

# Modelo normal linear multivariado

Prof. Caio Azevedo

# Suposições

- Dados de Potthoff and Roy (Exemplo 2).
- Dois grupos (11 meninas e 16 meninos), quatro instantes de avaliação.
- Objetivo: comparação entre grupos e instantes.

- Seja  $Y_{ijk}$  : a distância medida no k-ésimo instante ( $k=1,2,3,4$ ), para o j-ésimo indivíduo ( $j = 1, \dots, n_i$ ) do i-ésimo grupo ( $i = 1, 2$ ),  $n_1 = 11$  (meninas),  $n_2 = 16$  (meninos).
- Suposição  $\mathbf{Y}_{ij} = (Y_{ij1}, Y_{ij2}, Y_{ij3}, Y_{ij4}) \stackrel{ind.}{\sim} N_4(\boldsymbol{\mu}_i, \boldsymbol{\Sigma})$ .

$$\mathbf{Y}_{(n \times p)} = \begin{bmatrix}
 Y_{111} & Y_{112} & Y_{113} & Y_{114} \\
 Y_{121} & Y_{122} & Y_{123} & Y_{124} \\
 \vdots & \vdots & \ddots & \vdots \\
 Y_{1(11)1} & Y_{1(11)2} & Y_{1(11)3} & Y_{1(11)4} \\
 \text{---} & \text{---} & \text{---} & \text{---} \\
 Y_{211} & Y_{212} & Y_{213} & Y_{214} \\
 Y_{221} & Y_{222} & Y_{223} & Y_{224} \\
 \vdots & \vdots & \ddots & \vdots \\
 Y_{2(16)1} & Y_{2(16)2} & Y_{2(16)3} & Y_{2(16)4}
 \end{bmatrix}$$

# Suposições

- Suponha um conjunto de  $G$  populações independentes da qual retiramos  $G$  amostras de tamanho  $n_i$ ,  $i = 1, \dots, G$ ,
- Por suposição, temos que  $\mathbf{Y}_{ij} \sim N_p(\boldsymbol{\mu}_i, \boldsymbol{\Sigma})$ , em que  $i = 1, 2, \dots, G$  (grupo) e  $j = 1, 2, \dots, n_i$  (indivíduo). Notação:  $Y_{ijk}$  observação referente à condição de avaliação  $k$  do indivíduo  $j$  do grupo  $i$ .
- Homocedasticidades:  $\boldsymbol{\Sigma}_1 = \boldsymbol{\Sigma}_2 = \dots = \boldsymbol{\Sigma}_G = \boldsymbol{\Sigma}$ . Além disso,  $\boldsymbol{\Sigma}$  tem de ser não estruturada (variâncias e covariâncias livres).

# Suposições

- Matriz de covariâncias não estruturada:  $\Sigma = Cov(\mathbf{Y}) =$

$$\mathcal{E}[(\mathbf{Y} - \boldsymbol{\mu})(\mathbf{Y} - \boldsymbol{\mu})'] = \mathcal{E}(\mathbf{Y}\mathbf{Y}') - \boldsymbol{\mu}\boldsymbol{\mu}' = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{12} & \sigma_2^2 & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1p} & \sigma_{2p} & \dots & \sigma_p^2 \end{bmatrix}$$

- Os dados têm de ser balanceados (em relação às condições de avaliação) e completos (podem ser regulares ou irregulares).
- Assim, temos a seguinte matriz de dados ( $n = \sum_{i=1}^G n_i$ ):

$$\mathbf{Y}_{(n \times p)} = \begin{bmatrix}
 Y_{111} & Y_{112} & \dots & Y_{11p} \\
 Y_{121} & Y_{122} & \dots & Y_{12p} \\
 \vdots & \vdots & \ddots & \vdots \\
 Y_{1n_11} & Y_{1n_12} & \dots & Y_{1n_1p} \\
 \hline
 Y_{211} & Y_{212} & \dots & Y_{21p} \\
 Y_{221} & Y_{222} & \dots & Y_{22p} \\
 \vdots & \vdots & \ddots & \vdots \\
 Y_{2n_21} & Y_{2n_22} & \dots & Y_{2n_2p} \\
 \hline
 \vdots & \vdots & \ddots & \vdots \\
 \hline
 Y_{G11} & Y_{G12} & \dots & Y_{G1p} \\
 Y_{G21} & Y_{G22} & \dots & Y_{G2p} \\
 \vdots & \vdots & \ddots & \vdots \\
 Y_{Gn_G1} & Y_{Gn_G2} & \dots & Y_{Gn_Gp}
 \end{bmatrix}$$

- Queremos testar

$H_0 : \mu_1 = \mu_2 = \dots = \mu_G$  vs  $H_1$  : pelo menos uma diferença.

