

# Aula 5

Estudos com o tempo de duração

Modelo de Regressão logística

Quando não é possível estabelecer o número de participantes , devido a uma limitação de ocorrência (incidência). O tempo de duração pode ser preestabelecido.

Neste caso  $N_{ij}$  ,  $i,j = 1,2$  são contagens aleatórias, com  $N_{ij}$  e também  $N$ , conhecidas somente após o término da coleta dos dados.

		Categoria da Resposta Y		
		j	j	Totais
		1	2	
i	1	n11	n12	n1.
i	2	n21	n22	n2.
<b>Totais</b>		n.1	n.2	n

## Óbito HIV segundo sexo e Região em 2011.

---

Região	Sexo		Total
	FEM	MASC	
Sudeste	1078	270	1348
Sul	319	65	384
Total	1397	335	1732

---

Boletim de Epidemiologia 2012

---

Placa	Bacteria		Total
	Tipol	Tipoll	
A	246	17	263
B	458	32	490
Total	704	49	753

---

## λ distribuição de Poisson

A distribuição de Poisson pode ser vista como um limite "especial" da distribuição binomial: Suponha-se que  $n$  aumenta e que  $p$  diminui de tal forma que  $E(X) = np$  se mantém constante, seja  $\lambda$  essa constante, então tem-se

$$\begin{aligned}
 P(X = x) &= \binom{n}{x} p^x (1-p)^{n-x} = \\
 &= \frac{n(n-1)\cdots(n-x+1)}{x!} \left(\frac{np}{n}\right)^x \left(1 - \frac{np}{n}\right)^n \left(1 - \frac{np}{n}\right)^{-x} = \\
 &= \frac{n(n-1)\cdots(n-x+1)}{x!} \left(\frac{\lambda}{n}\right)^x \left(1 - \frac{\lambda}{n}\right)^n \left(1 - \frac{\lambda}{n}\right)^{-x} = \\
 &= \frac{n(n-1)\cdots(n-x+1)}{n^x} \frac{\lambda^x}{x!} \left(1 - \frac{\lambda}{n}\right)^n \left(1 - \frac{\lambda}{n}\right)^{-x} = \\
 &= \frac{n}{n} \frac{n-1}{n} \cdots \frac{n-x+1}{n} \frac{\lambda^x}{x!} \left(1 - \frac{\lambda}{n}\right)^n \left(1 - \frac{\lambda}{n}\right)^{-x} \\
 &\quad \downarrow \quad \downarrow \quad \quad \downarrow \quad \quad \downarrow \quad \quad \downarrow \\
 &\quad 1 \quad 1 \quad \quad 1 \quad \quad e^{-\lambda} \quad \quad 1
 \end{aligned}$$

logo

$$\lim_{n \rightarrow \infty, np = \lambda} P(X = x) = \frac{e^{-\lambda} \lambda^x}{x!}, \quad x = 0, 1, 2, \dots \quad (\lambda > 0)$$

**Definição:** Dado um intervalo de números reais suponha-se que certas ocorrências surgem aleatoriamente ao longo do intervalo. Se o intervalo puder ser subdividido em subintervalos de comprimento suficientemente pequeno de modo a que se verifique:

- 1) A probabilidade de mais do que uma ocorrência num subintervalo é zero.
- 2) A probabilidade duma ocorrência num subintervalo é constante e proporcional ao comprimento do subintervalo.
- 3) As ocorrências nos diversos subintervalos são independentes.

- Assumimos que  $N_{ij}$  tem uma distribuição binomial com parâmetro  $\mu_{ij}=t\lambda_{ij}$ ,
- $\lambda_{ij}$  a taxa média por unidade de tempo
- $t$  a duração do experimento ou observação
- Sendo  $N_{ij}$  independentes temos o produto de Poisson independentes.

$$P(\mathbf{N} = \mathbf{n}) = \prod_{i=1}^2 \prod_{j=1}^2 P(N_{ij} = n_{ij}) = \prod_{i=1}^2 \prod_{j=1}^2 \frac{e^{-\mu_{ij}} (\mu_{ij})^{n_{ij}}}{(n_{ij})!}, \quad \mu_{ij} > 0$$

com  $(\mathbf{N} = \mathbf{n}) = (N_{11} = n_{11}, N_{12} = n_{12}, N_{21} = n_{21}, N_{22} = n_{22})$ .

com  $\mu_{ij} = \hat{n}_{ij}$

As hipóteses neste modelo serão:

$$H_0: \frac{\mu_{1j}}{\mu_{1\bullet}} = \frac{\mu_{2j}}{\mu_{2\bullet}} \left( = \frac{\mu_{\bullet j}}{\mu} \right), \text{ para } j = 1, 2.$$

$$H_A: \frac{\mu_{1j}}{\mu_{1\bullet}} \neq \frac{\mu_{2j}}{\mu_{2\bullet}}$$

$$H_0: \mu_{ij} = \frac{(\mu_{i\bullet})(\mu_{\bullet j})}{\mu}, \text{ para } i, j = 1, 2.$$

$$H_A: \mu_{ij} \neq \frac{(\mu_{i\bullet})(\mu_{\bullet j})}{\mu}, \text{ para ao menos um par } ij.$$

Pode-se utilizar as estatísticas já estudadas para verificar a  $H_0$   
 $T_p$ ,  $T_n$  e  $T_L$

$$E(N_{ij}) = \mu_{ij} \quad E(N_{ij}) = \frac{(\mu_{i\bullet})(\mu_{\bullet j})}{\mu}$$

$$e_{ij} = \frac{(n_{i\bullet})(n_{\bullet j})}{n}$$

Usualmente utiliza-se a distribuição multinomial nestes casos

**Justificativa:** a distribuição de probabilidades do vetor  $(N_{11}, \dots, N_{22})$ ,  $N_{ij}$  Poisson independentes, condicional à soma  $N = \sum_{i,j} N_{ij}$ , segue distribuição Multinomial  $(N, \mathbf{p})$ , com  $\mathbf{p} = (p_{11}, \dots, p_{22})$ , em que  $p_{ij} = \frac{\mu_{ij}}{\sum_{i,j} \mu_{ij}}$ , para  $i, j = 1, 2$ .

