \mu) (\bar{x} - \mu)^T \quad \textcircled{4}$$

$$\therefore \text{tr} \left[\Sigma^{-1} \left(\sum_{i=1}^n (x_i - \mu) (x_i - \mu)^T \right) \right] \stackrel{\textcircled{5}}{=} \Sigma (x_i - \mu)^T \Sigma^{-1} (x_i - \mu)$$

$$= \text{tr} \left\{ \Sigma^{-1} \left[\sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})' + n(\bar{x} - \mu)(\bar{x} - \mu)' \right] \right\}$$

$$= \text{tr} \left\{ \Sigma^{-1} \left[\sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})' \right] \right\} + n \text{tr} \left\{ \Sigma^{-1} (\bar{x} - \mu)(\bar{x} - \mu)' \right\}$$

$$= \text{tr} \left\{ \Sigma^{-1} \left[\sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})' \right] + n \text{tr} \underbrace{[(\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu)]}_{n^{-\sigma}} \right\}$$

$$= \text{tr} \left\{ \Sigma^{-1} \left[\sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})' \right] \right\} + n (\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu)$$

NS || $\Sigma (x_i - \mu)' \Sigma^{-1} (x_i - \mu)$

Oftimizar

$$l(\mu, \Sigma) = \ln L(\mu, \Sigma) = -\frac{1}{2} n \ln(2\pi) - \frac{1}{2} n \ln |\Sigma|$$

$$- \frac{1}{2} \text{tr} \ln \Sigma^{-1} S + - \frac{n}{2} (\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu)$$

Como Σ^{-1} é positiva definida, $(\bar{x} - \mu)' \Sigma^{-1} (\bar{x} - \mu)$ é mínima para $\mu = \bar{x}$. Portanto

$\hat{\mu} = \bar{x}$ é o estimador de máxima verossimilhança de μ .

Cálculo de $\hat{\Sigma}$

Para $\hat{\mu} = \bar{x}$,

$$\ell(\hat{\mu}, \Sigma) = \underbrace{-\frac{1}{2} n p \ln(2\pi)}_{c} - \frac{1}{2} n \ln |\Sigma| - \frac{1}{2} \text{tr} [n \Sigma^{-1} S]$$

$$= c - \frac{1}{2} n \left\{ \ln |\Sigma| + \text{tr} [\Sigma^{-1} S] \right\}$$

Lema

Seja $f(\Sigma) = \log |\Sigma| + \text{tr} [\Sigma^{-1} A]$,

Se $A > 0$ e $\Sigma > 0$, então $f(\Sigma)$ é mínima para $\Sigma = A$.

Demonstração: Seer - Multivariate Observations pag 523 (resultado A.7.1)

Pelo lema, $\ell(\hat{\mu}, \Sigma)$ é mínima para $\hat{\Sigma} = S$.

Verifica-se que S é positiva definida pelo resultado A.5.13 Seer pag 522.

Portanto o estimador de máxima verossimilhança de Σ é $S = \frac{1}{n} \sum_{i=1}^n (\tilde{x}_i - \bar{x})(\tilde{x}_i - \bar{x})'$.

Propriedades dos Estimadores

$$E(\bar{x}) = \mu$$

$$\text{Var}(\bar{x}) = \frac{1}{n} \sum \quad \left. \begin{array}{l} \\ \end{array} \right\} \text{Do tópico 2}$$

$$E(S) = \frac{n-1}{n} \sum \quad \left. \begin{array}{l} \\ \end{array} \right\} \text{se } x_1, \dots, x_n \text{ i.i.d. } \sim N_p(\mu, \Sigma)$$

Verifica-se através de resultados que $\bar{x} \sim N_p(\mu, \frac{1}{n} \Sigma)$

Qual a distribuição de S?

Sejam y_1, y_2, \dots, y_n vetores aleatórios p dimensionais independentes com $y_i \sim N_p(0, \Sigma)$. A matriz aleatória