- Uma abordagem: análise de variância multivariada (MANOVA).
- Comparar médias através do estudo da decomposição da matriz de variâncias-covariâncias total.
- Como resumir a informação das matrizes de covariâncias de interesse? Variâncias generalizadas.



# Modelo linear normal multivariado

$$\mathbf{Y}_{(n \times p)} = \mathbf{X}_{(n \times q)} \mathbf{B}_{(q \times p)} + \boldsymbol{\xi}_{(n \times p)}$$

- $\mathbf{Y}_{(n \times p)}$ : matriz de dados
- $\mathbf{X}_{(n \times q)}$ : matriz de planejamento, conhecida e não-aleatória.
- $\mathbf{B}_{(q \times p)}$ : parâmetros de interesse, desconhecido e não aleatório.
- $\boldsymbol{\xi}_{(n \times p)}$ : matriz de resíduos,  $\xi_{ij} \stackrel{ind.}{\sim} N_p(\mathbf{0}, \boldsymbol{\Sigma})$ , logo  $\mathbf{Y}_{ij} \stackrel{ind.}{\sim} N_p(\mathbf{X}_{ij}, \boldsymbol{\Sigma})$ , em que  $\mathbf{X}_{ij}$  é a linha da matriz  $\mathbf{X}$  correspondente ao indivíduo  $j$  do grupo  $i$ .

$$\mathbf{X}_{(n \times q)} = \begin{bmatrix}
 X_{111} & X_{112} & \dots & X_{11G} \\
 X_{121} & X_{122} & \dots & X_{12G} \\
 \vdots & \vdots & \vdots & \vdots \\
 X_{1n_11} & X_{1n_12} & \dots & X_{1n_1G} \\
 \hline
 \vdots & \vdots & \vdots & \vdots \\
 \hline
 X_{G11} & X_{G12} & \dots & X_{G1G} \\
 X_{G21} & X_{G22} & \dots & X_{G2G} \\
 \vdots & \vdots & \vdots & \vdots \\
 X_{Gn_GG} & X_{Gn_GG} & \dots & X_{Gn_GG}
 \end{bmatrix}; \mathbf{B}_{(q \times p)} = \begin{bmatrix}
 \mu_{11} & \mu_{12} & \dots & \mu_{1p} \\
 \mu_{21} & \mu_{22} & \dots & \mu_{2p} \\
 \vdots & \vdots & \vdots & \vdots \\
 \mu_{G1} & \mu_{G2} & \dots & \mu_{Gp}
 \end{bmatrix}$$

$$\boldsymbol{\xi}_{(n \times p)} = \begin{bmatrix} \xi_{111} & \xi_{112} & \dots & \xi_{11p} \\ \xi_{121} & \xi_{122} & \dots & \xi_{12p} \\ \vdots & \vdots & \ddots & \vdots \\ \xi_{1n_11} & \xi_{1n_12} & \dots & \xi_{1n_1p} \\ \hline \xi_{211} & \xi_{212} & \dots & \xi_{21p} \\ \xi_{221} & \xi_{222} & \dots & \xi_{22p} \\ \vdots & \vdots & \ddots & \vdots \\ \xi_{2n_21} & \xi_{2n_22} & \dots & \xi_{2n_2p} \\ \hline \vdots & \vdots & \ddots & \vdots \\ \hline \xi_{G11} & \xi_{G12} & \dots & \xi_{G1p} \\ \xi_{G21} & \xi_{G22} & \dots & \xi_{G2p} \\ \vdots & \vdots & \ddots & \vdots \\ \xi_{Gn_G1} & \xi_{Gn_G2} & \dots & \xi_{Gn_Gp} \end{bmatrix}$$

# Nosso exemplo:

- Temos:  $G = 2$ ,  $p = 4$ ,  $n_1 = 11$ ,  $n_2 = 16$ , (2 grupos, quatro instantes, 11 e 16 indivíduos por grupo, respectivamente).
- Modelar as médias.
- $\mathbf{Y}_{(27 \times 4)}$ .

