

Tabelas de contingência: modelos de regressão e testes de hipóteses (parte 2)

Prof. Caio Azevedo

Como estimar as proporções sob o modelo $\mathbf{A}\pi = \mathbf{X}\beta$?

- Como a matriz $\mathbf{A}'\mathbf{A}$ quase sempre é não inversível (a matriz \mathbf{A} , e, geral, terá pelo menos uma coluna igual a zero), devemos encontrar uma matriz, digamos, \mathbf{H} e um vetor \mathbf{F} , de sorte que (a matriz \mathbf{H} guarda relação com a matriz \mathbf{X} e o vetor β , enquanto que o vetor \mathbf{F} serve, em geral, para recuperar os parâmetros ausentes no produto $\mathbf{A}\pi$):

$$\pi = \mathbf{H}\beta + \mathbf{F}.$$

- Assim, um estimador de π , sob o modelo em questão, é dado por $\hat{\pi}_R = \mathbf{H}\hat{\beta} + \mathbf{F}$, em que $\hat{\beta}$ é o estimador MQG de β (já visto anteriormente, slide 60 de

http://www.ime.unicamp.br/~cnaber/aula_tabelas_de_

Cont.

- Logo, para tamanhos amostrais suficientemente grandes (depende do modelo probabilístico adotado),
$$\hat{\pi}_R \approx N_q \left(\mathbf{H}\boldsymbol{\beta} + \mathbf{F}, \mathbf{H} (\mathbf{X}'\boldsymbol{\Sigma}_F^{-1}\mathbf{X})^{-1} \mathbf{H}' \right)$$
, em que $\boldsymbol{\Sigma}_F$ é como vista anteriormente.
- Portanto, intervalos de confiança podem ser construídos com base na distribuição assintótica de $\hat{\pi}_R$, utilizando um estimador consistente para $\boldsymbol{\Sigma}_F$ (estimador esse já visto anteriormente, slide 59 de http://www.ime.unicamp.br/~cnaber/aula_tabelas_de_contingencia_MDR_TH_1S_2017.pdf).

Voltando ao Exemplo 3 (três inclinações partidárias)

		Inclinação partidária			
		Democrata	Independente	Republicano	Total
Gênero	Feminino	762 (θ_{11})	327(θ_{12})	468(θ_{13})	$n_{1\cdot} = 1557$
	Masculino	484(θ_{21})	239(θ_{22})	477(θ_{23})	$n_{2\cdot} = 1200$
Total	-	1246	566	945	$n_{\cdot\cdot} = 2757$

Exemplo 3 (três inclinações partidárias)

- Homogeneidade entre as distribuições.
- $H_0 : \begin{cases} \theta_{11} = \theta_{21} \\ \theta_{12} = \theta_{22} \end{cases} \leftrightarrow H_0 : \begin{cases} \theta_{11} - \theta_{21} = 0 \\ \theta_{12} - \theta_{22} = 0 \end{cases}$ vs
 H_1 : há pelo menos uma diferença
- Nesse caso $\pi = (\theta_{11}, \theta_{12}, \theta_{13}, \theta_{21}, \theta_{22}, \theta_{23})'$ e $\beta = (\alpha_1, \alpha_2)'$.

Exemplo 3 (três inclinações partidárias)

■ Assim $\mathbf{A} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}$; $\mathbf{X} = \begin{bmatrix} 1 & 0 \\ 1 & 0 \\ 0 & 1 \\ 0 & 1 \end{bmatrix}$.

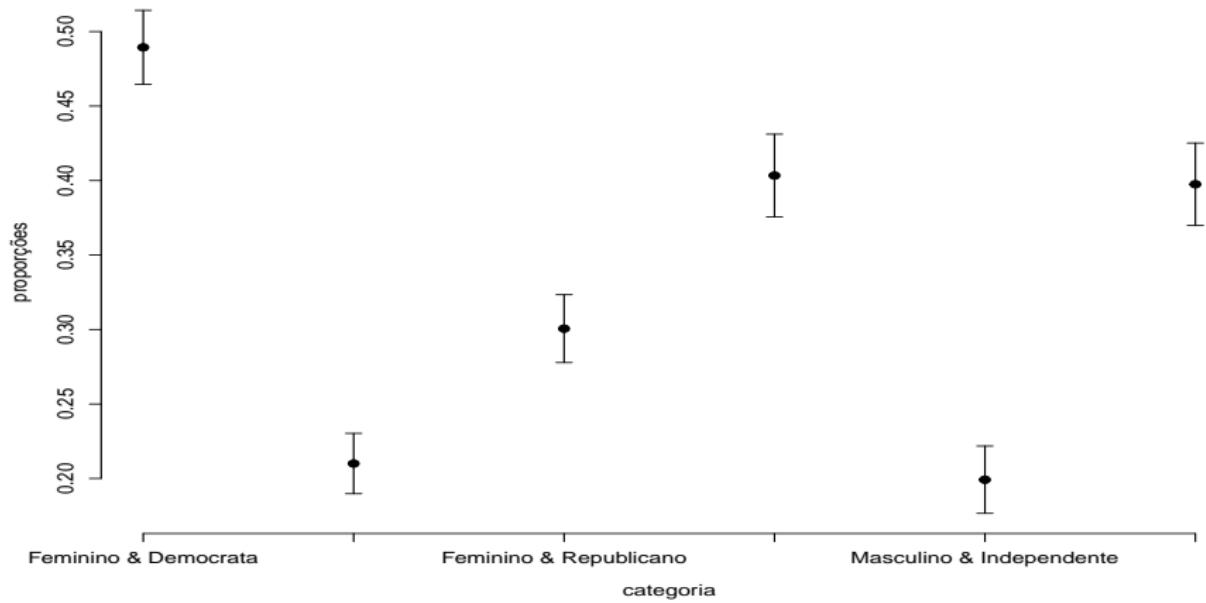
■ Modelo

$$\mathbf{A}\boldsymbol{\pi} = \mathbf{X}\boldsymbol{\beta} \Rightarrow \begin{bmatrix} \theta_{11} \\ \theta_{21} \\ \theta_{12} \\ \theta_{22} \end{bmatrix} = \begin{bmatrix} \alpha_1 \\ \alpha_1 \\ \alpha_2 \\ \alpha_2 \end{bmatrix}, \text{ assim } \theta_{i3} = 1 - \theta_{i1} - \theta_{i2}, i = 1, 2$$