$y = \sum_{i=1}^n y_i y_i'$ tem distribuição de Wishart, cuja densi-

$\underbrace{\quad}_{p \times 1} \quad \underbrace{\quad}_{p \times p}$

dade é

$$w(y, \Sigma, n) = \begin{cases} \frac{|y|^{\frac{n-p-1}{2}}}{2^{\frac{np}{2}} \pi^{\frac{p(p-1)}{4}} | \Sigma |^{\frac{n}{2}}} \prod_{i=1}^p \prod_{j=1}^{\frac{n+1-i}{2}} \exp\left(-\frac{1}{2} \text{tr } y \Sigma^{-1}\right) & \text{para } y \text{ positiva definida} \\ 0 & \text{caso contrário} \end{cases}$$

y matriz $p \times p$ de valores de y

$\text{tr} \rightarrow$ função gama, $w(y, \Sigma, n)$ é unidim. Este função não será utilizada

n - denominado número de graus de liberdade

Para $p=1$, $Y_i \sim N(0, 1)$, $Y = \sum_{i=1}^n Y_i Y_i^T = \sum_{i=1}^n Y_i^2 \sim \chi_n^2$. A dist. de Wishart é a extensão

da dist. qui-quadrado para p qualquer. Essa dist. tem várias propriedades da qui-quadrado. Em particular,

Se Z_1, Z_2, \dots, Z_K são matrizes aleatórias independentes com distribuições de Wishart com parâmetros Σ e graus de liberdade n_1, n_2, \dots, n_K , então

$$\sum_{j=1}^K Z_j \sim W(\Sigma, n_1 + n_2 + \dots + n_K)$$

dist de Wishart com parâmetros Σ , e gl = $n_1 + n_2 + \dots + n_K$.
de $X_i \sim N_p(\mu, \Sigma)$ e se independentes
Verifica-se que, se $n-1 \geq p$ então

$$(n-1) S^* \stackrel{MS}{\sim} W(\Sigma, n-1)$$

Resultado

Sejam $\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_n$ amostra aleatória de tamanho n da distribuição normal p -variação com vetor de médias M e matriz de covariância Σ . Então

a) $\bar{\tilde{x}} \sim N_p(M, \frac{1}{n} \Sigma)$ n-17/p.

b) $(n-1)S^* = nS \sim W(\Sigma, n-1)$ $S^* = \frac{1}{n-1} \sum_{i=1}^n (\tilde{x}_i - \bar{\tilde{x}})(\tilde{x}_i - \bar{\tilde{x}})^T$

c) $\bar{\tilde{x}}$ e S são independentes.

Obs: Como Σ é desconhecido, a distribuição de $\bar{\tilde{x}}$ não pode ser usada diretamente na inferência sobre M . A distribuição de S não depende de M e dessa forma, sendo S independente de $\bar{\tilde{x}}$, é possível construir uma estatística, que será a base para a inferência sobre M .

$$\tilde{x}_i \sim N_p \Rightarrow \bar{\tilde{x}} \sim N_p.$$

Se \tilde{x}_i não tiver distribuição normal?

Teorema do Limite Central Multivariado

Sejam $\tilde{X}_1, \tilde{X}_2, \dots, \tilde{X}_n$ vetores aleatórios p dimensionais independentes com média μ e matriz de covariância Σ . Para $n \rightarrow \infty$,

$$\sqrt{n}(\bar{\tilde{X}} - \mu) \xrightarrow{d} N_p(0, \Sigma).$$

Demonstrações:

T.W. Anderson - An Introduction to Multivariate Statistical Analysis.

Correlações e Regressão na Distribuição Normal multivariada

Obtidos os estimadores de máxima verossimilhança de θ_{jk} , $j, k = 1, 2, \dots, p$, queremos determinar os estimadores de máxima verossimilhança de ρ_{jk} , $j \neq k$.

Bem

Se a função distribuição de uma variável aleatória ou vetor aleatório depende dos parâmetros $\theta_1, \theta_2, \dots, \theta_m$ e $\lambda_j, j=1, 2, \dots, m$ são parâmetros univocamente determinados por

$$\lambda_1 = h_1(\theta_1, \theta_2, \dots, \theta_m)$$

:

$$\lambda_m = h_m(\theta_1, \theta_2, \dots, \theta_m)$$

e se $\hat{\theta}_1, \dots, \hat{\theta}_m$ são os estimadores de máxima verossimilhança de $\theta_1, \theta_2, \dots, \theta_m$ então, os estimadores de máxima verossimilhança de $\lambda_1, \lambda_2, \dots, \lambda_m$ são

$$\hat{\lambda}_1 = h_1(\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m) \dots \hat{\lambda}_m = h_m(\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_m).$$

