

# Estimación en presencia de parámetros incidentales via máxima $L_q$ -verosimilitud

Patricia Giménez<sup>1</sup>, Lucas Guarracino<sup>1</sup>, Manuel Galea<sup>2</sup>

<sup>1</sup> Centro Marplatense de Investigaciones Matemáticas - UNMdP

<sup>2</sup> Depto de Estadística, Facultad de Matemáticas, Pontificia Universidad Católica de Chile

**XV Congreso Monteiro**  
Bahía Blanca - Junio de 2019

# Contenido de la presentación

1. Estimación basada en la minimización de  $q$ -divergencias.  
 $q$ -entropía y estimador de máxima  $L_q$ -verosimilitud (EML $q$ V)  
(caso i.i.d.)
2. EML $q$ V en presencia de parámetros incidentales (caso i.n.i.d.)
3. Principales resultados.
4. Aplicación: modelo de regresión lineal simple con errores en las variables funcional.

# Estimación basada en la minimización de $q$ -divergencias

$\mathbf{Z}_1, \dots, \mathbf{Z}_n$  muestra aleatoria de una población cuya verdadera densidad es  $g$ .

Como modelo asumimos  $\mathcal{F} = \{f_{\boldsymbol{\theta}} = f(\cdot; \boldsymbol{\theta}) : \boldsymbol{\theta} \in \Theta \subset \mathbb{R}^p\}$

$q$ -divergencia o divergencia potencia (Cressie and Read, 1984)

$$\mathcal{D}_q(g, f_{\boldsymbol{\theta}}) = -\frac{1}{q} \mathbb{E}_g \left[ L_q \left\{ \frac{f(\mathbf{Z}; \boldsymbol{\theta})}{g(\mathbf{Z})} \right\} \right] = -\frac{1}{q} \int L_q \left\{ \frac{f(\mathbf{z}; \boldsymbol{\theta})}{g(\mathbf{z})} \right\} g(\mathbf{z}) d\mathbf{z},$$

$$L_q(u) = \begin{cases} \frac{u^{1-q} - 1}{1-q}, & q \neq 1 \\ \log(u), & q = 1 \end{cases} \quad q\text{-logaritmo}$$

$q = 1$ ,  $\mathcal{D}_1(g, f_{\boldsymbol{\theta}})$ : divergencia de Kullback-Leibler

# Estimación basada en la minimización de $q$ -divergencias

$\mathbf{Z}_1, \dots, \mathbf{Z}_n$  muestra aleatoria de una población cuya verdadera densidad es  $g$ .

Como modelo asumimos  $\mathcal{F} = \{f_{\boldsymbol{\theta}} = f(\cdot; \boldsymbol{\theta}) : \boldsymbol{\theta} \in \Theta \subset \mathbb{R}^p\}$

$q$ -divergencia o divergencia potencia (Cressie and Read, 1984)

$$\mathcal{D}_q(g, f_{\boldsymbol{\theta}}) = -\frac{1}{q} \mathbb{E}_g \left[ L_q \left\{ \frac{f(\mathbf{Z}; \boldsymbol{\theta})}{g(\mathbf{Z})} \right\} \right] = -\frac{1}{q} \int L_q \left\{ \frac{f(\mathbf{z}; \boldsymbol{\theta})}{g(\mathbf{z})} \right\} g(\mathbf{z}) d\mathbf{z},$$

$$L_q(u) = \begin{cases} \frac{u^{1-q} - 1}{1-q}, & q \neq 1 \\ \log(u), & q = 1 \end{cases} \quad q\text{-logaritmo}$$

$q = 1$ ,  $\mathcal{D}_1(g, f_{\boldsymbol{\theta}})$ : divergencia de Kullback-Leibler

$q$ -entropía o entropía no extensiva (Havdra y Charvat, 1967)

$$\mathcal{H}_q(g, f_{\boldsymbol{\theta}}) = -\mathbb{E}_g[L_q\{f(\mathbf{Z}; \boldsymbol{\theta})\}] = -\int L_q\{f(\mathbf{z}; \boldsymbol{\theta})\}g(\mathbf{z}) d\mathbf{z}$$