# Esquema Estudos Epidemiológicos

Quadro 7-1 Esquema para Análise de Estudos Epidemiológicos

Tipo de Estudo	Medida de Ocorrência	Medidas de Associação		Medida de Significância Estatística
		Proporcionalidade	Diferença	
Ecológico	Médias/freqüências	Razão de médias/correlação	—	Teste de diferença de médias (Z e t) Teste de significância da correlação
Seccional	Prevalência	Razão de prevalência	Diferença de prevalência (DP)	Teste de diferença de proporções (Z e t) Teste de qui-quadrado ( $x^2$ )
Coorte	Incidência	Risco relativo (RR)	Risco atribuível (RA, RAP%)	Teste de qui-quadrado ( $x^2$ )
Caso-controle	—	Odds ratio (OR)	RA de Levin (RAP%)	Teste de qui-quadrado ( $x^2$ ) Mantel-Haenszel (MH $x^2$ )

# Modelos para dados onde a variável resposta é dicotômica

- $Y \rightarrow \{0 \text{ ou } 1\}$
- $X_1, X_2, X_3, \dots, X_k$

$$E(Y | x) = \text{soma } (Y * P(Y | x))$$

# Exemplos

Tabela 0.1: Doença Coronária

Idade	Doença Coronária		Total	$P(Y = 1 x)$
	Nao	Sim		
20-29	9	1	10	0,10
30-34	13	2	15	0,13
35-39	9	3	12	0,25
40-44	10	4	14	0,29
45-49	7	5	12	0,42
50-54	3	6	9	0,67
55-59	4	13	17	0,76
60-69	2	8	10	0,80
Total	57	43	100	0,43

# Exemplos

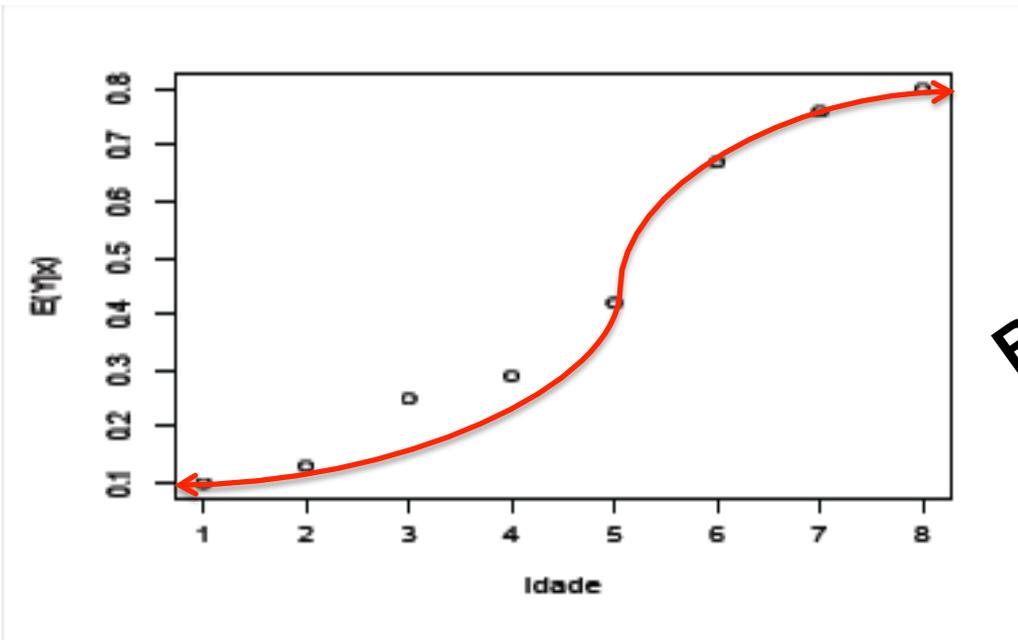
Tabela 0.2: Ocorrência de Violência

Idade	Violencia Fisica		Total	$P(Y = 1 x)$
	0	1		
15 - 25 anos	95	47	142	0,33
26 - 35 anos	86	45	131	0,34
36 - 45 anos	88	58	146	0,40
46 - 49 anos	55	21	76	0,28
Total	324	171	495	0,35

# Quantidade de interesse

$$E(Y|x) = \text{soma } (Y * P(Y|x))$$

$$\begin{aligned} E(Y|x) &= 1 * P(Y=1|x) + 0 * P(Y=0|x) \\ &= P(Y=1|x) \end{aligned}$$



**Relação não é linear**

# Função não linear

$$\underbrace{E(Y | \mathbf{x}) = P(Y = 1 | \mathbf{x})}_{\theta(\mathbf{x})} = \frac{\exp \left\{ \beta_0 + \sum_{k=1}^p \beta_k x_k \right\}}{1 + \exp \left\{ \beta_0 + \sum_{k=1}^p \beta_k x_k \right\}}$$

$$1 - \theta(\mathbf{x}) = \frac{1}{1 + \exp \left\{ \beta_0 + \sum_{k=1}^p \beta_k x_k \right\}}.$$

sendo  $\mathbf{x} = (x_1, x_2, \dots, x_p)$  = valores observados das variáveis  $\mathbf{X}$ ,  
 $\beta_0$  = constante e  $\beta_k$  ( $k = 1, \dots, p$ ) os  $p$  parâmetros de regressão.

# Função linearizável

$$\theta(\mathbf{x}) = \frac{\exp\{\beta' \mathbf{x}\}}{1 + \exp\{\beta' \mathbf{x}\}} \quad \text{e} \quad 1 - \theta(\mathbf{x}) = \frac{1}{1 + \exp\{\beta' \mathbf{x}\}}$$

$$\ln \left( \frac{\theta(\mathbf{x})}{1 - \theta(\mathbf{x})} \right) = \beta_0 + \sum_{k=1}^p \beta_k x_k = \beta' \mathbf{x}.$$

Esta transformação é denominada **logito**.