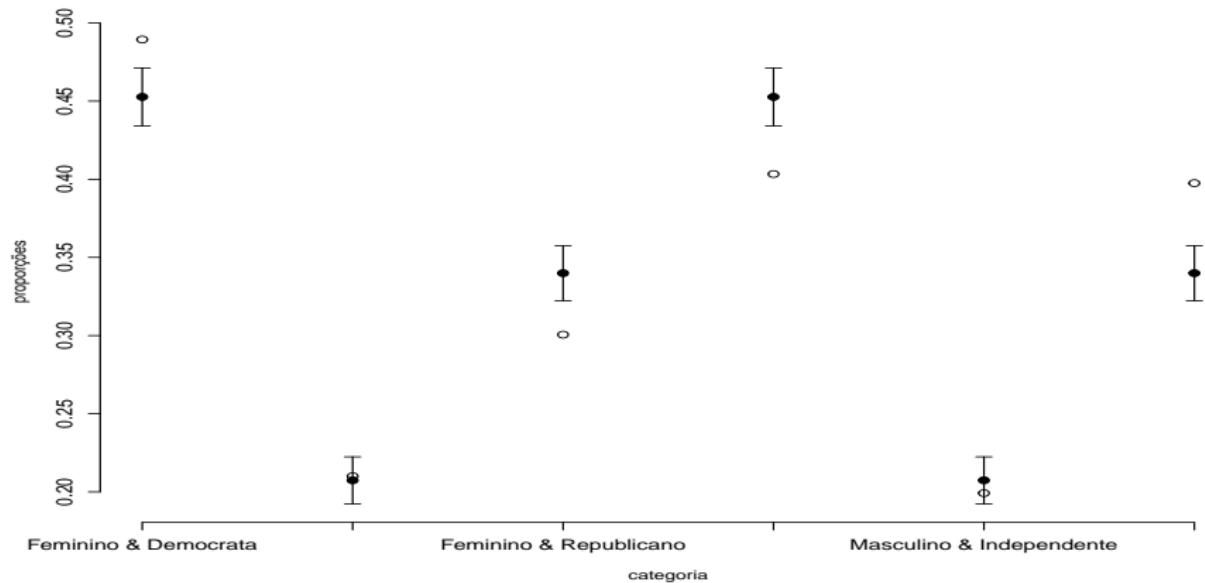
Cont. (Exemplo 1)

$$\boldsymbol{H} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ -1 & -1 \\ 1 & 0 \\ 0 & 1 \\ -1 & -1 \end{bmatrix}, \boldsymbol{F} = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 1 \end{bmatrix}.$$

Proporções (originais) estimadas



Proporções estimadas sob H_0 (em preto) e observadas (em branco)



Voltando ao exemplo 1: comparação de métodos de detecção de cárie

		Risco de cárie segundo o método convencional			
		Baixo	Médio	Alto	Total
Risco de cárie segundo o método simplificado	Baixo	11 (θ_{11})	5(θ_{12})	0(θ_{13})	16($\theta_{1.}$)
	Médio	14(θ_{21})	34(θ_{22})	7(θ_{23})	55($\theta_{2.}$)
	Alto	2(θ_{31})	13(θ_{32})	11(θ_{33})	26($\theta_{3.}$)
Total	-	27($\theta_{.1}$)	52($\theta_{.2}$)	18($\theta_{.3}$)	$n_{..} = 97$

Hipóteses de interesse

- Homogeneidade (simetria) marginal

$$H_0 : \begin{cases} \theta_{1\cdot} = \theta_{\cdot 1} \\ \theta_{2\cdot} = \theta_{\cdot 2} \end{cases} \leftrightarrow H_0 : \begin{cases} \theta_{12} + \theta_{13} - \theta_{21} - \theta_{31} = 0 \\ \theta_{21} + \theta_{23} - \theta_{12} - \theta_{32} = 0 \end{cases}$$

vs H_1 : há pelo menos uma diferença

- Nesse caso $\pi = (\theta_{11}, \theta_{12}, \theta_{13}, \theta_{21}, \theta_{22}, \theta_{23}, \theta_{31}, \theta_{32}, \theta_{33})'$ e
 $\theta = (\theta_{11}, \theta_{12}, \theta_{13}, \theta_{21}, \theta_{22}, \theta_{23}, \theta_{31}, \theta_{32})'$.

- Assim $\mathbf{B} = \begin{bmatrix} 0 & 1 & 1 & -1 & 0 & 0 & -1 & 0 & 0 \\ 0 & -1 & 0 & 1 & 0 & 1 & 0 & -1 & 0 \end{bmatrix}; \mathbf{D} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$

Cont. (Exemplo 1)

Relembrando

$$\mathbf{A}\boldsymbol{\pi} = \mathbf{X}\boldsymbol{\beta} \Rightarrow \begin{bmatrix} \theta_{11} \\ \theta_{12} \\ \theta_{13} \\ \theta_{21} \\ \theta_{22} \\ \theta_{23} \\ \theta_{31} \\ \theta_{32} \end{bmatrix} = \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \alpha_3 \\ \alpha_4 \\ \alpha_5 \\ \alpha_6 \\ \alpha_2 + \alpha_3 - \alpha_4 \\ -\alpha_2 + \alpha_4 + \alpha_6 \end{bmatrix}.$$