$q = 1$ ,  $\mathcal{H}_1(g, f_{\boldsymbol{\theta}})$ : entropía de Shannon

# Relación entre $q$ -divergencia y $q$ -entropía

(Ferrari y La Vecchia, 2012)

$$\theta^0 = \arg \min_{\theta \in \Theta} \mathcal{D}_q(g, f_\theta)$$

$$\text{Si } q = 1, \quad \theta^0 = \arg \min_{\theta \in \Theta} \mathcal{H}_1(g, f_\theta) = \arg \min_{\theta \in \Theta} \mathcal{D}_1(g, f_\theta)$$

$$\text{Si } q \neq 1, \quad \theta^* = \arg \min_{\theta \in \Theta} \mathcal{H}_q(g, f_\theta) = \arg \min_{\theta \in \Theta} \mathcal{D}_q(g^{(1/q)}, f_\theta)$$

siendo  $g^{(\alpha)}(z) = \frac{g^\alpha(z)}{\int g^\alpha(z) dz}$ ,  $\alpha > 0$ , la transformación potencia.

$$\theta^* \text{ parámetro sustituto, } \theta^* \neq \theta^0$$

Para  $0 < q < 1$ ,  $g^{(1/q)}$  acentúa partes de  $g$  con valores grandes de densidad y reduce la importancia de las colas.

Minimizando una versión empírica de  $\mathcal{H}_q$  se obtiene un procedimiento de estimación robusto totalmente paramétrico.

# Estimador de máxima $L_q$ -verosimilitud (EML $_q$ V)

Estimador de máxima  $L_q$ -verosimilitud (EML $_q$ V) (Ferrari y Yang, 2010)  
basado en una muestra  $\mathbf{Z}_1, \dots, \mathbf{Z}_n$ ,

$$\hat{\boldsymbol{\theta}}^* = \arg \max_{\boldsymbol{\theta} \in \Theta} \sum_{j=1}^n L_q\{f(\mathbf{Z}_j; \boldsymbol{\theta})\}$$

# Estimador de máxima $L_q$ -verosimilitud (EML $_q$ V)

Estimador de máxima  $L_q$ -verosimilitud (EML $_q$ V) (Ferrari y Yang, 2010) basado en una muestra  $\mathbf{Z}_1, \dots, \mathbf{Z}_n$ ,

$$\hat{\boldsymbol{\theta}}^* = \arg \max_{\boldsymbol{\theta} \in \Theta} \sum_{j=1}^n L_q\{f(\mathbf{Z}_j; \boldsymbol{\theta})\}$$

$\hat{\boldsymbol{\theta}}^*$  es estimador consistente de  $\boldsymbol{\theta}^*$ .

$\hat{\boldsymbol{\theta}} = \tau_q(\hat{\boldsymbol{\theta}}^*)$  es estimador consistente de  $\boldsymbol{\theta}^0$ , donde  $\tau_\alpha: \Theta \rightarrow \Theta$  es la transformación definida por

$$f(\mathbf{z}; \tau_\alpha(\boldsymbol{\theta})) = f^{(\alpha)}(\mathbf{z}; \boldsymbol{\theta}), \quad 0 < \alpha < \infty,$$

asumiendo que  $\mathcal{F}$  es cerrada bajo la transformación potencia.

# Estimador de máxima $L_q$ -verosimilitud (EML $_q$ V)

Estimador de máxima  $L_q$ -verosimilitud (EML $_q$ V) (Ferrari y Yang, 2010) basado en una muestra  $\mathbf{Z}_1, \dots, \mathbf{Z}_n$ ,

$$\hat{\boldsymbol{\theta}}^* = \arg \max_{\boldsymbol{\theta} \in \Theta} \sum_{j=1}^n L_q \{f(\mathbf{Z}_j; \boldsymbol{\theta})\}$$

$\hat{\boldsymbol{\theta}}^*$  es estimador consistente de  $\boldsymbol{\theta}^*$ .

