

# Modelos de regressão para dados de contagem (parte 4) (superdispersão)

Prof. Caio Azevedo

# Superdispersão (ou sobredispersão)

- Quando a variável resposta apresenta variância maior do que aquela imposta pelo modelo probabilístico/regressão.
- Exemplos 4 (análise descritiva/inferencial).
- Quando o modelo de regressão define grupos (covariáveis qualitativas, como no Exemplo 4) podemos comparar as médias amostrais com as variâncias amostrais.
- Contudo, mesmo quando a abordagem acima não é factível, podemos tentar identificar a presença de tal problema através de análises de diagnóstico.

## Cont.

- Do ponto de vista inferencial, quando o desvio  $D(\mathbf{y}; \tilde{\boldsymbol{\mu}})$  é maior que o número de graus de liberdade  $(n-p)$ , pode haver indícios de sobredispersão.
- Isso pode ser avaliado mais precisamente pelo nível descritivo do teste de ajustamento através do desvio (utilizando de sua aproximação pela distribuição de qui-quadrado, quando pertinente).
- O gráfico de envelopes e os de diagnóstico também podem fornecer indícios da existência de superdispersão.
- Diferentes circunstâncias, entretanto, podem causar um valor alto para o desvio. Algumas delas representam uma sobredispersão aparente (veja slide seguinte).

## Cont.

- Presença de pontos aberrantes, ausência de covariáveis relevantes ou de algum termo na parte sistemática ( $\eta_i$ ), incorreta especificação da função de ligação.
- A superdispersão também pode ser causada por: existência de subgrupos com diferentes distribuições, dependência entre as observações, características latentes (não observáveis diretamente) presentes nas unidades experimentais, fatores não controlados no experimento entre outros.
- Medidas de diagnóstico, vistas anteriormente, são ferramentas importantes para detectarmos o fenômeno.

# Consequências de superdispersão (Hinde e Demétrio (1998))

- Os erros-padrão estimados (a partir do modelo) podem ser (muito) subestimados conseqüentemente, podemos avaliar incorretamente a importância dos parâmetros (significância).
- Podem ocorrer (grandes) mudanças no valor do desvio as quais podem conduzir à seleção de modelos extremamente complexos.
- Finalmente, podemos selecionar modelos inapropriados e as previsões podem ser (falsamente) “precisas” (menor comprimento dos intervalos de confiança).

# Modelagem da super-dispersão

- Consideraremos uma abordagem que considera variáveis latentes.
- Suponha que para um conjunto fixo  $\mathbf{x} = (x_1, \dots, x_p)'$  de valores de variáveis explicativas,  $Y|z$  (resposta) tem média  $z$  e variância  $z$ .
- No entanto  $Z$ , que é não observável, varia nas unidades amostrais, (ou seja, temos  $(Y_i, Z_i)$ ,  $i=1,2,\dots,n$ ) com  $\mathbf{x}$  fixo, de modo que  $E(Z) = \mu$ .
- Assim  $\mathcal{E}(Y) = \mathcal{E}(\mathcal{E}(Y|Z)) = \mathcal{E}(Z) = \mu$  e  $\mathcal{V}(Y) = \mathcal{E}(\mathcal{V}(Y|Z)) + \mathcal{V}(\mathcal{E}(Y|Z)) = \mu + \mathcal{V}(Z)$ .

# Modelagem da super-dispersão

- Podemos assumir que  $Y|Z = z \sim \text{Poisson}(z)$  e  $Z \sim \text{gama}(\mu, \phi)$  (sob a parametrização adotada no curso).
- Assim  $\mathcal{E}(Z) = \mu$  e  $\mathcal{V}(Z) = \mu^2/\phi$ . Isto implica que  $\mathcal{E}(Y) = \mu$  e  $\mathcal{V}(Y) = \mu + \mu^2/\phi$ .
- Note que se  $\phi \rightarrow \infty$  então  $\mathcal{V}(Y) \rightarrow \mathcal{E}(Y) = \mu$  (à rigor teremos o modelo de Poisson).