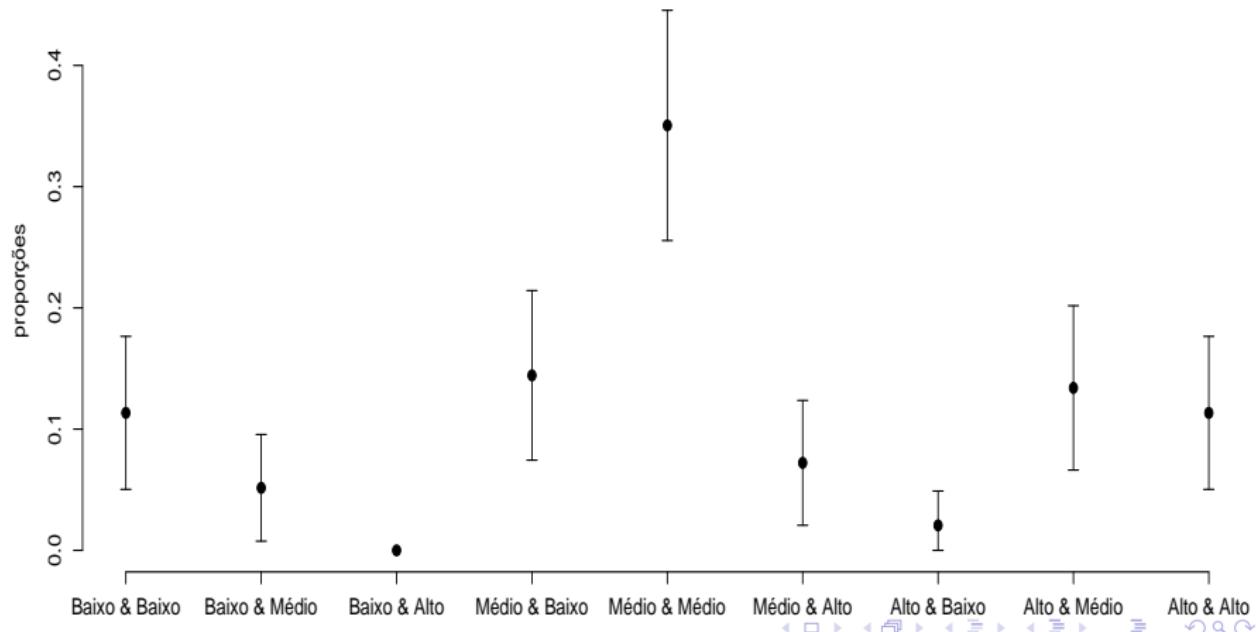
Assim, temos que $\theta_{33} = 1 - \theta_{11} - \theta_{12} - \theta_{13} - \theta_{21} - \theta_{22} - \theta_{23} - \theta_{31} - \theta_{32}$

$$= 1 - \alpha_1 - \alpha_2 - 2\alpha_3 - \alpha_4 - \alpha_5 - 2\alpha_6$$

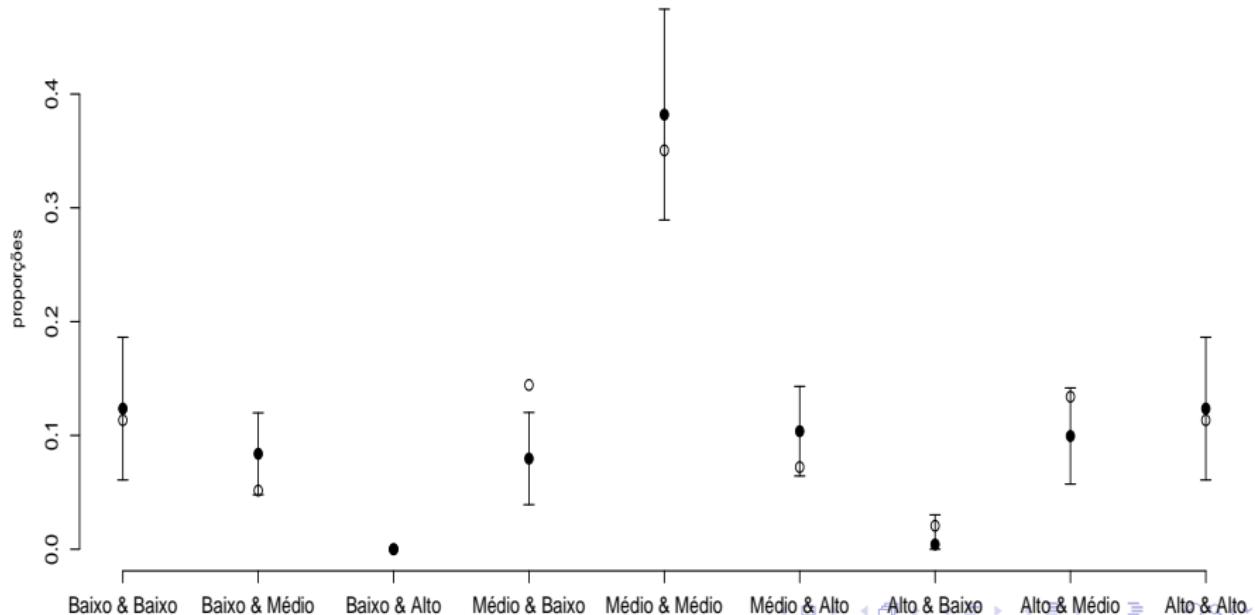
Cont. (Exemplo 1)

$$\boldsymbol{H} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 1 & -1 & 0 & 0 \\ 0 & -1 & 0 & 1 & 0 & 1 \\ -1 & -1 & -2 & -1 & -1 & -2 \end{bmatrix}, \boldsymbol{F} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 1 \end{bmatrix}.$$

Proporções (originais) estimadas



Proporções estimadas sob H_0 (em preto) e observadas (em branco)



Voltando ao Exemplo 7 (fatores idade e duração da gestação)

idade	Dur. da gest.	N. de cigarros	Sobrevivência		
			Não	Sim	Total
<30	≤ 260	< 5	50($\theta_{(11)11}$)	315($\theta_{(11)12}$)	$n_{(11)1.} = 365$
		5+	9($\theta_{(11)21}$)	40($\theta_{(11)22}$)	$n_{(11)2.} = 49$
	>260	< 5	24($\theta_{(12)11}$)	4012($\theta_{(12)12}$)	$n_{(12)1.} = 4036$
		5+	6($\theta_{(12)21}$)	459($\theta_{(12)22}$)	$n_{(12)2.} = 465$
30+	≤ 260	< 5	41($\theta_{(21)11}$)	147($\theta_{(21)12}$)	$n_{(21)1.} = 188$
		5+	4 ($\theta_{(21)21}$)	11($\theta_{(21)22}$)	$n_{(21)2.} = 15$
	>260	<5	14 ($\theta_{(22)11}$)	1594($\theta_{(22)12}$)	$n_{(22)1.} = 1608$
		5 +	1($\theta_{(22)21}$)	124($\theta_{(22)22}$)	$n_{(22)2.} = 125$