$\hat{\boldsymbol{\theta}} = \tau_q(\hat{\boldsymbol{\theta}}^*)$  es estimador consistente de  $\boldsymbol{\theta}^0$ , donde  $\tau_\alpha: \Theta \rightarrow \Theta$  es la transformación definida por

$$f(\mathbf{z}; \tau_\alpha(\boldsymbol{\theta})) = f^{(\alpha)}(\mathbf{z}; \boldsymbol{\theta}), \quad 0 < \alpha < \infty,$$

asumiendo que  $\mathcal{F}$  es cerrada bajo la transformación potencia.

Estimador de máxima verosimilitud (EMV) ( $q = 1$ )

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta} \in \Theta} \sum_{j=1}^n \log f(\mathbf{Z}_j; \boldsymbol{\theta})$$

$\hat{\boldsymbol{\theta}}$  es estimador consistente de  $\boldsymbol{\theta}^0$ .

# EMLqV en presencia de parámetros incidentales

$Z_1, \dots, Z_n$  v.a. independientes,  $Z_j$  con verdadera densidad  $g_j$ .

Como modelo asumimos

$$\mathcal{F}_j = \{f_{\theta, \xi_j} = f_j(\cdot; \theta, \xi_j): \theta \in \Theta \subset \mathbb{R}^p, \xi_j \in \Xi \subset \mathbb{R}^r\}, \quad j = 1, \dots, n$$

$\theta$  parámetro estructural de interés,  $\xi_1, \dots, \xi_n$  parámetros incidentales

# EMLqV en presencia de parámetros incidentales

$Z_1, \dots, Z_n$  v.a. independientes,  $Z_j$  con verdadera densidad  $g_j$ .

Como modelo asumimos

$$\mathcal{F}_j = \{f_{\theta, \xi_j} = f_j(\cdot; \theta, \xi_j): \theta \in \Theta \subset \mathbb{R}^p, \xi_j \in \Xi \subset \mathbb{R}^r\}, \quad j = 1, \dots, n$$

$\theta$  **parámetro estructural** de interés,  $\xi_1, \dots, \xi_n$  **parámetros incidentales**

Asumimos que existe  $\tau_\alpha = (\tau_{\alpha,1}, \tau_{\alpha,2}): \Theta \times \Xi \rightarrow \Theta \times \Xi$

$$f_j(z; \tau_{\alpha,1}(\theta), \tau_{\alpha,2}(\xi_j)) = f_j^{(\alpha)}(z; \theta, \xi_j) \quad j = 1, 2, \dots$$

y  $\mathcal{F}_j$  es cerrada bajo la transformación potencia.

# EML $q$ V en presencia de parámetros incidentales

$Z_1, \dots, Z_n$  v.a. independientes,  $Z_j$  con verdadera densidad  $g_j$ .

Como modelo asumimos

$$\mathcal{F}_j = \{f_{\theta, \xi_j} = f_j(\cdot; \theta, \xi_j) : \theta \in \Theta \subset \mathbb{R}^p, \xi_j \in \Xi \subset \mathbb{R}^r\}, \quad j = 1, \dots, n$$

$\theta$  **parámetro estructural** de interés,  $\xi_1, \dots, \xi_n$  **parámetros incidentales**

Asumimos que existe  $\tau_\alpha = (\tau_{\alpha,1}, \tau_{\alpha,2}) : \Theta \times \Xi \rightarrow \Theta \times \Xi$

$$f_j(z; \tau_{\alpha,1}(\theta), \tau_{\alpha,2}(\xi_j)) = f_j^{(\alpha)}(z; \theta, \xi_j) \quad j = 1, 2, \dots$$

y  $\mathcal{F}_j$  es cerrada bajo la transformación potencia.

$$(\theta^*, \xi_1^*, \dots, \xi_n^*) = \arg \min_{\theta, \xi_1, \dots, \xi_n} \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{j=1}^n \mathcal{H}_q(g_j, f_{\theta, \xi_j})$$

$\theta^*$  **parámetro estructural sustituto**.

