

Resumo sobre modelos lineares generalizados

Prof. Caio Azevedo

Família exponencial bi-paramétrica

- Dizemos que uma v.a. Y (discreta ou contínua) pertence à família exponencial biparamétrica se sua fdp é dada por:

$$f(y; \theta) = \exp \{ \phi [y\theta - b(\theta)] + c(y, \phi) \} \mathbb{1}_A(y)$$

em que $\theta \in \Theta \subset \mathfrak{R}$ (espaço paramétrico), $b(\theta), c(y, \phi) : \mathfrak{R} \rightarrow \mathfrak{R}$, A é um conjunto que não depende de θ e ϕ e, por sua vez, $\phi(\phi > 0)$ é o parâmetro de precisão.

Família exponencial bi-paramétrica

- Consideraremos que $Y \sim FE(\theta, \phi)$ e que temos $Y_i \stackrel{ind.}{\sim} FE(\theta_i, \phi), i = 1, 2, \dots, n$, ou seja

$$f(y_i; \theta) = \exp \{ \phi [y\theta_i - b(\theta_i)] + c(y_i, \phi) \} \mathbb{1}_A(y_i)$$

Modelo linear generalizado

- $Y_i \sim \text{FE}(\theta_i, \phi), i = 1, 2, \dots, n, \theta_i = h(\mu_i)$.
- $g(\mu_i) = \eta_i, \eta_i = \sum_{j=1}^p x_{ji}\beta_j, \mathcal{E}(Y_i) = \mu_i = b'(\theta_i), x_{ji}$: covariável j associada ao indivíduo i (fixa e conhecida) e $\beta = (\beta_1, \dots, \beta_p)'$, ϕ : parâmetros desconhecidos.
- $\mathcal{V}(Y) = \phi^{-1}V(\mu_i)$, em que $V(\mu_i) = \frac{d\mu_i}{d\theta_i}$.
- $g(\cdot)$ é uma função de ligação (invertível e duplamente diferenciável). Quando $\theta = g(\cdot)$ temos a função de ligação canônica.

Principais distribuições pertencentes à FE

Distribuição	$b(\theta)$	θ	ϕ	$V(\mu)$
Normal	$\theta^2/2$	μ	σ^{-2}	1
Poisson	e^θ	$\ln \mu$	1	μ
Binomial	$\ln(1 + e^\theta)$	$\ln(\mu/(1 - \mu))$	n	$\mu(1 - \mu)$
Gama	$-\ln(-\theta)$	$-1/\mu$	$1/(CV^2)$	μ^2
N.Inversa	$-\sqrt{-2\theta}$	$-1/2\mu^2$	ϕ	μ^3

Desvio (ou função desvio)

- Sem perda de generalidade, seja $l(\boldsymbol{\mu}, \mathbf{y}) \equiv l(\boldsymbol{\beta}, \phi)$ a logverossimilhança associada ao modelo em estudo e $l(\boldsymbol{\mu}^{(0)}, \mathbf{y})$ a logverossimilhança do modelo saturado ($n=p$), ou seja, em que cada média é representada por ela mesma.

- $l(\boldsymbol{\mu}, \mathbf{y}) = \phi \left[\sum_{i=1}^n y_i \theta_i - \sum_{i=1}^n b(\theta_i) \right] + \sum_{i=1}^n c(y_i, \phi)$

- $l(\boldsymbol{\mu}^{(0)}, \mathbf{y}) = \phi \left[\sum_{i=1}^n y_i \theta_i^{(0)} - \sum_{i=1}^n b(\theta_i^{(0)}) \right] + \sum_{i=1}^n c(y_i, \phi)$
em que $\theta_i^{(0)} = h(\mu_i^{(0)})$.