## Nosso exemplo: parametrização de médias

$$\blacksquare \mathbf{X} = \begin{bmatrix} \mathbf{1}_{(11 \times 1)} & \mathbf{0}_{(11 \times 1)} \\ \mathbf{0}_{(16 \times 1)} & \mathbf{1}_{(16 \times 1)} \end{bmatrix}$$

$$\blacksquare \mathbf{B} = \begin{bmatrix} \mu_{11} & \mu_{12} & \mu_{13} & \mu_{14} \\ \mu_{21} & \mu_{22} & \mu_{23} & \mu_{24} \end{bmatrix}$$

- $\mu_{ip}$  : média da distância na condição de avaliação  $p$  do grupo  $i$ .

# Nosso exemplo: parametrização casela de referência (grupo feminino):

$$\blacksquare \mathbf{X} = \begin{bmatrix} \mathbf{1}_{(11 \times 1)} & \mathbf{0}_{(11 \times 1)} \\ \mathbf{1}_{(16 \times 1)} & \mathbf{1}_{(16 \times 1)} \end{bmatrix}$$

$$\blacksquare \mathbf{B} = \begin{bmatrix} \mu_{11} & \mu_{12} & \mu_{13} & \mu_{14} \\ \alpha_{21} & \alpha_{22} & \alpha_{23} & \alpha_{24} \end{bmatrix}$$

- $\mu_{1p}$  : média da distância na condição de avaliação  $p$  do grupo 1 (grupo de referência).

# Decomposição da matriz de covariâncias total

- Pode-se demonstrar que (fazendo  $\bar{\mathbf{Y}}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \mathbf{Y}_{ij}$ ,

$$\bar{\mathbf{Y}} = \frac{1}{n} \sum_{i=1}^G \sum_{j=1}^{n_i} \mathbf{Y}_{ij}):$$

$$\underbrace{\sum_{i=1}^G \sum_{j=1}^{n_i} (\mathbf{Y}_{ij} - \bar{\mathbf{Y}}) (\mathbf{Y}_{ij} - \bar{\mathbf{Y}})'}_{\text{Matriz de SQ Total}} = \underbrace{\sum_{i=1}^G n_i (\bar{\mathbf{Y}}_i - \bar{\mathbf{Y}}) (\bar{\mathbf{Y}}_i - \bar{\mathbf{Y}})'}_{\text{Matriz de SQ do Modelo}} + \underbrace{\sum_{i=1}^G \sum_{j=1}^{n_i} (\mathbf{Y}_{ij} - \bar{\mathbf{Y}}_i) (\mathbf{Y}_{ij} - \bar{\mathbf{Y}}_i)'}_{\text{Matriz de SQ do Resíduo}}$$
$$\mathbf{T} = \mathbf{M} + \mathbf{E}$$

# Variância generalizada

- Seja  $\Sigma_{(p \times p)}$  uma matriz de covariâncias.
- Variância generalizada  $|\Sigma|$  (resume a informação contida em  $\Sigma$ ).
- Suponha  $p = 2$ .
- Assim  $|\Sigma| = \sigma_1^2 \sigma_2^2 - \sigma_{11}^2 = \sigma_1^2 \sigma_2^2 - \sigma_1^2 \sigma_2^2 \rho^2 = \sigma_1^2 \sigma_2^2 (1 - \rho^2)$ .
- Estamos supondo que  $\Sigma_1 = \Sigma_2 = \dots = \Sigma_G = \Sigma$  (teste de Box para igualdade de matrizes de covariâncias).



## As quatro estatísticas “tradicionais”

- Sejam  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_s$  os autovalores diferentes de zero da matriz  $\mathbf{E}^{-1}\mathbf{M}$ , em que  $s = \min(p, G - 1)$ .