Hipóteses de interesse

- Independência (sobrevida e n. de cigarros) dentro de cada estrato (grupo: idade × duração da gestação)

$$H_0 : \begin{cases} \theta_{(11)11} = \theta_{(11)21} \\ \theta_{(12)11} = \theta_{(12)21} \\ \theta_{(21)11} = \theta_{(21)21} \\ \theta_{(22)11} = \theta_{(22)21} \end{cases} \leftrightarrow \begin{cases} \theta_{(11)11} - \theta_{(11)21} = 0 \\ \theta_{(12)11} - \theta_{(12)21} = 0 \\ \theta_{(21)11} - \theta_{(21)21} = 0 \\ \theta_{(22)11} - \theta_{(22)21} = 0 \end{cases}$$

vs H_1 : há pelo menos uma diferença

Cont. (exemplo 7)

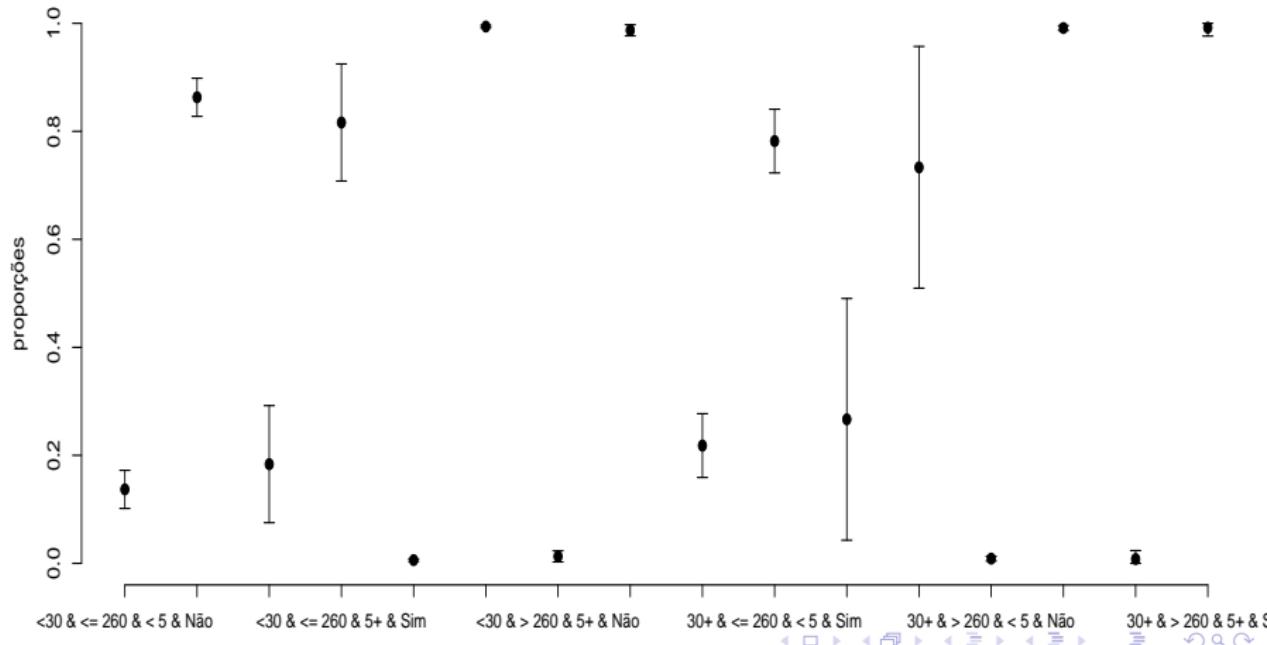
■ Relembrando

$$\mathbf{A}\boldsymbol{\pi} = \mathbf{X}\boldsymbol{\beta} \Rightarrow \begin{bmatrix} \theta_{(11)11} \\ \theta_{(11)21} \\ \theta_{(12)11} \\ \theta_{(12)21} \\ \theta_{(21)11} \\ \theta_{(21)21} \\ \theta_{(22)11} \\ \theta_{(22)21} \end{bmatrix} = \begin{bmatrix} \alpha_1 \\ \alpha_1 \\ \alpha_2 \\ \alpha_2 \\ \alpha_3 \\ \alpha_3 \\ \alpha_4 \\ \alpha_4 \end{bmatrix}, \text{ assim, } \theta_{(ij)k2} = 1 - \theta_{(ij)k1}, \forall i, j, k \in \{1, 2\}.$$

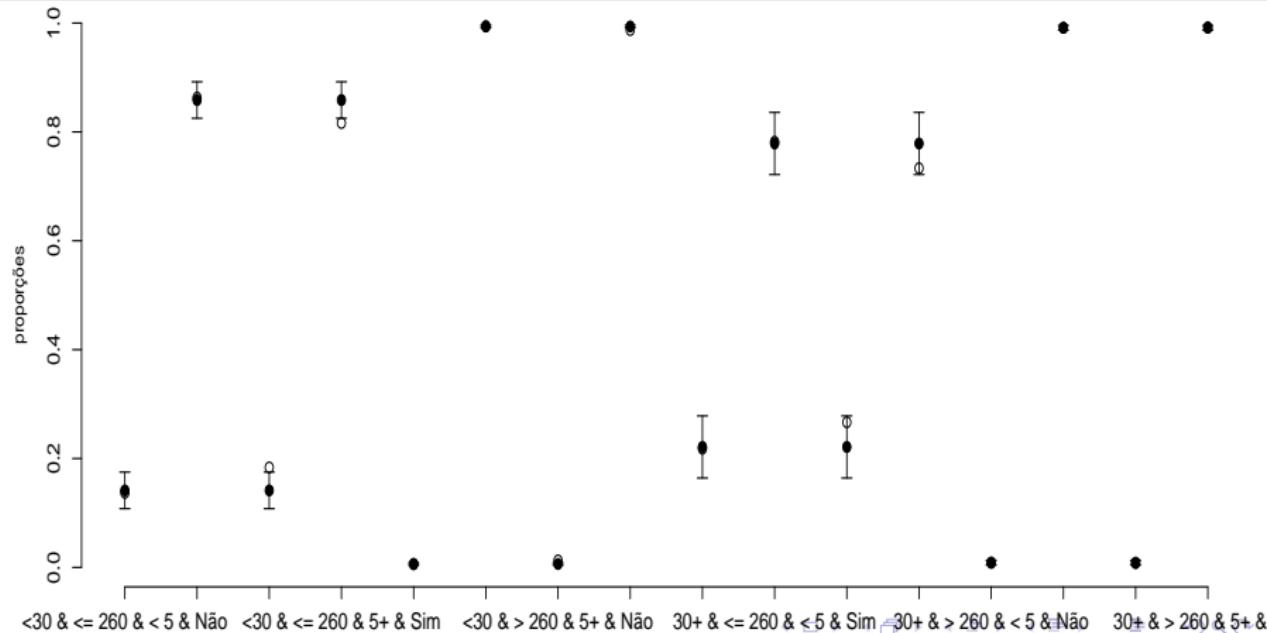
Cont. (exemplo 7)