- Além disso,  $f(y|z) = \frac{e^{-z} z^y}{y!} \mathbf{1}_{\{0,1,2,\dots\}}(y)$  e

$$g(z) = \frac{1}{\Gamma(\phi)} \left( \frac{z\phi}{\mu} \right)^\phi e^{-\frac{\phi z}{\mu}} \frac{1}{z} \mathbf{1}_{(0,\infty)}(z).$$

# Modelagem da super-dispersão

- Portanto, a fdp de  $Y$  é dada por

$$\begin{aligned} f(y) &= \int_0^\infty f(y|z)g(z)dy = \frac{1}{y!\Gamma(\phi)} \left(\frac{\phi}{\mu}\right)^\phi \int_0^\infty e^{-z(1+\phi/\mu)} z^{\phi+y-1} dz \\ &= \frac{1}{y!\Gamma(\phi)} \left(\frac{\phi}{\mu}\right)^\phi \frac{\Gamma(\phi+y)}{(1+\phi/\mu)^{\phi+y}} = \frac{\Gamma(\phi+y)}{\Gamma(y+1)\Gamma(\phi)} \frac{\phi^\phi}{\mu^\phi} \frac{\mu^{\phi+y}}{(\mu+\phi)^{\phi+y}} \\ &= \frac{\Gamma(\phi+y)}{\Gamma(y+1)\Gamma(\phi)} \left(\frac{\phi}{\mu+\phi}\right)^\phi \left(\frac{\mu}{\mu+\phi}\right)^y \mathbb{1}_{\{0,1,2,\dots\}}(y) \end{aligned}$$

- Assim, temos que  $Y \sim \text{BN}(\mu, \phi)$ . Neste caso, a distribuição BN (binomial negativa) não pertence à parametrização da FE adotada para a construção dos MLG.



# Modelo de regressão binomial-negativo

- Sejam  $Y_i, i = 1, 2, \dots, n$ ,  $Y_i \stackrel{ind.}{\sim} \text{BN}(\mu_i, \phi)$ .
- Temos que  $\mathcal{E}(Y_i) = \mu_i$  e  $\mathcal{V}(Y_i) = \mu_i + \frac{\mu_i^2}{\phi}$ .
- $g(\mu_i) = \eta_i \rightarrow \mu_i = g^{-1}(\eta_i)$ ,  $\eta_i = \mathbf{X}_i\boldsymbol{\beta}$ ,  $g(\cdot)$  é uma função de ligação apropriada, inversível e duplamente diferenciável.
- Comumente,  $g(\mu_i) = \ln(\mu_i)$ . Outras escolhas  $g(\mu_i) = \mu_i, \sqrt{\mu_i}, 1/\mu_i$ .

# Estimação por MV

- Logverossimilhança (seja  $\theta = (\beta, \phi)$ ).

$$\begin{aligned}l(\theta) &= \sum_{i=1}^n \left\{ \ln \left[ \frac{\Gamma(\phi + y_i)}{\Gamma(y_i + 1)\Gamma(\phi)} \right] + \phi \ln(\phi) + y_i \ln(\mu_i) \right. \\ &\quad \left. - (\phi + y_i) \ln(\mu_i + \phi) \right\} \\ &= \sum_{i=1}^n \left\{ \ln [\Gamma(\phi + y_i)] - \ln [\Gamma(y_i + 1)] - \ln [\Gamma(\phi)] + \phi \ln(\phi) \right. \\ &\quad \left. + y_i \ln(\mu_i) - (\phi + y_i) \ln(\mu_i + \phi) \right\}\end{aligned}$$