- Lambda de Wilkis: 
$$\prod_{i=1}^s \frac{1}{1 + \lambda_i} = \frac{|\mathbf{E}|}{|\mathbf{E} + \mathbf{M}|}.$$

- Traço de Pillai: 
$$\sum_{i=1}^s \frac{\lambda_i}{1 + \lambda_i} = \text{tr}[\mathbf{M}(\mathbf{M} + \mathbf{E})^{-1}].$$

- Traço de Lawley-Hotelling: 
$$\sum_{i=1}^s \lambda_i^{-1} = \text{tr}[\mathbf{M}\mathbf{E}^{-1}]$$

- Máxima raiz de Roy: 
$$\frac{\lambda_1}{1 + \lambda_1}$$

## Cont.

- Quanto menor for o valor das estatística de Wilks e maior forem os valores das estatísticas de Pillai, Lawley-Hotelling e de Roy, mais evidências tem-se contra  $H_0$ .
- Existem aproximações pela distribuição F, para cada uma destas estatísticas (pesquisar).
- Verificação da normalidade multivariada: Se  $\mathbf{Y}_{ij} \stackrel{ind.}{\sim} N_p(\mathbf{X}_{ij}\mathbf{B}, \mathbf{\Sigma})$ , então para n suficientemente grande:

$$\frac{n}{n-1} (\mathbf{Y}_{ij} - \bar{\mathbf{Y}}_i)' (\mathbf{S}_i^2)^{-1} (\mathbf{Y}_{ij} - \bar{\mathbf{Y}}_i) \\ \approx (\mathbf{Y}_{ij} - \bar{\mathbf{Y}}_i)' (\mathbf{S}_i^2)^{-1} (\mathbf{Y}_{ij} - \bar{\mathbf{Y}}_i) \sim \chi^2_{(p)}$$

# Teste para verificar a homocedasticidade

- Queremos testar se  $H_0 : \Sigma_1 = \dots = \Sigma_G$  vs  $H_1$  : há pelo menos uma diferença.
- A estatística do t.r.v, é tal que (exercício):

$$\Lambda \propto \prod_{i=1}^G \left[ \frac{|\mathbf{S}_i^2|}{|\mathbf{S}_P^2|} \right]^{(n_i-1)/2}$$

$$\mathbf{S}_P^2 = \frac{1}{\sum_{i=1}^G (n_i - 1)} \left[ \sum_{i=1}^G (n_i - 1) \mathbf{S}_i^2 \right]; \mathbf{S}_i^2 = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (\bar{\mathbf{Y}}_i - \mathbf{Y}_{ij}) (\bar{\mathbf{Y}}_i - \mathbf{Y}_{ij})'$$

- Sob  $H_0$ ,  $-2 \ln \Lambda \approx \chi^2_{(\nu)}$ , em que  $\nu = (G - 1)p(p + 1)/2$ .
- Correção proposta por Box para melhorar a performance da estatística acima é:

$$\begin{aligned}
 Q_B &= (1 - u)(-2 \ln \Lambda) = \\
 &= (1 - u) \left\{ \left[ \sum_{i=1}^G (n_i - 1) \right] \ln |\mathbf{S}_P^2| - \sum_{i=1}^G \left[ (n_i - 1) \ln |\mathbf{S}_i^2| \right] \right\}
 \end{aligned}$$

em que

$$u = \left[ \sum_{i=1}^G \frac{1}{n_i - 1} - \frac{1}{\sum_{i=1}^G (n_i - 1)} \right] \left[ \frac{2p^2 + 3p - 1}{6(p+1)(g-1)} \right]$$





- Sob  $H_0$ ,  $Q_B \approx \chi^2_{(u)}$ .

# Teste para verificar a homocedasticidade





- Resultados:  $q_{B(calc)} = 17,33(0,0673)$ .
- Estimativas das matrizes de covariâncias:

grupo	d8	d10	d12	d14
1	4,51	3,35	4,33	4,36
1	3,35	3,62	4,03	4,08
1	4,33	4,03	5,59	5,47
1	4,36	4,08	5,47	5,94
2	6,02	2,29	3,63	1,61
2	2,29	4,56	2,19	2,81
2	3,63	2,19	7,03	3,24
2	1,61	2,81	3,24	4,35



# Gráficos de quantis-quantis com envelope (feminino)



# Gráficos de quantis-quantis com envelope (masculino)



# Gráficos de quantis-quantis para a forma quadrática





# Estatísticas

<b>Estatística</b>	<b>Valor</b>	<b>Aproxim. pela dist. F.</b>	<b>p-valor</b>
Wilks	0,602	3,632	0,0203
Pillai	0,398	3,632	0,0203
Hotelling-Lawley	0,6603	3,632	0,0203
Roy	0,6603	3,632	0,0203

A igualdade simultânea dos vetores de médias é rejeitada (marginalmente), para cada uma das estatísticas. Como realizar outras comparações de interesse?