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & -1 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & -1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & -1 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & -1 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & -1 \end{bmatrix}, F = \begin{bmatrix} 0 \\ 1 \\ 0 \\ 1 \\ 1 \\ 0 \\ 0 \\ 1 \\ 0 \\ 1 \\ 0 \\ 1 \\ 0 \\ 1 \\ 0 \\ 1 \end{bmatrix}.$$

Proporções (originais) estimadas



Proporções estimadas sob H_0 (em preto) e observadas (em branco)



Mais sobre modelos de regressão

- Em geral, as hipóteses de interesse, relativas as tabelas de contingência geradas pelos modelos multinomial e produto de multinomiais, podem ser escritas como:

$$\mathbf{F}(\boldsymbol{\pi}) = \mathbf{X}\boldsymbol{\beta},$$

em que $\mathbf{F}(.)$ é uma matriz cujas componentes são funções de interesse.

- Exemplo

$$\ln(\mathbf{A}\boldsymbol{\pi}) = \mathbf{X}\boldsymbol{\beta},$$

nesse caso, $\ln(.)$ aplica o logaritmo natural em cada elemento do vetor $\mathbf{A}\boldsymbol{\pi}$.

Modelos funcionais lineares

- Estudaremos modelos da forma

$$\mathbf{A}_{a \times g} \ln(\mathbf{G}_{g \times q} \boldsymbol{\pi}_{q \times 1}) = \mathbf{X}_{a \times p} \boldsymbol{\beta}_{p \times 1}$$

em que \mathbf{A} e \mathbf{G} são matrizes conhecidas.

- Para outros modelos, consultar referências e pesquisar.

Exemplo 3 (duas inclinações partidárias)

- Homogeneidade entre as distribuições. Lembremos que
$$\eta = \ln \frac{\theta_{11}/(1 - \theta_{11})}{\theta_{21}/(1 - \theta_{21})} = \ln \frac{\theta_{11}/\theta_{12}}{\theta_{21}/\theta_{22}} \text{ e } \theta_{i1} + \theta_{i2} + \theta_{i3} = 1, i = 1, 2.$$
- $H_0 : \eta = 0$ vs $H_1 : \eta \neq 0 \leftrightarrow H_0 : \ln \theta_{11} - \ln \theta_{12} = \ln \theta_{21} - \ln \theta_{22}$ vs
 $H_1 : \ln \theta_{11} - \ln \theta_{12} \neq \ln \theta_{21} - \ln \theta_{22}.$
- Nesse caso $\pi = (\theta_{11}, \theta_{12}, \theta_{21}, \theta_{22})'$ e $\beta = (\alpha)$.
- Assim $\mathbf{G} = \mathbf{I}_4$, e $\mathbf{G}\pi = \pi = (\theta_{11}, \theta_{12}, \theta_{21}, \theta_{22})'$.

Exemplo 3 (duas inclinações partidárias)

- $\mathbf{A} = \begin{bmatrix} 1 & -1 & 0 & 0 \\ 0 & 0 & 1 & -1 \end{bmatrix}; \mathbf{X} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}.$
 - Modelo
- $$\mathbf{A} \ln(\mathbf{G}\boldsymbol{\pi}) = \mathbf{X}\boldsymbol{\beta} \Rightarrow \begin{bmatrix} \ln \theta_{11} - \ln \theta_{12} \\ \ln \theta_{21} - \ln \theta_{22} \end{bmatrix} = \begin{bmatrix} \alpha \\ \alpha \end{bmatrix}$$

Exemplo 3 (três inclinações partidárias)

- Homogeneidade entre as distribuições. Sejam

$$\eta_1 = \ln \frac{\theta_{11}/(1-\theta_{11})}{\theta_{21}/(1-\theta_{21})}, \eta_2 = \ln \frac{\theta_{12}/(1-\theta_{12})}{\theta_{22}/(1-\theta_{22})}$$

- $H_0 : \begin{cases} \eta_1 = 0 \\ \eta_2 = 0 \end{cases} \leftrightarrow H_0 :$
$$\begin{cases} \ln \theta_{11} - \ln(\theta_{12} + \theta_{13}) = \ln \theta_{21} - \ln(\theta_{22} + \theta_{23}) \\ \ln \theta_{12} - \ln(\theta_{11} + \theta_{13}) = \ln \theta_{22} - \ln(\theta_{21} + \theta_{23}) \end{cases}$$
 vs
 $H_1 : \text{há pelo menos uma diferença}$

- Nesse caso $\pi = (\theta_{11}, \theta_{12}, \theta_{13}, \theta_{21}, \theta_{22}, \theta_{23})'$ e $\beta = (\alpha_1, \alpha_2)'$.

Exemplo 3 (três inclinações partidárias)

■ Assim $\mathbf{G} =$

$$\begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 1 \end{bmatrix}, \mathbf{G}\boldsymbol{\pi} = \begin{bmatrix} \theta_{11} \\ \theta_{12} + \theta_{13} \\ \theta_{21} \\ \theta_{22} + \theta_{23} \\ \theta_{12} \\ \theta_{11} + \theta_{13} \\ \theta_{22} \\ \theta_{21} + \theta_{23} \end{bmatrix}.$$

Exemplo 3 (três inclinações partidárias)

- Assim $A = \begin{bmatrix} 1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & -1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & -1 \end{bmatrix}$.
- $x = \begin{bmatrix} 1 & 0 \\ 1 & 0 \\ 0 & 1 \\ 0 & 1 \end{bmatrix}$.