A razão entre  $\theta(\mathbf{x})$  e  $1 - \theta(\mathbf{x}) \Rightarrow$  definição de *odds*

↓

$$\text{odds} = \frac{\theta(\mathbf{x})}{1 - \theta(\mathbf{x})} = \exp\{\beta' \mathbf{x}\}.$$

# Como encontrar quantidades estimadas

Estimação de  $\beta \Rightarrow$  Método da Máxima Verossimilhança

$$L(\beta) = \prod_{\ell=1}^n P(Y = y_{\ell} | \mathbf{x}_{\ell}) = \prod_{\ell=1}^n (\theta(\mathbf{x}_{\ell}))^{y_{\ell}} (1 - \theta(\mathbf{x}_{\ell}))^{1-y_{\ell}}$$

- $y_{\ell} = 1$ , se indivíduo  $l$  apresentou a resposta e  $y_{\ell} = 0$ , c.c.
- Valores de  $\beta$  que maximizam  $\ln L(\beta) \Rightarrow \hat{\beta}$ .
- Distribuição assintótica de  $\hat{\beta} \Rightarrow$  Normal

Estimação da matriz de variâncias-covariâncias de  $\hat{\beta}$

$\Sigma(\beta) = [I(\beta)]^{-1}$  = matriz de variâncias-covariâncias

- $I(\beta)$  = matriz contendo o negativo das derivadas parciais de 2ª ordem de  $\ln L(\beta)$ .
- Estimadores são obtidos por avaliar  $\Sigma(\beta)$  em  $\hat{\beta}$ .

# Qual variável explicativa é importante?

- Testar hipóteses relativas aos parâmetros  $\beta_k$  ( $k = 1, \dots, p$ )

## 1. Teste da Razão de Verossimilhanças (TRV)

$$TRV = -2 \ln \left[ \frac{L_S}{L_C} \right] = \underbrace{2 \ln(L_C) - 2 \ln(L_S)}_{\text{equivalente à diferença de deviances}} \sim \chi_{(q)}^2$$

- $L_S$ : função de verossimilhança associada ao modelo sem a(s) variável(is) sob investigação
- $L_C$ : função de verossimilhança associada ao modelo com a(s) variável(is) sob investigação
- $q$  = diferença de parâmetros entre os dois modelos.

- Considerere que modelos encaixados sejam ajustados aos dados de um estudo em que  $Y$  é binária e  $X_1$  e  $X_2$  são categóricas com duas categorias cada.

**Tabela de Análise de *Deviances* (ANODEV).**

<b>Modelos</b>	<b>g.l.</b>	<b><i>Deviances</i></b>	<b><i>TRV</i></b>	<b><math>\neq</math> g.l.</b>
<b>Nulo</b>	$gl_N$	$D_N$		
$X_1$	$gl_N - 1$	$D_1$	$D_N - D_1$	1
$X_2   X_1$	$gl_N - 2$	$D_2$	$D_1 - D_2$	1
$X_1 * X_2   X_1, X_2$	$gl_N - 3$	$D_3$	$D_2 - D_3$	1

$gl_N =$  g.l. do modelo nulo = número de subpopulações – 1

- Obs: na presença de dados faltantes, o tamanho amostral nos modelos sequenciais dependerá das variáveis  $X_k$  que os compõem  $\Rightarrow TRV$  apresentará problemas.

# Ainda escolhendo variáveis

## 2. Teste de Wald (Wald, 1943)

i) Para testar hipóteses relativas a um parâmetro

$$H_0 : \beta_k = 0, k = 1, \dots, p$$

$$W = \frac{(\hat{\beta}_j)^2}{\widehat{Var}(\hat{\beta}_j)} \sim \chi_1^2$$

ii) Para hipóteses relativas a  $q \geq 2$  parâmetros

$$H_0 : \beta^* = \mathbf{0} \quad (\beta^* = \text{vetor } q \times 1)$$

$$W = (\hat{\beta}^*)' [\widehat{\Sigma}(\hat{\beta}^*)]^{-1} (\hat{\beta}^*) \sim \chi_q^2$$

- Sob a hipótese  $H_0$ : modelo ajustado é satisfatório, faz-se uso de estatísticas que resumem a concordância entre os valores observados e os preditos pelo modelo.

$$Q_P = \sum_{i,j} \frac{(n_{ij} - e_{ij})^2}{e_{ij}} \sim \chi_m^2$$

$$Q_L = 2 \sum_{i,j} n_{ij} \ln \left( \frac{n_{ij}}{e_{ij}} \right) \sim \chi_m^2$$

$$e_{ij} = n_{i+} \hat{\theta}(\mathbf{x}_i), j = 1 \quad \text{e} \quad e_{ij} = n_{i+} (1 - \hat{\theta}(\mathbf{x}_i)), j = 2.$$

$n_{i+}$  = sujeitos na  $i$ -ésima subpopulação da tabela de dados  $s \times 2$ .

$\hat{\theta}(\mathbf{x}_i)$  = probabilidade  $P(Y = 1 | \mathbf{x}_i)$  predita pelo modelo ajustado.

$e_{ij}$  = frequências esperadas sob o modelo ajustado.

$m = n^o$  subpopulações –  $n^o$  parâmetros do modelo ajustado.

- Na presença de variáveis contínuas  $\Rightarrow$  frequências muito pequenas para a grande maioria das  $s$  subpopulações.



inviabiliza o uso de  $Q_L$  e  $Q_P$



Hosmer e Lemeshow (1989) propuseram **uma estatística alternativa**,  $Q_{HL}$ , que é obtida calculando-se a estatística qui-quadrado de Pearson a partir de uma tabela  $g \times 2$  de frequências observadas e previstas

# Estatística de Hosmer e Lemeshow

- Inicialmente, as  $n$  observações são ordenadas em ordem crescente das probabilidades  $\theta(\mathbf{x})$  previstas pelo modelo.
- Tais observações são, então, divididas em  $g$  grupos ( $g = 10$ , por exemplo). No 1<sup>o</sup> grupo ficam as  $n_1$  observações com probabilidades estimadas  $< 0,1$  e, no último, as  $n_g$  observações com probabilidades  $\geq 0,9$ .

$$Q_{HL} = \sum_{i=1}^g \frac{(o_i - n_i \bar{\theta}(\mathbf{x}_i))^2}{n_i \bar{\theta}(\mathbf{x}_i) (1 - \bar{\theta}(\mathbf{x}_i))} \sim \chi_{(g-2)}^2$$

$n_i$  = frequência de observações no grupo  $i$

$o_i$  = frequência de resposta  $Y = 1$  no grupo  $i$

$\bar{\theta}(\mathbf{x}_i)$  = probab. média estimada de resposta  $Y = 1$  no grupo  $i$ .