# Anova para cada variável

- Idade de 8 anos:  $f = 3,451$  (0,0751).
- Idade de 10 anos:  $f = 3,914$  (0,0600).
- Idade de 12 anos:  $f = 6,973$  (0,0141).
- Idade de 14 anos:  $f = 14,918$  (0,0008).

# Forma vetorial

- Considere novamente o modelo:  $\mathbf{Y}_{(n \times p)} = \mathbf{X}_{(n \times q)}\mathbf{B}_{(q \times p)} + \boldsymbol{\xi}_{(n \times p)}$ .  
Assim, note que:

$$\mathbf{Y}'_{(p \times n)} = \mathbf{B}'_{(p \times q)}\mathbf{X}'_{(q \times n)} + \boldsymbol{\xi}'_{(p \times n)}$$

$$\text{vec}(\mathbf{Y}) = (\mathbf{X}_{(n \times q)} \otimes \mathbf{I}_p) \text{vec}(\mathbf{B}') + \text{vec}(\boldsymbol{\xi}')$$

$$\mathbf{Y}^*_{(np \times 1)} = \mathbf{X}^*_{(np \times pq)}\boldsymbol{\beta}_{(pq \times 1)} + \boldsymbol{\xi}^*_{(np \times 1)}$$

pois  $\text{vec}(\mathbf{ABC}) = (\mathbf{C}' \otimes \mathbf{A})\text{vec}(\mathbf{B})$ .

- Note, assim, que as observações dos indivíduos foram concatenadas (uma abaixo da outra), nos vetores  $\mathbf{Y}^*$  e  $\boldsymbol{\xi}^*$ .

## Cont.

- Portanto, temos que  $\mathbf{Y}^* \sim N_{pn}(\mathbf{X}^*\boldsymbol{\beta}, \boldsymbol{\Sigma}^*)$ , em que

$$\boldsymbol{\Sigma}^* = \mathbf{I}_n \otimes \boldsymbol{\Sigma}_{(p \times p)}$$

- O estimador de mínimos quadrados generalizados de  $\boldsymbol{\beta}$  é obtido minimizando-se

$$(\mathbf{Y}^* - \mathbf{X}^*\boldsymbol{\beta})' \boldsymbol{\Sigma}^{*-1} (\mathbf{Y}^* - \mathbf{X}^*\boldsymbol{\beta}).$$

- O que implica que  $\hat{\boldsymbol{\beta}} = \left( \mathbf{X}^{*'} \boldsymbol{\Sigma}^{*-1} \mathbf{X}^* \right)^{-1} \mathbf{X}^{*'} \boldsymbol{\Sigma}^{*-1} \mathbf{Y}^*$

## Cont.

- Note que

$$\begin{aligned}\hat{\beta} &= [(\mathbf{X} \otimes \mathbf{I})' (\mathbf{I} \otimes \boldsymbol{\Sigma})^{-1} (\mathbf{X} \otimes \mathbf{I})]^{-1} (\mathbf{X} \otimes \mathbf{I})' (\mathbf{I} \otimes \boldsymbol{\Sigma})^{-1} \mathbf{Y}^* \\ &= [(\mathbf{X}'\mathbf{X} \otimes \boldsymbol{\Sigma}^{-1})]^{-1} [\mathbf{X}' \otimes \boldsymbol{\Sigma}^{-1}] \mathbf{Y}^* \\ &= [(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \otimes \mathbf{I}] \mathbf{Y}^* \\ &= \mathbf{A} \mathbf{Y}^*\end{aligned}\tag{1}$$

- Por outro lado, temos que

$$\mathcal{E}(\hat{\beta}) = [(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \otimes \mathbf{I}] [\mathbf{X} \otimes \mathbf{I}] \beta = \beta.$$