- Assim, $D^*(\mathbf{y}, \boldsymbol{\mu}) = 2(l(\boldsymbol{\mu}^{(0)}, \mathbf{y}) - l(\boldsymbol{\mu}, \mathbf{y})) =$
 $\phi \sum_{i=1}^n \left[y_i \left(\theta_i^{(0)} - \theta_i \right) + b(\theta_i) - b(\theta_i^{(0)}) \right] = \phi D(\mathbf{y}, \boldsymbol{\mu})$

Desvio (ou função desvio)

- Sejam $\hat{\boldsymbol{\mu}}^{(0)} = \mathbf{Y}$ e $\hat{\boldsymbol{\mu}} = g^{-1}(\hat{\boldsymbol{\eta}}) = g^{-1}(\mathbf{X}\hat{\boldsymbol{\beta}})$ os respectivos estimadores de MV e defina $\hat{\theta}_i^{(0)} = h(\hat{\mu}_i^{(0)})$ e $\hat{\theta}_i = h(\hat{\mu}_i)$.
- Assim, o desvio não escalonado é dado por
$$D(\mathbf{y}, \hat{\boldsymbol{\mu}}) = \sum_{i=1}^n \left[y_i \left(\hat{\theta}_i^{(0)} - \hat{\theta}_i \right) + b(\hat{\theta}_i) - b(\hat{\theta}_i^{(0)}) \right].$$
- O desvio escalonado é dado por $D^*(\mathbf{y}, \hat{\boldsymbol{\mu}}) = \phi D(\mathbf{y}, \hat{\boldsymbol{\mu}})$. Na prática, substituímos ϕ por algum estimador consistente.

Desvio: exemplos

- Já vimos como ficam os desvios no caso dos modelos Poisson e binomial (lembrando que $\phi = 1$) para esses modelos.
- Normal: $D(\mathbf{y}, \hat{\boldsymbol{\mu}}) = \sum_{i=1}^n (y_i - \hat{\mu}_i)^2$ e
 $D^*(\mathbf{y}, \hat{\boldsymbol{\mu}}) = \frac{1}{\sigma^2} \sum_{i=1}^n (y_i - \hat{\mu}_i)^2$.
- Gama: $D(\mathbf{y}, \hat{\boldsymbol{\mu}}) = 2 \sum_{i=1}^n \{-\ln(y_i/\hat{\mu}_i) + (y_i - \hat{\mu}_i)/\hat{\mu}_i\}$ e
 $D^*(\mathbf{y}, \hat{\boldsymbol{\mu}}) = \phi D(\mathbf{y}, \hat{\boldsymbol{\mu}})$.

Desvio: comportamento assintótico

- Já vimos o comportamento assintótico para os modelos Poisson e binomial.
- Para os outros modelos, $D^*(\mathbf{y}, \hat{\boldsymbol{\mu}})$ depende de ϕ . Então, nesses casos, utilizamos uma estimativa consistente de ϕ . Além disso, temos que

$$D^*(\mathbf{y}, \hat{\boldsymbol{\mu}}) \xrightarrow[\phi \rightarrow \infty]{D} \chi_{n-p}^2$$

- Assim, podemos comparar o valor do desvio com os quantis de uma distribuição qui-quadrado, para verificar a qualidade de ajuste do modelo, quando a variabilidade dos dados for pequena.

Análise do desvio

- Podemos definir um procedimento para testar as hipóteses

$$H_0 : \beta_1 = \mathbf{0} \text{ vs } H_1 : \beta_1 \neq \mathbf{0}.$$

- A estatística $Q_{AD} = \frac{\left(D(\mathbf{y}; \hat{\boldsymbol{\mu}}^{(0)}) - D(\mathbf{y}; \hat{\boldsymbol{\mu}}) \right) / q}{D(\mathbf{y}; \hat{\boldsymbol{\mu}}) / (n - p)}$ sob H_0 e para n suficientemente grande, é tal que $Q_{AD} \approx F_{(q, n-p)}$

- Note que só podemos utilizar esta abordagem para modelos não saturados ($n > p$).