# Voltamos ao exemplo

Tabela 0.1: Doença Coronária

Idade	Doença Coronária		Total	P(Y = 1 x)
	Nao	Sim		
20-29	9	1	10	0,10
30-34	13	2	15	0,13
35-39	9	3	12	0,25
40-44	10	4	14	0,29
45-49	7	5	12	0,42
50-54	3	6	9	0,67
55-59	4	13	17	0,76
60-69	2	8	10	0,80
Total	57	43	100	0,43

$$\hat{\beta}_0 = -5,123 \text{ (e.p.} = 1,11) \text{ e } \hat{\beta}_1 = 0,1058 \text{ (e.p.} = 0,023).$$

$$\hat{\theta}(\mathbf{x}) = \frac{\exp\{-5,123 + 0,1058 \mathbf{x}\}}{1 + \exp\{-5,123 + 0,1058 \mathbf{x}\}}$$

$$\ln\left(\frac{\hat{\theta}(\mathbf{x})}{1 - \hat{\theta}(\mathbf{x})}\right) = -5,123 + 0,1058 \mathbf{x}$$

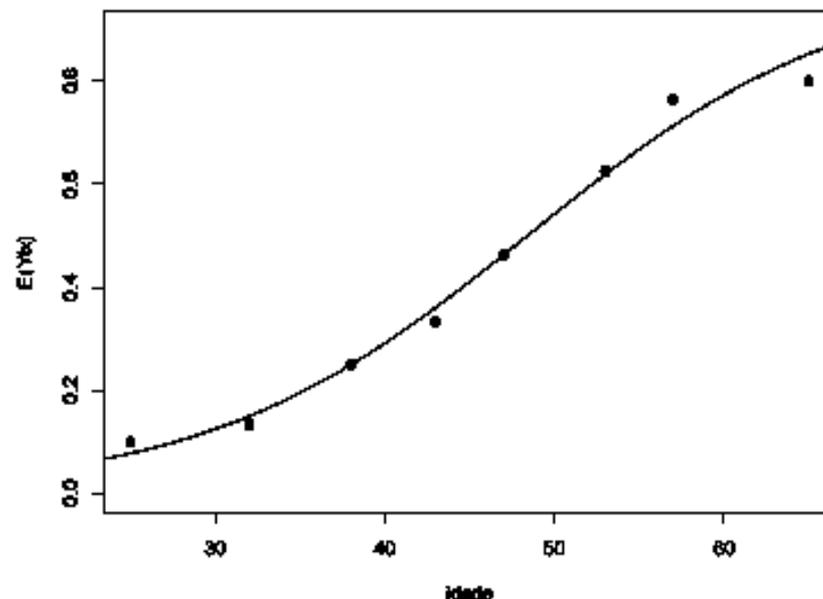
Tabela 1. Diferenças de *deviances*

Modelos	g.l.	<i>Deviances</i>	Diferenças	$\neq$ g.l.
Nulo	7	28,7015		
X: idade	6	0,5838	28,1177	1

Tabela 2. Análise de *Deviance* (ANODEV)

Fonte de variação	g.l.	<i>Deviances</i>	<i>TRV</i>	valor <i>p</i>
Regressão	1	28,1177	28,1177	< 0,00001
<i>Deviance</i> residual	6	0,5838		
<i>Deviance</i> total	7	28,7015		

- Evidências de associação entre idade e doença coronária.
- Ainda, teste de Wald  $\Rightarrow W = 20,49$  (g.l. = 1,  $p < 0,00001$ )



A partir do modelo ajustado tem-se, por exemplo:

$x_i$	$\hat{\theta}(x_i)$	$1 - \hat{\theta}(x_i)$	$\frac{\hat{\theta}(x_i)}{1 - \hat{\theta}(x_i)} = \exp\{\hat{\beta}_0 + \hat{\beta}_1 x_i\}$
26	0,0853	0,9147	$\exp\{\hat{\beta}_0 + \hat{\beta}_1 * 26\} = 0,093$
27	0,0939	0,9061	$\exp\{\hat{\beta}_0 + \hat{\beta}_1 * 27\} = 0,103$
65	0,8524	0,1476	$\exp\{\hat{\beta}_0 + \hat{\beta}_1 * 65\} = 5,774$

- Relembrando que  $\frac{\theta(x_i)}{1 - \theta(x_i)} = odds$ , segue que:

$$\widehat{OR} = \frac{odds_{(27)}}{odds_{(26)}} = \exp\{\widehat{\beta}_1(27 - 26)\} = \exp\{\widehat{\beta}_1\} \approx 1,11$$

$$\widehat{OR} = \frac{odds_{(65)}}{odds_{(26)}} = \exp\{\widehat{\beta}_1(65 - 26)\} = \exp\{\widehat{\beta}_1 * 39\} \approx 62$$

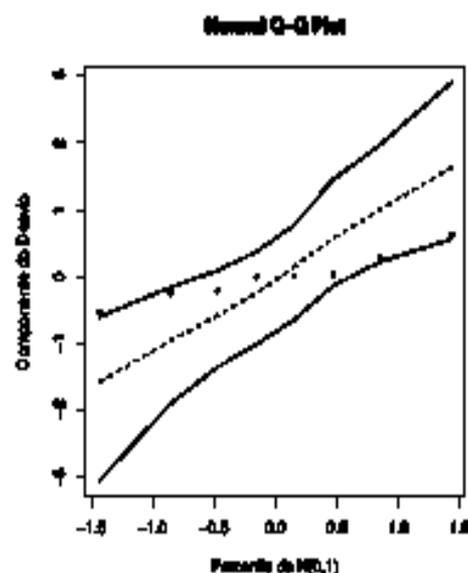
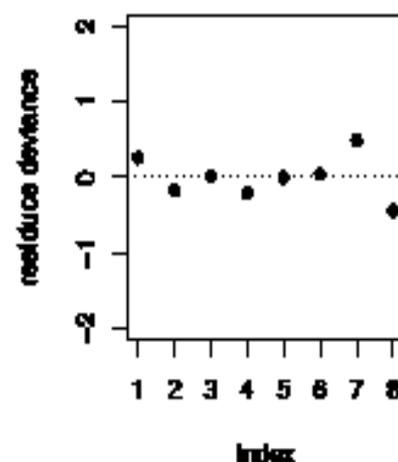
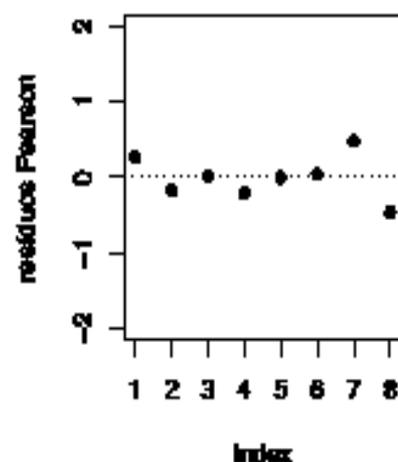
- A *odds* de doença coronária entre indivíduos com 65 anos de idade é  $\approx 62$  vezes a dos indivíduos com 26 anos.