# Estimação por MV

- Vetor escore para  $\beta$  (cada componente)

$$\begin{aligned} S(\beta_j) &= \sum_{i=1}^n \left\{ \frac{y_i}{\mu_i} \frac{\partial \mu_i}{\partial \eta_i} \frac{\partial \eta_i}{\partial \beta_j} - \frac{\phi + y_i}{\phi + \mu_i} \frac{\partial \mu_i}{\partial \eta_i} \frac{\partial \eta_i}{\partial \beta_j} \right\} \\ &= \sum_{i=1}^n \left\{ \frac{y_i}{\mu_i} \frac{\partial \mu_i}{\partial \eta_i} x_{ji} - \frac{\phi + y_i}{\phi + \mu_i} \frac{\partial \mu_i}{\partial \eta_i} x_{ji} \right\} \\ &= \sum_{i=1}^n \left\{ \frac{\phi (\partial \mu_i / \partial \eta_i)}{\mu_i (\phi + \mu_i)} (y_i - \mu_i) x_{ji} \right\} = \sum_{i=1}^n \omega_i f_i^{-1} (y_i - \mu_i) x_{ji} \end{aligned}$$

- Em que  $\omega_i = (\partial \mu_i / \partial \eta_i)^2 / (\mu_i^2 \phi^{-1} + \mu_i)$  e  $f_i = \partial \mu_i / \partial \eta_i$

# Estimação por MV

- Matricialmente, temos

$$S(\beta) = \mathbf{X}'\mathbf{W}\mathbf{F}^{-1}(\mathbf{y} - \boldsymbol{\mu})$$

em que  $\mathbf{X}$  é a matriz de planejamento do modelo (conforme visto anteriormente),  $\mathbf{W} = \text{diag}\{\omega_1, \dots, \omega_n\}$ ,  $\mathbf{F} = \text{diag}\{f_1, \dots, f_n\}$ ,  $\mathbf{y} = (y_1, \dots, y_n)'$  e  $\boldsymbol{\mu} = (\mu_1, \dots, \mu_n)'$ .

# Estimação por MV

- Para o parâmetro  $\phi$ , temos que

$$S(\phi) = \sum_{i=1}^n \left[ \Psi(\phi + y_i) - \Psi(\phi) - \frac{y_i + \phi}{\phi + \mu_i} + \ln(\phi) - \ln(\mu_i + \phi) + 1 \right]$$

em que  $\Psi(\cdot)$  é a função digama (vista anteriormente).

- Podemos notar que o sistema  $\begin{cases} \mathbf{S}(\tilde{\beta}) = \mathbf{0}_{(p \times 1)} \\ S(\tilde{\phi}) = 0 \end{cases}$  não apresenta solução analítica. Assim, algum método numérico deverá ser empregado e, nesse caso, utilizaremos o algoritmo Escore de Fisher semelhante ao que fizemos para os MLG.

# Estimação por MV

## ■ Matriz Hessiana

$$\begin{aligned}\frac{\partial^2 l(\boldsymbol{\theta})}{\partial \beta_j \partial \beta_l} &= \frac{\partial}{\partial \beta_l} \sum_{i=1}^n \left\{ \frac{y_i}{\mu_i} \frac{\partial \mu_i}{\partial \eta_i} x_{ji} - \frac{\phi + y_i}{\phi + \mu_i} \frac{\partial \mu_i}{\partial \eta_i} x_{ji} \right\} \\ &= \sum_{i=1}^n \left\{ \frac{y_i}{\mu_i^2} x_{ji} \left[ \frac{\partial^2 \mu_i}{\partial \eta_i^2} \mu_i x_{li} - x_{li} \left( \frac{\partial \mu_i}{\partial \eta_i} \right)^2 \right] \right. \\ &\quad \left. - x_{ji} \frac{\phi + y_i}{(\phi + \mu_i)^2} \left[ \frac{\partial^2 \mu_i}{\partial \eta_i^2} (\phi + \mu_i) x_{li} - \left( \frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{li} \right] \right\} \\ &= \sum_{i=1}^n \left\{ \frac{\phi + y_i}{(\phi + \mu_i)^2} - \frac{y_i}{\mu_i^2} \right\} \left( \frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{ji} x_{jl} \\ &\quad + \sum_{i=1}^n \left\{ \frac{y_i}{\mu_i} - \frac{\phi + y_i}{\phi + \mu_i} \right\} \frac{\partial^2 \mu_i}{\partial \eta_i^2} x_{ji} x_{jl}\end{aligned}$$