- Assim, rejeita-se H_0 se $p - \text{valor} \leq \alpha$, em que

$$p - \text{valor} \approx P(X \geq q_{AD} | H_0), \text{ e } X \sim F_{(q, n-p)}$$

$$q_{AD} = \frac{\left(D(\mathbf{y}; \tilde{\boldsymbol{\mu}}^{(0)}) - D(\mathbf{y}; \tilde{\boldsymbol{\mu}}) \right) / q}{D(\mathbf{y}; \tilde{\boldsymbol{\mu}}) / (n - p)}.$$

Outras funções de ligação

- Seja μ a proporção de sucessos de uma binomial.
- A ligação probito é dada por

$$\Phi^{-1}(\mu) = \eta$$

ou, de modo equivalente, $\mu = \Phi(\eta)$, em que $\Phi(\cdot)$ é a fda de uma distribuição normal padrão.

Outras funções de ligação

- Novamente, seja μ a proporção de sucessos de uma binomial.
- A fda de uma distribuição do valor extremo padrão (ou Gumbell padrão, a qual corresponde ao logaritmo natural de uma distribuição exponencial com seu parâmetro igual a 1) é dada por:

$$F(x) = 1 - \exp\{-\exp(x)\}$$

- Assim, o modelo binomial com ligação log-log é dado por

$$\mu = 1 - \exp\{-\exp(\eta)\}$$


ou de modo equivalente,

$$\ln(-\ln(1 - \mu)) = \eta.$$


Resumo: principais funções de ligação

Distribuição	$g(\theta)$
Normal	$\mu, (\text{canônica}), 1/\mu \text{ e } \ln \mu \text{ (se } \mu > 0)$
Poisson	$\ln \mu (\text{canônica}), \sqrt{\mu}$
Binomial	$\ln(\mu/(1 - \mu)) \text{ (canônica)}, \Phi^{-1}(\mu), \ln(-\ln(1 - \mu))$
Gama	$1/\mu (\text{canônica}), \ln \mu$
N.Inversa	$1/(2\mu^2) \text{ (canônica)}, \ln \mu, 1/\mu$

Funções de ligação para médias no intervalo (0,1)



Funções de ligação da família Box-Cox



Estimação

- Lembremos que $\theta_i = h(\mu_i)$, $\mu_i = g^{-1}(\eta_i)$ em que $\eta_i = \sum_{j=1}^p x_{ji}\beta_j$.
- Logo $\theta_i = h(g^{-1}(\eta_i))$. Se $g(\cdot)$ form uma função de ligação canônica, então $\theta_i = \eta_i$.

- Verossimilhança

$$L(\boldsymbol{\beta}, \phi) = \exp \left\{ \phi \left[\sum_{i=1}^n y_i \theta_i - \sum_{i=1}^n b(\theta_i) \right] + \sum_{i=1}^n c(y_i, \phi) \right\}$$

- Log-verossimilhança

$$l(\boldsymbol{\beta}, \phi) = \phi \left[\sum_{i=1}^n y_i \theta_i - \sum_{i=1}^n b(\theta_i) \right] + \sum_{i=1}^n c(y_i, \phi)$$

Estimação

- Vetor Escore para β (usando a regra da cadeia)

$$\begin{aligned} S(\beta) &= \sum_{i=1}^n \phi \left\{ y_i \frac{d\theta_i}{d\mu_i} \frac{d\mu_i}{d\eta_i} \frac{d\eta_i}{d\beta} - \frac{db(\theta_i)}{d\theta_i} \frac{d\theta_i}{d\mu_i} \frac{d\mu_i}{d\eta_i} \frac{d\eta_i}{d\beta} \right\} \\ &= \phi \sum_{i=1}^n \left\{ \sqrt{\frac{\omega_i}{V_i}} (y_i - \mu_i) \mathbf{X}_i \right\} = \phi \mathbf{X}' \mathbf{W}^{1/2} \mathbf{V}^{-1/2} (\mathbf{y} - \boldsymbol{\mu}) \end{aligned}$$

em que $\mathbf{W} = \text{diag}(\omega_1, \dots, \omega_n)$, $\omega_i = (d\mu_i/d\eta_i)^2/V_i$, $V_i = V(\mu_i)$ e $\mathbf{V} = \text{diag}(V_1, \dots, V_n)'$. As outras quantidades são como definidas para os modelos de regressão de Poisson e logístico.