Obs: *OR* nos modelos de regressão logística são denominadas *OR* ajustadas, uma vez que o efeito  $\beta_k$  associado à covariável  $k$  é estimado na presença dos demais no modelo.

Ajuste bom????

Qual a qualidade deste ajuste????

- $Q_p = 0,59$  ( $p = 0,9965$ ) e  $Q_L = 0,58$  ( $p = 0,9967$ ), g.l.= 6.
- Resíduos  $c_i$  e  $d_i$  entre  $-2,5$  e  $2,5$ .



- Área abaixo da curva ROC:  $AUC \approx 0,79$ .
- Evidências favoráveis ao modelo ajustado.

- Limitação das estatísticas  $Q_p$  e  $Q_L \Rightarrow$  único valor é utilizado para resumir uma quantidade considerável de informação.
- Pregibon (1981) estendeu os métodos de diagnóstico de regressão linear para a regressão logística, fazendo uso dos componentes individuais das estatísticas  $Q_p$  e  $Q_L$ .

$$c_i = \frac{n_{i1} - (n_{i+}) \hat{\theta}(\mathbf{x}_i)}{\underbrace{\sqrt{(n_{i+}) \hat{\theta}(\mathbf{x}_i) (1 - \hat{\theta}(\mathbf{x}_i))}}_{\text{resíduos de Pearson}}}, i = 1, \dots, s.$$

- Componentes  $c_i$  são denominados **resíduos de Pearson**, pois a soma deles ao quadrado resulta em  $Q_P$ , i.e.,

$$Q_P = \sum_{i=1}^s (c_i)^2$$

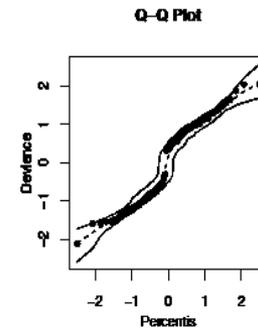
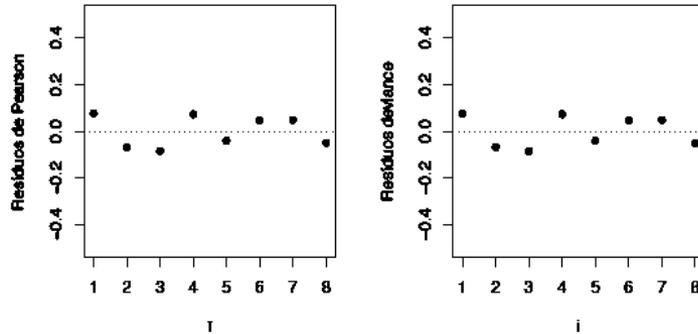
- Limitação das estatísticas  $Q_p$  e  $Q_L \Rightarrow$  único valor é utilizado para resumir uma quantidade considerável de informação.
- Pregibon (1981) estendeu os métodos de diagnóstico de regressão linear para a regressão logística, fazendo uso dos componentes individuais das estatísticas  $Q_p$  e  $Q_L$ .

$$c_i = \frac{n_{i1} - (n_{i+}) \hat{\theta}(\mathbf{x}_i)}{\underbrace{\sqrt{(n_{i+}) \hat{\theta}(\mathbf{x}_i) (1 - \hat{\theta}(\mathbf{x}_i))}}_{\text{resíduos de Pearson}}}, i = 1, \dots, s.$$

- Componentes  $c_i$  são denominados **resíduos de Pearson**, pois a soma deles ao quadrado resulta em  $Q_P$ , i.e.,

$$Q_P = \sum_{i=1}^s (c_i)^2$$

- Distribuição aproximada dos resíduos  $c_i$  e  $d_i \sim N(0, 1)$ .
- Resíduos excedendo  $\pm 2,5$  pode indicar
  - possível falta de ajuste do modelo
  - presença de *outliers*
  - padrões sistemáticos de variação.
- Assumindo que os resíduos  $d_i$  seguem distribuição aproximada normal  $\Rightarrow$  construir *normal Q-Q plot* com envelope simulado (Davison e Gigli, 1989).



- Se os resíduos estiverem dentro do envelope simulado  $\Rightarrow$  evidências favoráveis ao modelo ajustado.

Ben e Yohai (2004) argumentam, contudo, que para alguns MLG, tal distribuição pode estar distante da normalidade.

Assim, propuseram uma estimativa da distribuição dos resíduos  $d_i$ , de modo que no *Q-Q plot* tais resíduos são graficado versus os quantis da distribuição estimada.

Para avaliar o poder preditivo do modelo é necessário estabelecer um *ponto de corte* ( $0 < pc < 1$ ), tal que:

a) Probabilidades preditas pelo modelo  $\geq pc \Rightarrow Y = 1$

b) Probabilidades preditas pelo modelo  $< pc \Rightarrow Y = 0$ .