- Além disso,

$$\text{Cov}(\hat{\beta}) = [(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \otimes \mathbf{I}] [\mathbf{I} \otimes \boldsymbol{\Sigma}] [\mathbf{X} (\mathbf{X}\mathbf{X}')^{-1} \otimes \mathbf{I}] = (\mathbf{X}'\mathbf{X})^{-1} \otimes \boldsymbol{\Sigma}$$

## Cont.

- Logo,  $\hat{\beta} \sim N_{pq}(\beta, \Sigma_\beta)$ , em que  $\Sigma_\beta = (\mathbf{X}'\mathbf{X})^{-1} \otimes \Sigma$ .
- Portanto, se  $\Sigma$  for conhecido (e conseqüentemente,  $\Sigma_\beta$ ), então

$$(\hat{\beta} - \beta)' (\Sigma_\beta)^{-1} (\hat{\beta} - \beta) \sim \chi^2_{(qp)}$$

- De modo semelhante ao caso univariado, a grande maioria das hipóteses de interesse, podem ser escritas na forma

$$H_0 : \mathbf{C}_{(r \times q)} \mathbf{B}_{(q \times p)} \mathbf{U}_{(p \times s)} = \mathbf{M}_{(r \times s)} \text{ vs } H_1 : \mathbf{CBU} \neq \mathbf{M}$$

em que  $r \leq q$  e  $s \leq p$ .

## Cont.

- Note agora que  $H_0 : \mathbf{U}'\mathbf{B}'\mathbf{C}' = \mathbf{M}'$  e, assim, temos que:

$$\text{vec}(\mathbf{U}'\mathbf{B}'\mathbf{C}') - \underbrace{\text{vec}(\mathbf{M}')}_{\mathbf{M}^*} = \underbrace{(\mathbf{C} \otimes \mathbf{U}')}_{\mathbf{C}^*} \boldsymbol{\beta} - \mathbf{M}^* = \mathbf{C}^* \boldsymbol{\beta} - \mathbf{M}^*.$$

- Logo,  $\hat{\boldsymbol{\theta}} = \mathbf{C}^* \hat{\boldsymbol{\beta}} - \mathbf{M}^* \sim N_{rs} \left( \mathbf{C}^* \boldsymbol{\beta} - \mathbf{M}^*, \mathbf{C}^* \boldsymbol{\Sigma}_{\boldsymbol{\beta}} \mathbf{C}^{*'} \right)$ .
- Se  $\boldsymbol{\Sigma}_{\boldsymbol{\beta}}$  for conhecido, e fazendo  $\boldsymbol{\theta} = \mathbf{C}^* \boldsymbol{\beta} - \mathbf{M}^*$ , temos que, sob  $H_0$

$$\hat{\boldsymbol{\theta}}' \left( \mathbf{C}^* \boldsymbol{\Sigma}_{\boldsymbol{\beta}} \mathbf{C}^{*'} \right)^{-1} \hat{\boldsymbol{\theta}} \sim \chi^2_{(rs)}$$

## Cont.

- Considere, então, que  $\widehat{\Sigma}$  é um estimador consistente de  $\Sigma$ , logo  $\widehat{\Sigma}_{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \otimes \widehat{\Sigma}$  o será para  $\Sigma_{\beta}$ .
- Assim, por Slutsky,

$$Q = \widehat{\theta}' \left( \mathbf{C}^* \widehat{\Sigma}_{\beta} \mathbf{C}^{*'} \right)^{-1} \widehat{\theta} \xrightarrow[n \rightarrow \infty]{D} \chi^2_{(rs, \delta)}$$

em que

$$\delta = (\mathbf{C}^* \beta - \mathbf{M}^*)' \left( \mathbf{C}^* \Sigma_{\beta} \mathbf{C}^{*'} \right)^{-1} (\mathbf{C}^* \beta - \mathbf{M}^*).$$

Mas, sob  $H_0$  tem-se que  $\delta = 0$ .