## ■ Informação de Fisher

$$\begin{aligned}
 I(\beta_j, \beta_l) &= -\mathcal{E} \left( \sum_{i=1}^n \left\{ \frac{\phi + Y_i}{(\phi + \mu_i)^2} - \frac{Y_i}{\mu_i^2} \right\} \left( \frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{ji} x_{jl} \right. \\
 &\quad \left. + \sum_{i=1}^n \left\{ \frac{Y_i}{\mu_i} - \frac{\phi + Y_i}{\phi + \mu_i} \right\} \frac{\partial^2 \mu_i}{\partial \eta_i^2} x_{ji} x_{jl} \right) \\
 &= -\sum_{i=1}^n \left\{ \frac{1}{(\phi + \mu_i)} - \frac{1}{\mu_i} \right\} \left( \frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{ji} x_{jl} \\
 &= \sum_{i=1}^n \left\{ \frac{\phi}{(\phi + \mu_i) \mu_i} \right\} \left( \frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{ji} x_{jl} = \sum_{i=1}^n \left\{ \frac{\left( \frac{\partial \mu_i}{\partial \eta_i} \right)^2 \phi}{(\phi + \mu_i) \mu_i} \right\} x_{ji} x_{jl} \\
 &= \sum_{i=1}^n \omega_i x_{ji} x_{jl}
 \end{aligned}$$

# Estimação por MV

- Matricialmente, temos  $I(\beta, \beta) = \mathbf{X}' \mathbf{W} \mathbf{X}$ .
- Por outro lado, Lawless (1987) mostra que a componente da informação de Fisher para  $\phi$  pode ser expressa na forma:

$$I(\phi, \phi) = \sum_{i=1}^n \left\{ \sum_{j=0}^{\infty} (\phi + j)^{-2} P(Y_i \geq j) - \phi^{-1} \mu_i / (\mu_i + \phi) \right\}$$

e que  $\beta$  e  $\phi$  são ortogonais, ou seja,  $I(\beta, \phi) = \mathbf{0}_{(p \times 1)}$ .



# Estimação por MV

- Assim, embora a Informação de Fisher seja bloco diagonal, ou seja,

$$I(\boldsymbol{\beta}, \phi) = \begin{bmatrix} \mathbf{X}'\mathbf{W}\mathbf{X} & \mathbf{0}_{(p \times 1)} \\ \mathbf{0}_{(1 \times p)} & I(\phi, \phi) \end{bmatrix}$$

o algoritmo escore de Fisher, nesse caso, terá de ser conduzido, simultaneamente, para os dois parâmetros, pois  $\mathbf{W}$  depende de  $\phi$ , lembrando que  $\omega_i = (\partial\mu_i/\partial\eta_i)^2/(\mu_i^2\phi^{-1} + \mu_i)$ .

- O algoritmo Escore de Fisher (AEF) é definido como:

Sejam  $\beta^{(0)}$  e  $\phi^{(0)}$  estimativas iniciais de  $\beta$  e  $\phi$  (chute inicial), respectivamente, então faça

$$\begin{aligned}
 & \begin{bmatrix} \beta^{(t+1)} \\ \phi^{(t+1)} \end{bmatrix} = \begin{bmatrix} \beta^{(t)} \\ \phi^{(t)} \end{bmatrix} \\
 & + \begin{bmatrix} \mathbf{X}' \mathbf{W}^{(t)} \mathbf{X} & \mathbf{0}_{(p \times 1)} \\ \mathbf{0}_{(1 \times p)} & I(\phi^{(t)}, \phi^{(t)}) \end{bmatrix}^{-1} \\
 & \times \begin{bmatrix} \mathbf{X}' \mathbf{W}^{(t)} (\mathbf{F}^{(t)})^{-1} (\mathbf{y} - \boldsymbol{\mu}^{(t)}) \\ \sum_{i=1}^n \left[ \psi(\phi^{(t)} + y_i) - \psi(\phi^{(t)}) - \frac{y_i + \phi^{(t)}}{\phi^{(t)} + \mu_i^{(t)}} + \ln(\phi^{(t)}) - \ln(\mu_i^{(t)} + \phi^{(t)}) + 1 \right] \end{bmatrix}
 \end{aligned}$$