Exemplo 3 (três inclinações partidárias)

■ Modelo

$$\mathbf{A} \ln(\mathbf{G}\boldsymbol{\pi}) = \mathbf{X}\boldsymbol{\beta} \Rightarrow \begin{bmatrix} \ln \theta_{11} - \ln(\theta_{12} + \theta_{13}) \\ \ln \theta_{21} - \ln(\theta_{22} + \theta_{23}) \\ \ln \theta_{12} - \ln(\theta_{11} + \theta_{13}) \\ \ln \theta_{22} - \ln(\theta_{21} + \theta_{23}) \end{bmatrix} = \begin{bmatrix} \alpha_1 \\ \alpha_1 \\ \alpha_2 \\ \alpha_2 \end{bmatrix}$$

Exemplo 1: comparação de métodos de detecção de cárie

- Independência entre os métodos de detecção de cárie

$H_0 : \theta_{ij} = \theta_{i\cdot}\theta_{\cdot j}, \forall i, j$ vs $H_1 : \text{há pelo menos uma diferença}$

- Nesse caso $\pi = (\theta_{11}, \theta_{12}, \theta_{13}, \theta_{21}, \theta_{22}, \theta_{23}, \theta_{31}, \theta_{32}, \theta_{33})'$ e

$\beta = (\alpha_1, \alpha_2, \alpha_3, \alpha_4, \alpha_5, \alpha_6, \alpha_7, \alpha_8, \alpha_9)'$.

- Note que H_0 equivale à

$H_0 : \ln \theta_{ij} = \ln \theta_{i\cdot} + \ln \theta_{\cdot j}, \forall i, j$ vs $H_1 : \text{há pelo menos uma diferença}$

- Para cada casela, temos

$$H_0 : \left\{ \begin{array}{l} \ln \theta_{11} = \ln \theta_{1.} + \ln \theta_{.1} \\ \ln \theta_{12} = \ln \theta_{1.} + \ln \theta_{.2} \\ \ln \theta_{13} = \ln \theta_{1.} + \ln \theta_{.3} \\ \ln \theta_{21} = \ln \theta_{2.} + \ln \theta_{.1} \\ \ln \theta_{22} = \ln \theta_{2.} + \ln \theta_{.2} \\ \ln \theta_{23} = \ln \theta_{2.} + \ln \theta_{.3} \\ \ln \theta_{31} = \ln \theta_{3.} + \ln \theta_{.1} \\ \ln \theta_{32} = \ln \theta_{3.} + \ln \theta_{.2} \\ \ln \theta_{33} = \ln \theta_{3.} + \ln \theta_{.3} \end{array} \right.$$

Exemplo 1: comparação de métodos de detecção de cárie

■ Portanto,

$$\mathbf{G} = \begin{bmatrix} \mathbf{I}_9 & & \\ \mathbf{1}'_3 & \mathbf{0}'_3 & \mathbf{0}'_3 \\ \mathbf{0}'_3 & \mathbf{1}'_3 & \mathbf{0}'_3 \\ \mathbf{0}'_3 & \mathbf{0}'_3 & \mathbf{1}'_3 \\ 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 \end{bmatrix}, \mathbf{G}\boldsymbol{\pi} = \begin{bmatrix} \pi \\ \theta_{1.} \\ \theta_{2.} \\ \theta_{3.} \\ \theta_{.1} \\ \theta_{.2} \\ \theta_{.3} \end{bmatrix}.$$

Exemplo 1: comparação de métodos de detecção de cárie

- Também,

$$\mathbf{A} = \begin{bmatrix} & I_9 & & \mathbf{0}_{9 \times 6} \\ \begin{matrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 1 \end{matrix} \end{bmatrix}$$

■ Finalmente,

$$\mathbf{x} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

■ Modelo

$$\mathbf{A} \ln(\mathbf{G}\boldsymbol{\pi}) = \mathbf{X}\boldsymbol{\beta} \Rightarrow \begin{bmatrix} \ln \theta_{11} \\ \ln \theta_{12} \\ \ln \theta_{13} \\ \ln \theta_{21} \\ \ln \theta_{22} \\ \ln \theta_{23} \\ \ln \theta_{31} \\ \ln \theta_{32} \\ \ln \theta_{33} \\ \ln \theta_{1.} + \ln \theta_{.1} \\ \ln \theta_{1.} + \ln \theta_{.2} \\ \ln \theta_{1.} + \ln \theta_{.3} \\ \ln \theta_{2.} + \ln \theta_{.1} \\ \ln \theta_{2.} + \ln \theta_{.2} \\ \ln \theta_{2.} + \ln \theta_{.3} \\ \ln \theta_{3.} + \ln \theta_{.1} \\ \ln \theta_{3.} + \ln \theta_{.2} \\ \ln \theta_{3.} + \ln \theta_{.3} \end{bmatrix} = \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \alpha_3 \\ \alpha_4 \\ \alpha_5 \\ \alpha_6 \\ \alpha_7 \\ \alpha_8 \\ \alpha_9 \\ \alpha_1 \\ \alpha_2 \\ \alpha_3 \\ \alpha_4 \\ \alpha_5 \\ \alpha_6 \\ \alpha_7 \\ \alpha_8 \\ \alpha_9 \end{bmatrix}$$

Exemplo 7: efeitos de certos fatores na sobrevivência de recém nascidos (considerando apenas o fator idade)

- Independência (sobrevivência e n. de cigarros) dentro de cada estrato (grupo: idade)

$$H_0 : \begin{cases} \theta_{(1)11} = \theta_{(1)21} \\ \theta_{(2)11} = \theta_{(2)21} \end{cases} \leftrightarrow \begin{cases} \eta_{(1)} = 0 \\ \eta_{(2)} = 0 \end{cases} \leftrightarrow$$

$$\begin{cases} \ln \theta_{(1)11} - \ln \theta_{(1)12} = \ln \theta_{(1)21} - \ln \theta_{(1)22} \\ \ln \theta_{(2)11} - \ln \theta_{(2)12} = \ln \theta_{(2)21} - \ln \theta_{(2)22} \end{cases}$$

vs H_1 : há pelo menos uma diferença,

Exemplo 7: efeitos de certos fatores na sobrevivência de recém nascidos (considerando apenas o fator idade)

- em que $\eta_{(i)} = \ln \frac{\theta_{(i)11}/(1 - \theta_{(i)11})}{\theta_{(i)21}/(1 - \theta_{(i)21})} = \ln \frac{\theta_{(i)11}/\theta_{(i)12}}{\theta_{(i)21}/\theta_{(i)22}}, i = 1, 2.$
- Nesse caso $\pi = (\theta_{(1)11}, \theta_{(1)12}, \theta_{(1)21}, \theta_{(1)22}, \theta_{(2)11}, \theta_{(2)12}, \theta_{(2)21}, \theta_{(2)22})'$ e $\beta = (\alpha_1, \alpha_2)'$.
- Assim $\mathbf{G} = \mathbf{I}_8$, $\mathbf{G}\pi = \pi$.