## Cont.

- Nível descritivo:  $P(Q > q_{calc} | H_0)$ , em que  $Q \approx \chi^2_{(rs)}$ , para  $n$  suficientemente grande e  $q_{calc}$  é o valor calculado da estatística  $Q$ .
- Função poder:  $P(Q > q_c | H_1, \alpha)$ , em que  $Q \approx \chi^2_{(rs)}$  para  $n$  suficientemente grande e  $q_c$  é o valor crítico para um dado  $\alpha$  (nível de significância).
- Assim, o poder estimado do teste é dado por:  $P(\tilde{Q} > q_c | H_1, \alpha)$ , em que  $\tilde{Q} \approx \chi^2_{(rs, \tilde{\delta})}$  para  $n$  suficientemente grande e  $q_c$  é o valor crítico para um dado  $\alpha$  (nível de significância) e  $\tilde{\delta} = (\mathbf{C}^* \tilde{\beta} - \mathbf{M}^*)' (\mathbf{C}^* \tilde{\Sigma}_\beta \mathbf{C}^{*'})^{-1} (\mathbf{C}^* \tilde{\beta} - \mathbf{M}^*)$  e “ $\tilde{\sim}$ ” representa a respectiva estimativa.

# Igualdade entre as médias por gênero em cada tempo

- Hipóteses:

- (1)  $H_0 : \mu_{11} = \mu_{21}$ .

- (2)  $H_0 : \mu_{12} = \mu_{22}$ .

- (3)  $H_0 : \mu_{13} = \mu_{23}$ .

- (4)  $H_0 : \mu_{14} = \mu_{24}$ .

- Para todas as hipóteses (como estamos usando a parametrização casela de referência) temos que  $\mathbf{M} = 0_{(1 \times 1)}$  e  $\mathbf{C} = \begin{bmatrix} 0 & 1 \end{bmatrix}$ . Note que  $\mathbf{CB} = \begin{bmatrix} \alpha_{21} & \alpha_{22} & \alpha_{23} & \alpha_{24} \end{bmatrix}$ .

# Igualdade entre as médias por gênero em cada tempo

## ■ Assim

$$\begin{aligned} \blacksquare (1) \mathbf{U}' &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \\ \blacksquare (2) \mathbf{U}' &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \\ \blacksquare (3) \mathbf{U}' &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \\ \blacksquare (4) \mathbf{U}' &= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \end{aligned}$$

## ■ Resultados

- (1)  $q_{calc} = 3,45(0,0632)$ .
- (2)  $q_{calc} = 3,91(0,0479)$ .
- (3)  $q_{calc} = 6,97(0,0083)$ .
- (4)  $q_{calc} = 14,92(< 0,0001)$ .

# Igualdade entre as médias de idades consecutivas por gênero

## ■ Hipóteses (gênero feminino):

- (1)  $H_0 : \mu_{11} = \mu_{12}$ .

- (2)  $H_0 : \mu_{12} = \mu_{13}$ .

- (3)  $H_0 : \mu_{13} = \mu_{14}$ .

## ■ Hipóteses (gênero masculino):

- (1)  $H_0 : \mu_{21} = \mu_{22}$ .

- (2)  $H_0 : \mu_{22} = \mu_{23}$ .

- (3)  $H_0 : \mu_{23} = \mu_{24}$ .

## Cont.

- Em todos os casos  $\mathbf{M} = 0$ ,  $\mathbf{CB} = \begin{bmatrix} 1 & 0 \end{bmatrix}$  (gênero feminino) e  $\mathbf{CB} = \begin{bmatrix} 1 & 1 \end{bmatrix}$  (gênero masculino).
- Além disso,
  - (1)  $\mathbf{U}' = \begin{bmatrix} 1 & -1 & 0 & 0 \end{bmatrix}$
  - (2)  $\mathbf{U}' = \begin{bmatrix} 0 & 1 & -1 & 0 \end{bmatrix}$
  - (3)  $\mathbf{U}' = \begin{bmatrix} 0 & 0 & 1 & -1 \end{bmatrix}$

## Cont.

- Resultados (gênero feminino)

- (1)  $q_{calc} = 2,89(0,0894)$ .

- (2)  $q_{calc} = 1,71(0,1904)$ .

- (3)  $q_{calc} = 3,46(0,0629)$ .

- Resultados (gênero masculino)

- (1)  $q_{calc} = 3,38(0,0662)$ .

- (2)  $q_{calc} = 12,15(< 0,0001)$ .

- (3)  $q_{calc} = 15,41(< 0,0001)$ .