$t = 0, 1, 2, \dots$ , até que algum critério de convergência seja satisfeito, por exemplo  $\|\boldsymbol{\theta}^{(t+1)} - \boldsymbol{\theta}^{(t)}\| < \epsilon$  para algum  $\epsilon > 0$  e  $\boldsymbol{\theta} = (\beta', \phi)'$

- O algoritmo Escore de Fisher (AEF) pode ser também escrito como:

$$\beta^{(t+1)} = \left( \mathbf{X}' \mathbf{W}^{(t)} \mathbf{X} \right)^{-1} \mathbf{X}' \mathbf{W}^{(t)} \mathbf{y}^{*(t)}$$

$$\phi^{(t+1)} = \phi^{(t)} + I_O(\phi^{(t)}, \phi^{(t)})^{-1} \left( S(\phi^{(t)}) \right)$$

$t = 0, 1, 2, \dots$ , até que algum critério de convergência seja satisfeito.

em que  $\mathbf{y}^* = \mathbf{X}\beta + \mathbf{F}^{-1}(\mathbf{y} - \boldsymbol{\mu})$ ,  $I_O(\phi, \phi) =$

$$\sum_{i=1}^n \left\{ \Psi'(\phi + y_i) + \frac{(y_i - 2\mu_i - \phi)}{(\phi + \mu_i)^2} \right\} + n\phi^{-1} \{1 - \phi\Psi'(\phi)\}$$

é a informação de Fisher observada, que corresponde ao valor simétrico da Hessiana ( $H(\phi, \phi)$ ) (podemos utilizar a informação de Fisher esperada  $I(\phi, \phi)$ ) embora esta possa trazer uma certa instabilidade numérica (?) e  $\Psi'(\cdot)$  é a função trigama.

- Quantidades  $\omega_i$  e  $f_i$  para algumas funções de ligação:

Ligação	$\omega_i$	$f_i$
$\ln(\mu_i) = \eta_i$	$\frac{\mu_i}{(\mu_i\phi^{-1} + 1)}$	$\mu_i$
$\mu_i = \eta_i$	$(\mu_i^2\phi^{-1} + \mu_i)^{-1}$	1
$\sqrt{\mu_i} = \eta_i$	$\frac{4}{(\mu_i\phi^{-1} + 1)}$	$2\sqrt{\mu_i}$

- Sob as condições de regularidade e para  $n$  suficientemente grande temos que  $\hat{\beta} \approx N_p(\beta, (\mathbf{X}'\mathbf{W}\mathbf{X})^{-1})$  e  $\hat{\phi} \approx N(\phi, I^{-1}(\phi, \phi))$  e  $\hat{\beta} \perp \hat{\phi}$  (assintoticamente).
- Defina  $\widehat{\mathbf{W}}$  e  $I(\hat{\phi}, \hat{\phi})$ , respectivamente  $\mathbf{W}$  e  $I(\phi, \phi)$ , em que as quantidades desconhecidas são substituídas pelos respectivos emv.

- Se  $\hat{\beta}_j$  é a j-ésima componente do vetor  $\hat{\beta}$  então  $\hat{\beta}_j \approx N(\beta_j, \psi_j)$  em que  $\psi_j$  é o j-ésimo elemento da diagonal principal de  $(\mathbf{X}'\mathbf{W}\mathbf{X})^{-1}$ .
- Temos ainda que como  $\hat{\phi}$  é um estimador consistente, então  $\frac{\hat{\beta}_j - \beta_j}{\sqrt{\hat{\psi}_j}} \approx N(0, 1)$  (sob as condições de regularidade e para  $n$  suficientemente grande), em que  $\hat{\psi}_j$  é o j-ésimo elemento da diagonal principal de  $(\mathbf{X}'\hat{\mathbf{W}}\mathbf{X})^{-1}$ .
- Analogamente, temos que  $\frac{\hat{\phi} - \phi}{\sqrt{\hat{\mathcal{V}}(\hat{\phi})}} \approx N(0, 1)$ , em que  $\hat{\mathcal{V}}(\hat{\phi}) = I^{-1}(\hat{\phi}, \hat{\phi})$ .