Resposta Observada	Resposta Predita pelo Modelo		Totais
	Y = 1 (+)	Y = 0 (-)	
Y = 1 (+)	a	b	(a + b)
Y = 0 (-)	c	d	(c + d)
Totais	(a + c)	(b + d)	n

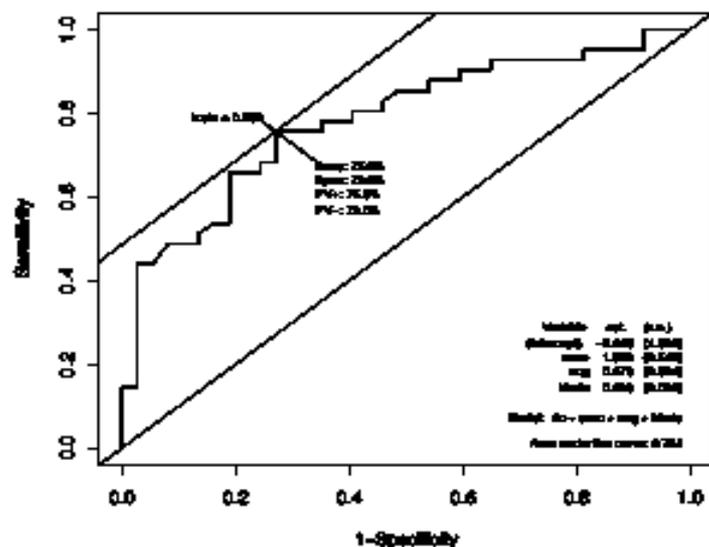
$\Rightarrow$  **Sensibilidade** =  $\frac{a}{a+b}$  = taxa de verdadeiros +

$\Rightarrow$  **Especificidade** =  $\frac{d}{c+d}$  = taxa de verdadeiros -

$\Rightarrow$  **Valor Preditivo** =  $\frac{a+d}{n}$  = proporção geral de acertos

## Para diversos pontos de corte $\Rightarrow$ Curva ROC

- Pares  $(x, y) = (1 - \text{especificidade}, \text{sensibilidade})$ .
- Modelo com discriminação perfeita  $\Rightarrow (x, y) = (0, 1)$ .
- Pontos de corte próximos ao canto superior esquerdo, produzirão os maiores % de acertos ( $V+$  e  $V-$ ).
- Quanto mais próxima de 1 for a área abaixo da curva, melhor o poder de predição do modelo.



# NO R

```
resim<-c(1,2,3,5,6,5,13,8)
resnao<-c(9,13,9,10,7,3,4,2)
idade<-c(25,32,38,43,47,53,57,65)
dados<-as.data.frame(cbind(resim,resnao,idade))
attach(dados)
ajust<-glm(as.matrix(dados[,c(1,2)])~idade,
           family=binomial(link="logit"),data=dados)
anova(ajust,test="Chisq")
summary(ajust)
ajust$y
ajust$fitted.values
dev<-residuals(ajust,type='deviance')
QL<-sum(dev^2)
p1<-1-pchisq(QL,6)
cbind(QL,p1)
plot(dev,ylim=c(-2,2),ylab="residuos deviance",pch=16)
abline(h=0, lty=3)
```

```
rpears<-residuals(ajust,type='pearson')
```

```
rpears
```

```
QP<-sum(rpears^2)
```

```
p2<-1-pchisq(QP,6)
```

```
cbind(QP,p2)
```

```
plot(rpears,ylim=c(-2,2),ylab="residuos Pearson",pch=16)
```

```
abline(h=0,lty=3)
```

```
theta<-resim/(resim+resnao)
```

```
plot(idade,theta,ylim=range(0,0.9),xlab="idade",
```

```
      ylab="E(Y|x)",pch=16)
```

```
idade<-20:70
```

```
modajust<-(exp(-5.123+0.1058*idade))/(1+ exp(-5.123+  
      0.1058*idade))
```

```
lines(idade,modajust)
```

```
ntot<-c(10,15,12,15,13,8,17,10)
fit.model<-ajust
source("http://www.ime.usp.br/~giapaula/envelr_bino")

dados1<-read.table("coronaria.txt",h=T)
# dados 1 = arquivo com 1 indivíduo por linha (100 x 2)
attach(dados1)
dados1[1:3,]
y idade
1 25
0 25
0 25
...
require(Epi)
ROC(form=y~idade,plot="ROC")
```

## FUNÇÃO LIGAÇÃO

Alguns *links* para dados com resposta binária.

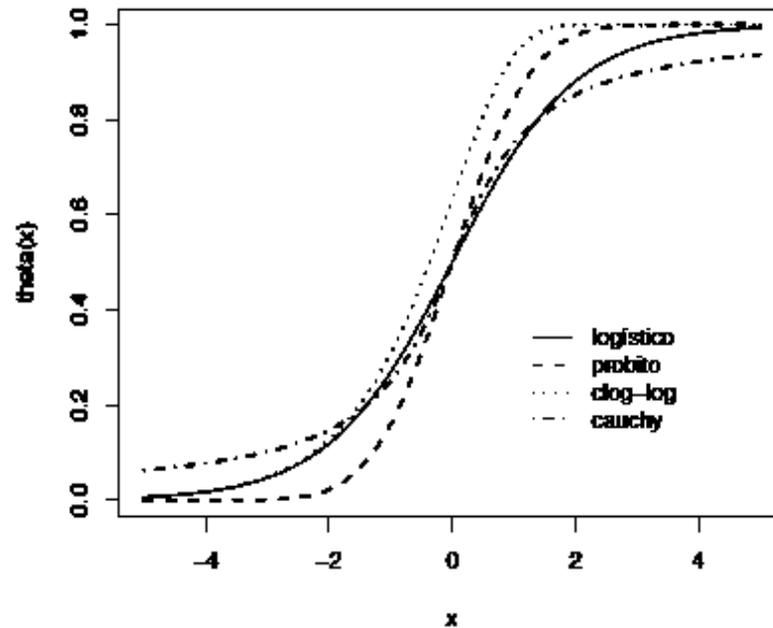
$\theta(\mathbf{x}) = F(\beta' \mathbf{x})$	<i>links</i> paramétricos alternativos	
$\frac{\exp\{\beta' \mathbf{x}\}}{1 + \exp\{\beta' \mathbf{x}\}}$	logito	$\Rightarrow \ln \left( \frac{\theta(\mathbf{x})}{1 - \theta(\mathbf{x})} \right)$
$\Phi(\beta' \mathbf{x})$	probito	$\Rightarrow \Phi^{-1}(\theta(\mathbf{x}))$
$1 - \exp\{-\exp\{\beta' \mathbf{x}\}\}$	clog-log	$\Rightarrow \ln(-\ln(1 - \theta(\mathbf{x})))$
$\frac{1}{2} + \frac{\text{arctg}(\beta' \mathbf{x})}{\pi}$	cauchy	$\Rightarrow F^{-1}(\theta(\mathbf{x}))$