Como consequência, se $X_i, i=1, 2, \dots, n$ é uma amostra aleatória da dist. $N(\mu, \Sigma)$, os estimadores de máxima verossimilhança de $\rho_{jk} = \text{Corr}(X_j, X_k)$ são

$$r_{jk} = \frac{s_{jk}}{\sqrt{s_{jj}} \sqrt{s_{kk}}} = \frac{\sum_{i=1}^n (X_{ij} - \bar{X}_j)(X_{ik} - \bar{X}_k)}{\sqrt{\sum_{i=1}^n (X_{ij} - \bar{X}_j)^2} \sqrt{\sum_{i=1}^n (X_{ik} - \bar{X}_k)^2}}$$

$$j, k = 1, 2, \dots, p \quad j \neq k.$$

Em particular, para $p=2$, amostra de n pares da distribuições normal bivariada,

$$\rho = \text{Corr}(X_1, X_2) \quad \hat{\rho} = r \rightarrow \text{coef. de correlações amostral}$$

$$r = \frac{\sum_{i=1}^n (x_{i1} - \bar{x}_1)(x_{i2} - \bar{x}_2)}{\sqrt{\sum_{i=1}^n (x_{i1} - \bar{x}_1)^2} \sqrt{\sum_{i=1}^n (x_{i2} - \bar{x}_2)^2}}$$

Verifica-se que se $\rho=0$, a variável aleatória r tem densidade

$$f(r) = \begin{cases} \frac{1}{\sqrt{\pi}} \frac{\pi(\frac{n-1}{2})}{\pi(\frac{n-2}{2})} (1-r^2)^{\frac{n-4}{2}}, & -1 \leq r \leq 1 \\ 0 & \text{caso contrário} \end{cases}$$

e

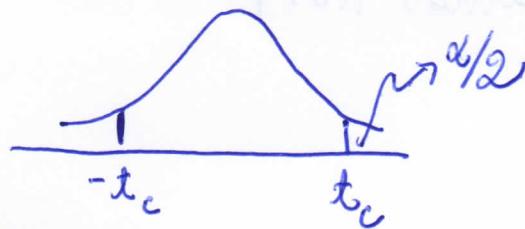
$$t = \frac{n \sqrt{n-2}}{\sqrt{1-r^2}} \sim t_{n-2} \quad (\text{distribuições t-student com } n-2 \text{ gl})$$

$$H_0: \rho = 0$$

$$H_a: \rho \neq 0$$

Rejeitamos H_0 ao nível α se $|t_{obs}| \geq t_c$,

$$P(t_{m-2} \geq t_c) = \frac{\alpha}{2}$$



A partir daí, obtemos os correspondentes testes unicaudais. Se $\rho \neq 0$, a distribuição de r não tem uma forma simples. Verifica-se no entanto que

$$\left(W - \frac{1}{2} \ln \frac{1+\rho}{1-\rho} \right) \sqrt{n-3} \xrightarrow[n \rightarrow \infty]{D} N(0,1)$$

onde $W = \frac{1}{2} \ln \frac{1+r}{1-r}$.

$$H_0: \rho = \rho_0$$

$$H_a: \rho \neq \rho_0$$

Rejeitamos H_0 se $\left| W - \frac{1}{2} \ln \frac{1+\rho_0}{1-\rho_0} \right| \sqrt{n-3} \geq z_c$,

$$z_c \mid P(Z \geq z_c) = \frac{\alpha}{2}, Z \sim N(0,1)$$

Teste de igualdade de dois coeficientes de correlação

$$\tilde{X} = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix} \sim N_2 \quad \tilde{Y} = \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} \sim N_2$$

$\tilde{X}_{11}, \tilde{X}_{12}, \dots, \tilde{X}_{n_1}$ e $\tilde{Y}_{11}, \tilde{Y}_{12}, \dots, \tilde{Y}_{n_2}$ duas amostras aleatórias independentes entre si das distribuições de \tilde{X} e \tilde{Y} respectivamente.

$$H_0: \rho_{X_1 X_2} = \rho_{Y_1 Y_2}$$

$$H_a: \rho_{X_1 X_2} \neq \rho_{Y_1 Y_2}$$

$$D = \frac{\frac{1}{2} \ln \frac{1+r_{X_1 X_2}}{1-r_{X_1 X_2}} - \frac{1}{2} \ln \frac{1+r_{Y_1 Y_2}}{1-r_{Y_1 Y_2}}}{\sqrt{\frac{1}{m_1-3} + \frac{1}{m_2-3}}}$$

Rejeitamos H_0 ao nível α se

$$|D| > z_{\alpha/2} \quad z_{\alpha/2} \mid P(Z \geq z_{\alpha/2}) = \frac{\alpha}{2}, Z \sim N(0, 1)$$

$$\begin{array}{ll} \text{Ex: } X_1 - \text{altura homens} & Y_1 - \text{altura mulheres} \\ X_2 - \text{peso homens} & Y_2 - \text{peso mulheres} \end{array}$$