# Inferência

- Portanto (considerando-se  $P(X \leq z_{\frac{1+\gamma}{2}}) \approx \frac{1+\gamma}{2}$ ,  $X \sim N(0, 1)$ ), temos que

$$IC(\beta_j, \gamma) \approx \left[ \hat{\beta}_j - z_{\frac{1+\gamma}{2}} \sqrt{\hat{\psi}_j}; \hat{\beta}_j + z_{\frac{1+\gamma}{2}} \sqrt{\hat{\psi}_j} \right]$$

$$IC(\phi, \gamma) \approx \left[ \hat{\phi} - z_{\frac{1+\gamma}{2}} \sqrt{\hat{\nu}(\hat{\phi})}; \hat{\phi} + z_{\frac{1+\gamma}{2}} \sqrt{\hat{\nu}(\hat{\phi})} \right]$$

- Os intervalos de confiança numéricos são obtidos substituindo-se os estimadores pelas respectivas estimativas.

# Inferência

- Hipóteses do tipo  $H_0 : \mathbf{C}\beta = \mathbf{M}$  vs  $H_1 : \mathbf{C}\beta \neq \mathbf{M}$  podem ser testadas através da estatística (do tipo Wald)

$$Q_t = (\mathbf{C}\hat{\beta} - \mathbf{M})' (\mathbf{C}\hat{\mathcal{V}}(\hat{\beta})\mathbf{C}')^{-1} (\mathbf{C}\hat{\beta} - \mathbf{M}).$$

em que  $\hat{\mathcal{V}}(\hat{\beta}) = (\mathbf{X}'\widehat{\mathbf{W}}\mathbf{X})^{-1}$ .

# Inferência

- Note que  $\hat{\beta} \approx N_p(\beta, (\mathbf{X}'\mathbf{W}\mathbf{X})^{-1})$ , portanto, devido à esse resultado e algumas propriedades da normal multivariada, temos que se

$$Q_t^* = (\mathbf{C}\hat{\beta} - \mathbf{M})' (\mathbf{C}\mathcal{V}(\hat{\beta})\mathbf{C}')^{-1} (\mathbf{C}\hat{\beta} - \mathbf{M}),$$

então sob  $H_0$  e para  $n$  suficientemente grande,  $Q_t^* \approx \chi_c^2$ , em que  $c$  é o número de linhas de  $\mathbf{C}$ . Além disso,  $\widehat{\mathbf{W}} \xrightarrow[n \rightarrow \infty]{P} \mathbf{W}$  o que implica que  $\widehat{\mathcal{V}}(\hat{\beta}) \xrightarrow[n \rightarrow \infty]{P} \mathcal{V}(\hat{\beta})$ , pois cada componente de  $\widehat{\mathcal{V}}(\hat{\beta})$  é uma função contínua da respectiva componente de  $\widehat{\mathbf{W}}$  e também por Slutsky pois  $\hat{\phi} \xrightarrow[n \rightarrow \infty]{P} \phi$ .