$\Phi(\cdot)$  denota a função de distribuição da  $N(0,1)$ ,  $\text{arctg}$  = arco tangente

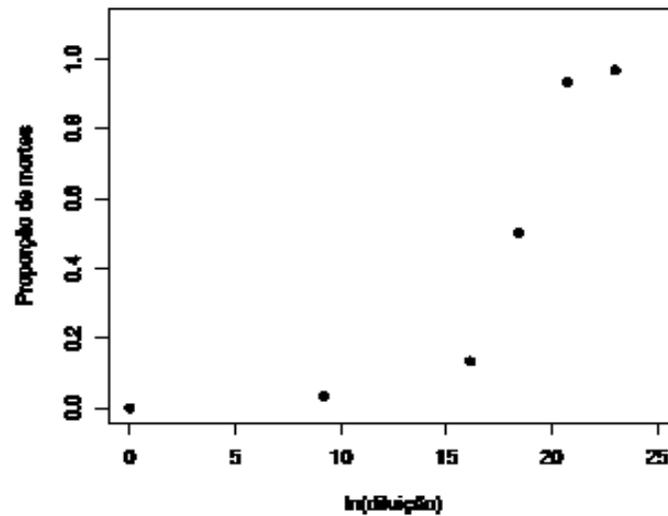
$F(\cdot)$  denota a função de distribuição da Cauchy(0,1)  $\sim$  t-Student<sub>(1g.l.)</sub>

$\Rightarrow$  Simétricos: logístico, probito e cauchy

$\Rightarrow$  Assimétricos: complemento log-log.



- Procedimentos de estimação, qualidade e diagnóstico são análogos aos do modelo logístico.
- Interpretação dos parâmetros difere da apresentada para o modelo logístico.



Logístico  $\Rightarrow \theta(x_i) = \frac{\exp\{\beta_0 + \beta_1 x_i\}}{1 + \exp\{\beta_0 + \beta_1 x_i\}}$

Probito  $\Rightarrow \theta(x_i) = \Phi(\beta_0 + \beta_1 x_i)$

Clog-log  $\Rightarrow \theta(x_i) = 1 - \exp\{-\exp\{\beta_0 + \beta_1 x_i\}\}$

Cauchy  $\Rightarrow \theta(x_i) = \frac{1}{2} + \frac{\arctan(\beta_0 + \beta_1 x_i)}{\pi}$

## EXEMPLO

- Bioensaio conduzido em laboratório por Machado (2006).
- Objetivo: concentração ideal de uma suspensão viral.

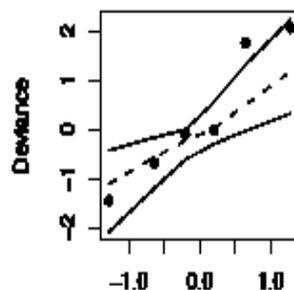
Diluições (CPI/ml)	Mortes		Totais
	Sim	Não	
Testemunha	0	30	30
$10^3$	1	29	30
$10^6$	4	26	30
$10^7$	15	15	30
$10^8$	28	2	30
$10^9$	29	1	30

- $x_i$  = logaritmo neperiano das diluições.

## Estatística *deviance* de qualidade de ajuste

	Logito	Probito	Clog-log	Cauchy
$Q_L$	6,59	10,99	6,18	1,72
p-valor	0,158	0,027	0,186	0,787

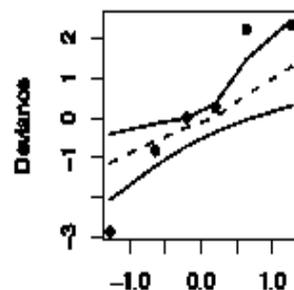
Normal Q-Q Plot



Percentis da N(0,1)

a) logito

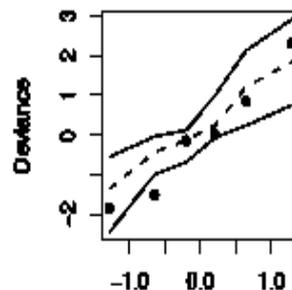
Normal Q-Q Plot



Percentis da N(0,1)

b) probito

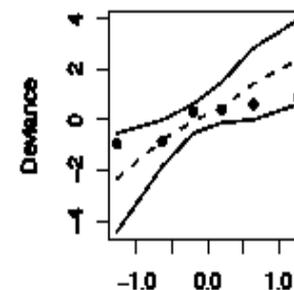
Normal Q-Q Plot



Percentis da N(0,1)

c) clog-log

Normal Q-Q Plot



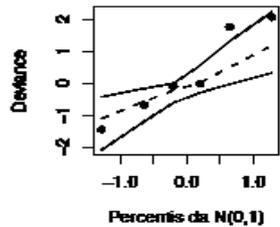
Percentis da N(0,1)

d) Cauchy

## Estatística *deviance* de qualidade de ajuste

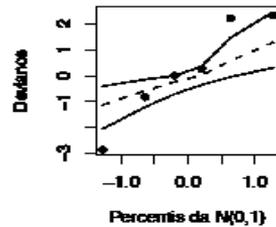
	Logito	Probito	Clog-log	Cauchy
$Q_L$	6,59	10,99	6,18	1,72
p-valor	0,158	0,027	0,186	0,787