$\rho_{X_1 X_2} = \rho_{Y_1 Y_2}$ a correlação entre peso e altura para homens é a mesma que para mulheres.

$$X^{(1)} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_q \end{bmatrix} \quad X^{(2)} = \begin{bmatrix} X_{q+1} \\ \vdots \\ X_p \end{bmatrix}$$

$$X \sim N_p(\mu, \Sigma) \quad \mu = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} \quad \Sigma = \begin{bmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{bmatrix}$$

$$X^{(1)} | X^{(2)} = x_2 \sim N_q \left(\mu_1 + \Sigma_{12} \Sigma_{22}^{-1} (x_2 - \mu_2), \Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21} \right)$$

Os elementos da matriz $\Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21}$ são denominados variâncias e covariâncias parciais pois medem a variabilidade e a dependência entre os elementos de $X^{(1)}$ fixados os valores de $X^{(2)}$.

mados variâncias e covariâncias parciais pois medem a variabilidade e a dependência entre os elementos de $X^{(1)}$ fixados os valores de $X^{(2)}$.

Se

$$\delta_{jk}, q+1, q+2, \dots, p, \quad j, k = 1, 2, \dots, q$$

é o elemento de ordem jk da matriz $\Sigma_{11} - \Sigma_{12} \Sigma_{22}^{-1} \Sigma_{21}$
o valor

$$P_{jk}, q+1, q+2, \dots, p = \frac{\delta_{jk}, q+1, q+2, \dots, p}{\sqrt{\delta_{jj}, q+1, q+2, \dots, p} \delta_{kk}, q+1, q+2, \dots, p}$$

é denominado coeficiente de correlação parcial entre X_j e X_k fixados $X_{q+1}, X_{q+2}, \dots, X_p$.

Se $X^{(1)}$ é unidimensional $X^{(1)} = [X_1]$ e $X^{(2)} = \begin{bmatrix} X_{q+1} \\ X_{q+2} \\ \vdots \\ X_p \end{bmatrix}$,

$$\text{seja } Y = \beta^T X^{(2)} = \underbrace{\beta_{q+1} X_{q+1} + \beta_{q+2} X_{q+2} + \dots + \beta_p X_p}_{1 \times p-q \quad p-q \times 1 \quad 1 \times 1}$$

$$\text{com } \beta = [\beta_{q+1} \ \beta_{q+2} \ \dots \ \beta_p].$$

Verifica-se que o máximo valor de $\text{Corr}(X_1, Y)$ é obtido para

$$\beta = \sum_{22}^{-1} S_{12} \quad \text{onde}$$

$$S_{12} = \text{Cov}(X_1, X^{(2)}) = [S_{1q+1} \ S_{1q+2} \ \dots \ S_{1p}]$$

e

$$Y = S_{12} \sum_{22}^{-1} X^{(2)}.$$

$$\begin{aligned}\text{Cov}(X_1, Y) &= \text{Cov}\left(X_1, \delta_{12}^1 \sum_{22}^{-1} X^{(2)}\right) = \\ &= \text{Cov}(X_1, X^{(2)}) \sum_{22}^{-1} \delta_{12} = \delta_{12}^1 \sum_{22}^{-1} \delta_{12} = \\ &\quad \downarrow x(p-q)(p-q)x(p-q)(p-q) x_1\end{aligned}$$

$$\begin{aligned}\text{Var}(Y) &= \text{Var}(\beta^1 X^{(2)}) = \text{Var}\left(\delta_{12}^1 \sum_{22}^{-1} X^{(2)}\right) = \\ &= \delta_{12}^1 \sum_{22}^{-1} \sum_{22} \sum_{22}^{-1} \delta_{12} = \delta_{12}^1 \sum_{22}^{-1} \delta_{12} = \\ &\quad \downarrow x\end{aligned}$$

$$\therefore \text{Corr}(X_1, Y) = \frac{\delta_{12}^1 \sum_{22}^{-1} \delta_{12}}{\sqrt{\delta_{11}} \sqrt{\delta_{12}^1 \sum_{22}^{-1} \delta_{12}}} = \frac{\sqrt{\delta_{12}^1 \sum_{22}^{-1} \delta_{12}}}{\sqrt{\delta_{11}}}$$

$\text{Corr}(X_1, Y)$ é o coeficiente de correlação múltipla entre X_1 e os elementos de $X^{(2)}$.

$\beta = \sum_{22}^{-1} \delta_{12}$ é o vetor de coeficientes de regressão da variável X_1 em função dos elementos de $X^{(2)}$.