# Inferência

- Portanto, sob  $H_0$  e para  $n$  suficientemente grande, pelos resultados anteriores  $(Q_t^*, \widehat{\mathbf{W}})$ ,  $Q_t \approx \chi_c^2$ .
- Assim, rejeita-se  $H_0$  se  $p$ -valor  $\leq \alpha$ , em que  $p$ -valor  $\approx P(X \geq q_t | H_0)$ , em que  $X \sim \chi_c^2$   
 $q_t = (\mathbf{C}\tilde{\boldsymbol{\beta}} - \mathbf{M})' (\mathbf{C}\tilde{\mathbf{V}}(\hat{\boldsymbol{\beta}})\mathbf{C}')^{-1} (\mathbf{C}\tilde{\boldsymbol{\beta}} - \mathbf{M})$ .
- Sob  $H_1$ , temos que  $Q_t \approx \chi_{(c,\delta)}^2$  (qui-quadrado não central com  $c$  graus de liberdade e parâmetro de assimetria  $\delta$ ), em que  $\delta = (\mathbf{C}\boldsymbol{\beta} - \mathbf{M})' (\mathbf{C}\mathbf{V}(\hat{\boldsymbol{\beta}})\mathbf{C}')^{-1} (\mathbf{C}\boldsymbol{\beta} - \mathbf{M})$ . Uma estimativa de  $\delta$  é dada por  $\tilde{\delta} = (\mathbf{C}\tilde{\boldsymbol{\beta}} - \mathbf{M})' (\mathbf{C}\tilde{\mathbf{V}}(\hat{\boldsymbol{\beta}})\mathbf{C}')^{-1} (\mathbf{C}\tilde{\boldsymbol{\beta}} - \mathbf{M})$ .

## Diagnóstico do modelo aqui

- A  $i$ -ésima componente do desvio do modelo para  $\phi$  fixo é dada por

$$D^*(y_i, \hat{\mu}_i) = 2 \left\{ \phi \ln \left[ \frac{\hat{\mu}_i + \phi}{y_i + \phi} \right] + y_i \ln \left[ \frac{y_i(\hat{\mu}_i + \phi)}{\hat{\mu}_i(y_i + \phi)} \right] \right\},$$

$\forall y_i \in \{1, 2, \dots\}$ .

em que  $\hat{\mu}_i$  é o emv de  $\mu_i$  sob o modelo de regressão.

- Se  $y_i = 0$  então

$$\begin{aligned} D^*(y_i, 0) &= 2 \{ \ln f(0; y_i, \phi) - \ln f(0, \hat{\mu}_i, \phi) \} \\ &= 2\phi \ln \{ \phi(y_i + \phi) \} - 2\phi \ln \{ \phi / (\hat{\mu}_i + \phi) \} \\ &= 2\phi \ln \{ (\hat{\mu}_i + \phi) / (y_i + \phi) \} \\ \rightarrow D^*(0, 0) &= 2\phi \ln \{ (\hat{\mu}_i + \phi) / \phi \} \end{aligned}$$

# Diagnóstico do modelo

- Assim o desvio é dado por

$$D^*(\mathbf{y}, \hat{\boldsymbol{\mu}}) = \sum_{i=1}^n \left\{ \left[ \phi \ln \left[ \frac{\hat{\mu}_i + \phi}{y_i + \phi} \right] + y_i \ln \left[ \frac{y_i(\hat{\mu}_i + \phi)}{\hat{\mu}_i(y_i + \phi)} \right] \right] \mathbb{1}_{\{1,2,\dots\}}(y_i) + \phi \ln \{(\hat{\mu}_i + \phi)/\phi\} \mathbb{1}_{\{0\}}(y_i) \right\}$$

- Na prática, substituímos  $\phi$  por um estimador consistente, ou seja:

$$D(\mathbf{y}, \hat{\boldsymbol{\mu}}) = \sum_{i=1}^n \left\{ \left[ \hat{\phi} \ln \left[ \frac{\hat{\mu}_i + \hat{\phi}}{y_i + \hat{\phi}} \right] + y_i \ln \left[ \frac{y_i(\hat{\mu}_i + \hat{\phi})}{\hat{\mu}_i(y_i + \hat{\phi})} \right] \right] \mathbb{1}_{\{1,2,\dots\}}(y_i) + \hat{\phi} \ln \{(\hat{\mu}_i + \hat{\phi})/\hat{\phi}\} \mathbb{1}_{\{0\}}(y_i) \right\}$$