Estimação

- Vetor Escore para ϕ

$$S(\phi) = \sum_{i=1}^n \{y_i \theta_i - b(\theta_i)\} + \sum_{i=1}^n c'(y_i, \phi)$$

em que $c'(y_i, \phi) = \frac{dc(y_i, \phi)}{d\phi}$

Estimação

- Informação de Fisher (usando a regra da cadeia)

$$I(\beta, \beta) = -\mathcal{E} \left\{ \phi \left\{ \sum_{i=1}^n \frac{1}{V_i^{1/2}} (Y_i - \mu_i) \mathbf{X}_i \frac{d\omega_i^{1/2}}{d\beta'} + \omega_i^{1/2} (Y_i - \mu_i) \mathbf{X}_i \frac{dV_i^{-1/2}}{d\beta'} - \sqrt{\frac{\omega_i}{V_i}} \mathbf{X}_i \frac{d\mu_i}{d\beta'} \right\} \right\} = \phi \mathbf{X}' \mathbf{W} \mathbf{X}$$

$$I(\beta, \phi) = -\mathcal{E} \left(\left\{ \sqrt{\frac{\omega_i}{V_i}} (Y_i - \mu_i) x_{ji} \right\} \right) = \mathbf{0}$$

Estimação

- Informação de Fisher para ϕ

$$I(\phi, \phi) = -\mathcal{E} \left(\sum_{i=1}^n c''(Y_i, \phi) \right)$$

em que $c''(y_i, \phi) = \frac{d^2 c(y_i, \phi)}{d\phi^2}$

Inferência para o modelo

- O sistema de equações $\mathbf{S}(\hat{\boldsymbol{\beta}}) = \mathbf{0}$, $S(\hat{\phi}) = 0$ não tem solução explícita e algum método de otimização numérica, como o algoritmo score de Fisher, deve ser utilizado para obter-se as estimativas de MV.

- Contudo, como os parâmetros são ortogonais

$$l(\boldsymbol{\beta}, \phi) = -\mathcal{E} \left(\left\{ \sqrt{\frac{\omega_j}{V_i}} (Y_i - \mu_i) x_{ji} \right\} \right) = \mathbf{0} \text{ e o produto matricial}$$

$\mathbf{I}^{-1}(\boldsymbol{\beta})\mathbf{S}(\boldsymbol{\beta})$ não depende de ϕ a estimação é feita em duas etapas.

Estimação de β : Algoritmo escore de Fisher

- Seja $\beta^{(0)}$ uma estimativa inicial de β (chute inicial), então faça

$$\beta^{(t+1)} = \beta^{(t)} + \mathbf{I}^{-1}(\beta^{(t)})\mathbf{S}(\beta^{(t)}), t = 1, 2, \dots \quad (1)$$

até que algum critério de convergência seja satisfeito, como

$$|l(\beta^{(t+1)}) - l(\beta^{(t)})| < \epsilon, \epsilon > 0,$$

em que $l(\cdot)$ é a logverossimilhança.

Estimação de ϕ

- Com as estimativas de β , digamos $\tilde{\beta}$, obtidas no passo anterior, obtenha as estimativas de ϕ através de

$\hat{\phi} = \frac{n-p}{\sum_{i=1}^n \left(\frac{(Y_i - \hat{\mu}_i)^2}{V(\hat{\mu}_i)} \right)}$ que é o estimador do método dos momentos (e consistente) de ϕ .

- O R fornece a estimativa associada ao estimador $\hat{\phi} = \frac{n-p}{D(\mathbf{y}, \hat{\boldsymbol{\mu}})}$ que não é consistente para ϕ .
- Para os modelos Poisson e Binomial, $\phi = 1$.

Análise de diagnóstico

- O procedimento para verificação do ajuste do modelo segue o mesmo padrão anteriormente apresentado para os modelos Poisson e binomial.
- As fórmulas para o resíduo componente do desvio e da variável z já foram apresentadas para os dois modelos acima.
- Para os outros modelos, veja o livro do Prof. Gilberto.