- $\mathbf{A} = \begin{bmatrix} 1 & -1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & -1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & -1 \end{bmatrix}, \mathbf{X} = \begin{bmatrix} 1 & 0 \\ 1 & 0 \\ 0 & 1 \\ 0 & 1 \end{bmatrix}.$

Exemplo 7: efeitos de certos fatores na sobrevivência de recém nascidos (considerando apenas o fator idade)

- Modelo

$$\mathbf{A} \ln(\mathbf{G}\boldsymbol{\pi}) = \mathbf{X}\boldsymbol{\beta} \Rightarrow \begin{bmatrix} \ln \theta_{(1)11} - \ln \theta_{(1)12} \\ \ln \theta_{(1)21} - \ln \theta_{(1)22} \\ \ln \theta_{(2)11} - \ln \theta_{(2)12} \\ \ln \theta_{(2)21} - \ln \theta_{(2)22} \end{bmatrix} = \begin{bmatrix} \alpha_1 \\ \alpha_1 \\ \alpha_2 \\ \alpha_2 \end{bmatrix}$$

Ajuste do modelo

- Mínimos quadrados generalizados (MQG): minimizar a seguinte forma quadrática em função de β

$$(\hat{\mathbf{F}} - \mathbf{X}\beta)' \boldsymbol{\Sigma}_{\mathbf{F}}^{-1} (\hat{\mathbf{F}} - \mathbf{X}\beta),$$

em que $\hat{\mathbf{F}} = \mathbf{A} \ln(\mathbf{G}\hat{\pi})$, $\boldsymbol{\Sigma}_{\mathbf{F}} = \text{Cov}(\hat{\mathbf{F}})$, a qual dependerá da forma funcional ($\mathbf{F}(\pi)$) adotada e $\hat{\pi}$ são as proporções amostrais.

- A obtenção de $\boldsymbol{\Sigma}_{\mathbf{F}}$ dar-se-á pelo método Delta.

Ajuste do modelo

- Estimador MQG (como visto anteriormente):

$$\hat{\beta}^* = (\mathbf{X}' \boldsymbol{\Sigma}_F^{-1} \mathbf{X})^{-1} \mathbf{X}' \boldsymbol{\Sigma}_F^{-1} \hat{\mathbf{F}}$$

- Como desconhecemos $\boldsymbol{\Sigma}_F$, a substituímos, na fórmula de $\hat{\beta}^*$, por um estimador consistente, denotado por $\hat{\boldsymbol{\Sigma}}_F$. Ou seja, trabalhamos com o estimador

$$\hat{\beta} = (\mathbf{X}' \hat{\boldsymbol{\Sigma}}_F^{-1} \mathbf{X})^{-1} \mathbf{X}' \hat{\boldsymbol{\Sigma}}_F^{-1} \hat{\mathbf{F}},$$

em que, novamente, $\hat{\boldsymbol{\Sigma}}_F$ dependerá da forma funcional ($\mathbf{F}(\pi)$) adotada.

Ajuste do modelo

- Para tamanhos amostrais $n_{..}$ (multinomial) ou n_i (produto de multinomiais), $i = 1, \dots, r$ suficientemente grandes e sob H_0 temos que

$$\hat{\beta} \approx N_p(\beta, (\mathbf{X}' \boldsymbol{\Sigma}_F^{-1} \mathbf{X})^{-1}).$$

- Esse resultado pode ser utilizado para construir intervalos de confiança para cada componente do vetor β , utilizando a estimativa de $\boldsymbol{\Sigma}_F$, obtida através de um estimador consistente.

Ajuste do modelo

- O ajuste do modelo pode ser testado através da estatística

$$Q_F = (\hat{\mathbf{F}} - \mathbf{X}\hat{\boldsymbol{\beta}})' \hat{\boldsymbol{\Sigma}}_{\mathbf{F}}^{-1} (\hat{\mathbf{F}} - \mathbf{X}\hat{\boldsymbol{\beta}}).$$

- Sob H_0 e para tamanhos amostrais $n_{..}$ (multinomial) ou $n_{i..}$ (produto de multinomiais), $i = 1, \dots, r$ suficientemente grandes, $Q_F \approx \chi^2_{(a-p)}$, em que a é o número de linhas da matriz \mathbf{X} e p é o número de parâmetros do vetor $\boldsymbol{\beta}$.
- Assim, rejeitamos H_0 se p-valor $\leq \alpha$, em que p-valor $p\text{-valor} \approx P(X \geq q_F | H_0)$, $X \sim \chi^2_{(a-p)}$ e q_F é o valor calculado da estatística Q_F .

Ajuste do modelo

- Dado que o modelo está bem ajustado, podemos ainda testar hipóteses acerca do vetor β , da forma:

$$H_0 : \mathbf{C}_{(c \times p)} \boldsymbol{\beta}_{(p \times 1)} = \mathbf{M}_{(c \times 1)} \text{ vs } H_1 : \mathbf{C}_{(c \times p)} \boldsymbol{\beta}_{(p \times 1)} \neq \mathbf{M}_{(c \times 1)}$$

- Para tal, podemos considerar a estatística usual:

$$Q_C = (\mathbf{C} \hat{\boldsymbol{\beta}} - \mathbf{M})' [\mathbf{C}(\mathbf{X}' \hat{\boldsymbol{\Sigma}}_F^{-1} \mathbf{X})^{-1} \mathbf{C}']^{-1} (\mathbf{C} \hat{\boldsymbol{\beta}} - \mathbf{M})$$

Ajuste do modelo

- Sob H_0 e para tamanhos amostrais $n_{..}$ (multinomial) ou $n_{i.}$ (produto de multinomiais), $i = 1, \dots, r$ suficientemente grandes, $Q_C \approx \chi_c^2$.
- Assim, rejeitamos H_0 se p-valor $\leq \alpha$, $\approx P(X \geq q_C | H_0)$, $X \sim \chi_c^2$ e q_C é o valor calculado da estatística Q_C .