- Sob a hipótese de que o modelo adotado está correto  $D(\mathbf{y}, \hat{\boldsymbol{\mu}})$  segue, aproximadamente, para  $\hat{\phi}$  e  $\hat{\mu}_i$  grandes, uma distribuição qui-quadrado com  $(n - p)$  graus de liberdade.
- O resíduo componente do desvio é dado por:

$$T_{D_i} = \frac{D(y_i; \hat{\mu}_i)}{\sqrt{1 - \hat{h}_{ii}}}$$

em que

$$\left\{ \begin{array}{l} \sqrt{2} \operatorname{sign}(y_i - \hat{\mu}_i) \left\{ \hat{\phi} \ln \left[ \frac{\hat{\mu}_i + \hat{\phi}}{y_i + \hat{\phi}} \right] + y_i \ln \left[ \frac{y_i(\hat{\mu}_i + \hat{\phi})}{\hat{\mu}_i(y_i + \hat{\phi})} \right] \right\}^{1/2}, \\ \text{se } y_i \in \{1, 2, \dots, \} \\ \sqrt{2} \operatorname{sign}(y_i - \hat{\mu}_i) \left\{ \hat{\phi} \ln(\hat{\mu}_i + \hat{\phi}) / \hat{\phi} \right\}^{1/2}, \text{ se } y_i = 0 \end{array} \right.$$

- e

$\hat{h}_{ii}$  é o  $i$ -ésimo elemento da diagonal principal da matriz,

$$\hat{\mathbf{H}} = \hat{\mathbf{W}}^{1/2} \mathbf{X} (\mathbf{X}' \hat{\mathbf{W}} \mathbf{X})^{-1} \mathbf{X}' \hat{\mathbf{W}}^{1/2}, \text{ ou seja,}$$

$$\hat{h}_{ii} = \frac{\hat{\phi} \hat{\mu}_i}{\hat{\phi} + \hat{\mu}_i} \mathbf{X}'_i (\mathbf{X}' \hat{\mathbf{W}} \mathbf{X})^{-1} \mathbf{X}_i.$$

- Estudos de Monte Carlo desenvolvidos por Svetliza (2002) (ver também Svetliza e Paula, 2003) indicam boa concordância entre o resíduo componente do desvio e a distribuição normal padrão, sob o bom ajuste do modelo.

# Voltando ao Exemplo 4: comparação do número de acidentes




## Modelo

$$Y_{ij} \stackrel{ind.}{\sim} \text{BN}(\mu_i, \phi), i = 1 \text{ (ano de 1961)}, 2 \text{ (ano de 1962)}, j = 1, \dots, 43$$





$$\ln \mu_i = \mu + \alpha_i, \alpha_1 = 0$$

- $\mathcal{E}(Y_{ij}) = \mu_i = e^{\mu + \alpha_i}$ .
- $e^{\alpha_2}$ : o incremento multiplicativo (positivo ou negativo) da média do ano de 1962 em relação à média do ano de 1961 ( $\mu_2 = \mu_1 e^{\alpha_2}$ ).

# Gráficos de diagnóstico: Poisson




# Gráficos de diagnóstico: binomial negativo






# Gráficos de envelopes: Poisson e binomial negativo



Modelo de Poisson



Modelo binomial negativo



# Distribuições previstas e observadas (boxplot)



# Estatísticas de ajuste e comparação de modelos

Modelo	AIC	BIC	Desvio	p-valor desvio
Poisson	656,94	661,85	235,17	<0,0001
Binomial negativo	595,37	602,73	86,66	0,3996

# Estimativas dos parâmetros dos modelos

Modelo	Par.	Est.	EP	IC(95%)	Estat. $Z_t$	p-valor
Poisson	$\beta_0$	3,26	0,03	[3,20 ; 3,32]	109,10	< 0,0001
	$\beta_1$	-0,37	0,05	[-0,46 ; -0,28]	-7,86	< 0,0001
BN	$\beta_0$	3,26	0,05	[3,16 ; 3,36]	62,31	< 0,0001
	$\beta_1$	-0,37	0,08	[-0,52 ; -0,22]	-4,79	< 0,0001
	$\phi$	12,61	3,04	[6,65 ; 18,57]	-	-