Normal Q-Q Plot



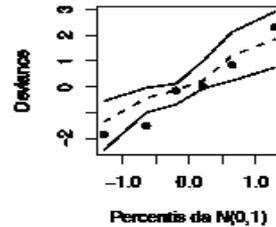
a) logito

Normal Q-Q Plot



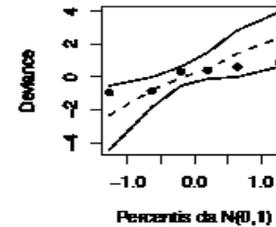
b) probito

Normal Q-Q Plot



c) clog-log

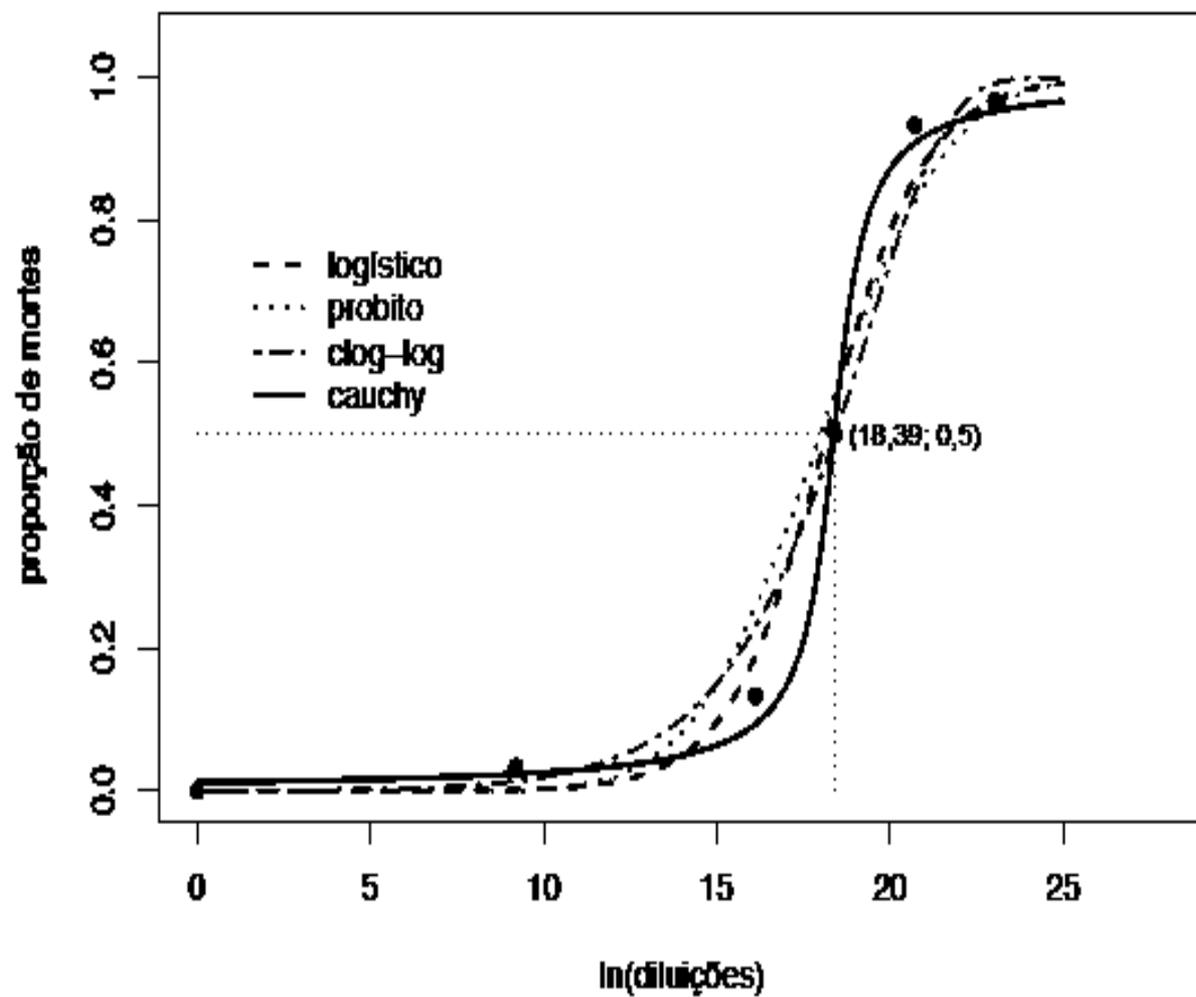
Normal Q-Q Plot



d) Cauchy

		$x_{50} = \ln(\widehat{LD}_{50})$	$\widehat{LD}_{50}$
Logito	$\ln\left(\frac{0,50}{1-0,50}\right) = \widehat{\beta}_0 + \widehat{\beta}_1 x$	$-\frac{\widehat{\beta}_0}{\widehat{\beta}_1} \approx 18,17$	$(7,7)^7$
Probito	$\Phi^{-1}(0,50) = \widehat{\beta}_0 + \widehat{\beta}_1 x$	$-\frac{\widehat{\beta}_0}{\widehat{\beta}_1} \approx 18,00$	$(6,6)^7$
Clog-log	$\ln(-\ln(1-0,50)) = \widehat{\beta}_0 + \widehat{\beta}_1 x$	$\frac{-0,3665 - \widehat{\beta}_0}{\widehat{\beta}_1} \approx 18,43$	$(10)^7$
Cauchy	$F^{-1}(0,50) = \widehat{\beta}_0 + \widehat{\beta}_1 x$	$-\frac{\widehat{\beta}_0}{\widehat{\beta}_1} \approx 18,39$	$(9,7)^7$

**Obs:** para os modelos com *links* simétricos  $\Rightarrow x_{50} = -\frac{\widehat{\beta}_0}{\widehat{\beta}_1}$ .



```

resim<-c(0,1,4,15,28,29)
resnao<-c(30,29,26,15,2,1)
lnd<-c(0,9.21,16.12,18.42,20.72,23.02)
dados<-as.data.frame(cbind(resim,resnao,lnd))
attach(dados)

ajuste4<-glm(as.matrix(dados[,c(1,2)])~lnd,
             family=binomial(link="cauchit"),data=dados)
ajuste4
anova(ajuste4,test="Chisq")
summary(ajuste4)
ntot<-c(30,30,30,30,30,30)
fit.model<-ajuste4
source("http://www.ime.usp.br/~giapaula/envelr_bino")

x<-seq(0,25,0.1)
m4<- pcauchy(-26.678+1.451*x)

plot(lnd,resim/(resim+resnao),pch=16, ylab="proporção de
mortes",xlab="ln(diluições)",xlim=c(0,28),ylim=c(0,1.05))
lines(x,m4,lty=1,lwd=2,col=1)
legend(1,0.8,lty=c(1),col=c(1),lwd=2,c("cauchy"),bty="n")

lines(c(18.386,18.386),c(0,0.50),lty=3)
lines(c(0,18.386),c(0.50,0.50),lty=3)
legend(17.7,0.55,c("(18.386, 0.5)"),bty="n",cex=0.8)

```