Ajuste do modelo

- Em nosso caso, $\mathbf{F}(\boldsymbol{\pi}) = \mathbf{A} \ln(\mathbf{G}\boldsymbol{\pi})$. Assim, $\boldsymbol{\Sigma}_F = \boldsymbol{\Psi} \boldsymbol{\Sigma}_{\boldsymbol{\pi}} \boldsymbol{\Psi}'$, em que

$$\boldsymbol{\Psi} = \frac{\partial}{\partial \boldsymbol{\pi}} \mathbf{A} \ln(\mathbf{G}\boldsymbol{\pi}) = \mathbf{A} \mathbf{B} \mathbf{G},$$

e \mathbf{B} é uma matriz diagonal composta pelo inverso de cada um dos elementos do vetor $\mathbf{G}\boldsymbol{\pi}$.

- Logo, $\widehat{\boldsymbol{\Sigma}}_F = \mathbf{A} \widehat{\mathbf{B}} \mathbf{G} \widehat{\boldsymbol{\Sigma}}_{\boldsymbol{\pi}} \mathbf{G}' \widehat{\mathbf{B}}' \mathbf{A}'$, $\widehat{\boldsymbol{\Sigma}}_{\boldsymbol{\pi}}$ é como vista anteriormente e $\widehat{\mathbf{B}}$ é uma matriz diagonal composta pelo inverso de cada um dos elementos do vetor $\mathbf{G}\widehat{\boldsymbol{\pi}}$.

Aplicação da metodologia aos exemplos anteriores

- Exemplo 3 (duas inclinações partidárias): $q_F = 29,38$, p-valor $< 0,0001$. Assim, rejeita-se a hipótese de independência entre gênero e inclinação partidária.
- Exemplo 3 (três inclinações partidárias): $q_F = 191,85$, p-valor $< 0,0001$. Portanto, rejeita-se a hipótese de independência entre gênero e inclinação partidária.

Aplicação da metodologia aos exemplos anteriores

- Exemplo 1 : $q_F = 153,03$, p-valor < 0,0001. Assim, rejeita-se a hipótese de independência entre os métodos de classificação.
- Exemplo 7: (grupo= idade): $q_F = 3,97$, p-valor= 0,1373. Portanto, não se rejeita a hipótese de independência entre n. de cigarros e sobrevivência do recém nascido para todos os estratos.

Resumos dos dois modelos de regressão vistos

- Consideramos um, dos dois seguintes modelos:

- $\mathbf{N} \sim \text{multinomial}_r(n_{..}, \boldsymbol{\theta})$, $\boldsymbol{\theta} = (\theta_1, \dots, \theta_{(r-1)})'$ e $\boldsymbol{\pi} = (\theta_1, \dots, \theta_r)'$.
- $\mathbf{N}_i \stackrel{ind.}{\sim} \text{multinomial}_s(n_{i..}, \boldsymbol{\theta}_i)$, $i = 1, 2, \dots, r$, $\boldsymbol{\theta}_i = (\theta_{i1}, \dots, \theta_{i(s-1)})'$,
 $\boldsymbol{\pi}_i = (\theta_{i1}, \dots, \theta_{is})'$, $\boldsymbol{\theta} = (\boldsymbol{\theta}'_1, \dots, \boldsymbol{\theta}'_r)'$ e $\boldsymbol{\pi} = (\boldsymbol{\pi}'_1, \dots, \boldsymbol{\pi}'_r)'$.

- Estruturas de regressão:

- Linear: $\mathbf{A}\boldsymbol{\pi} = \mathbf{X}\boldsymbol{\beta}$.
- Log-linear: $\mathbf{A}\ln(\mathbf{G}\boldsymbol{\pi}) = \mathbf{X}\boldsymbol{\beta}$.

Resumos dos dois modelos de regressão vistos

- Estimador (MQG): $\hat{\beta} = (\mathbf{X}' \hat{\Sigma}_F^{-1} \mathbf{X})^{-1} \mathbf{X}' \hat{\Sigma}_F^{-1} \hat{\mathbf{F}}$.
- Estatística de ajuste do modelo: $Q_F = (\hat{\mathbf{F}} - \mathbf{X}\hat{\beta})' \hat{\Sigma}_F^{-1} (\hat{\mathbf{F}} - \mathbf{X}\hat{\beta})$.
- Estatística para testes de hipóteses do tipo

$$H_0 : \mathbf{C}\beta = \mathbf{M} \text{ vs } H_1 : \mathbf{C}\beta \neq \mathbf{M}$$

$$Q_C = (\mathbf{C}\hat{\beta} - \mathbf{M})' [\mathbf{C}(\mathbf{X}' \hat{\Sigma}_F^{-1} \mathbf{X})^{-1} \mathbf{C}']^{-1} (\mathbf{C}\hat{\beta} - \mathbf{M})$$

Resumos dos dois modelos de regressão vistos

- Em que:
 - Modelo linear: $\hat{\mathbf{F}} = \mathbf{A}\hat{\boldsymbol{\pi}}$ e $\hat{\Sigma}_F = \mathbf{A}\hat{\Sigma}_{\pi}\mathbf{A}'$.
 - Modelo log-linear: $\hat{\mathbf{F}} = \mathbf{A} \ln(\mathbf{G}\hat{\boldsymbol{\pi}})$ e $\hat{\Sigma}_F = \hat{\Psi}\hat{\Sigma}_{\pi}\hat{\Psi}'$, em que $\hat{\Psi} = \mathbf{A}\hat{\mathbf{B}}\mathbf{G}$ e $\hat{\mathbf{B}}$ é como definida anteriormente.
- Para $n_{..}$ ou $n_{i..}, i = 1, \dots, r$ suficientemente grandes,
 $\hat{\beta} \approx N_p(\beta, (\mathbf{X}'\Sigma_F^{-1}\mathbf{X})^{-1})$, e, além disso, sob H_0 , $Q_F \approx \chi^2_{(a-p)}$ e $Q_C \approx \chi^2_c$.