# EML<sub>q</sub>V en presencia de parámetros incidentales

$$\hat{\theta}^*, \hat{\xi}_1^*, \dots, \hat{\xi}_n^* \text{ EML}_q\text{V}$$

$$(\hat{\theta}^*, \hat{\xi}_1^*, \dots, \hat{\xi}_n^*) = \arg \max_{\theta, \xi_1, \dots, \xi_n} \sum_{j=1}^n L_q\{f_j(\mathbf{Z}_j; \theta, \xi_j)\}$$

$$\hat{\xi}_j(\mathbf{Z}_j; \theta) = \arg \max_{\xi_j} L_q\{f_j(\mathbf{Z}_j; \theta, \xi_j)\}, \quad j = 1, 2, \dots$$

$$\hat{\theta}^* = \arg \max_{\theta \in \Theta} H_n(\theta),$$

donde

$$H_n(\theta) = \sum_{j=1}^n L_q\{f_j(\mathbf{Z}_j; \theta, \hat{\xi}_j(\mathbf{Z}_j; \theta))\} = \sum_{j=1}^n h_j(\mathbf{Z}_j; \theta)$$

# EML $_q$ V en presencia de parámetros incidentales

$$\hat{\boldsymbol{\theta}}^*, \hat{\boldsymbol{\xi}}_1^*, \dots, \hat{\boldsymbol{\xi}}_n^* \text{ EML}_q\text{V}$$

$$(\hat{\boldsymbol{\theta}}^*, \hat{\boldsymbol{\xi}}_1^*, \dots, \hat{\boldsymbol{\xi}}_n^*) = \arg \max_{\boldsymbol{\theta}, \boldsymbol{\xi}_1, \dots, \boldsymbol{\xi}_n} \sum_{j=1}^n L_q\{f_j(\mathbf{Z}_j; \boldsymbol{\theta}, \boldsymbol{\xi}_j)\}$$

$$\hat{\boldsymbol{\xi}}_j(\mathbf{Z}_j; \boldsymbol{\theta}) = \arg \max_{\boldsymbol{\xi}_j} L_q\{f_j(\mathbf{Z}_j; \boldsymbol{\theta}, \boldsymbol{\xi}_j)\}, \quad j = 1, 2, \dots$$

$$\hat{\boldsymbol{\theta}}^* = \arg \max_{\boldsymbol{\theta} \in \Theta} H_n(\boldsymbol{\theta}),$$

donde

$$H_n(\boldsymbol{\theta}) = \sum_{j=1}^n L_q\{f_j(\mathbf{Z}_j; \boldsymbol{\theta}, \hat{\boldsymbol{\xi}}_j(\mathbf{Z}_j; \boldsymbol{\theta}))\} = \sum_{j=1}^n h_j(\mathbf{Z}_j; \boldsymbol{\theta})$$

$\hat{\boldsymbol{\theta}}^*$  es estimador consistente de  $\boldsymbol{\theta}^\dagger \neq \boldsymbol{\theta}^*$

$$\boldsymbol{\theta}^\dagger = \arg \max_{\boldsymbol{\theta} \in \Theta} \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{j=1}^n E_{g_j}[h_j(\mathbf{Z}_j; \boldsymbol{\theta})]$$

# Resultados

- ▶ Bajo condiciones de regularidad apropiadas el  $\text{EML}_{qV} \hat{\theta}^*$  converge en probabilidad a  $\theta^\dagger$  y es asintóticamente normal.

# Resultados

- ▶ Bajo condiciones de regularidad apropiadas el  $\text{EML}_{qV} \hat{\theta}^*$  converge en probabilidad a  $\theta^\dagger$  y es asintóticamente normal.
- ▶ Si  $\theta^\dagger = \rho(\theta^*)$ , entonces  $\hat{\theta} = \eta_q(\hat{\theta}^*)$  es estimador consistente de  $\theta^0$ , donde  $\eta_q = \tau_{q,1} \circ \rho^{-1}$

# Resultados

- ▶ Bajo condiciones de regularidad apropiadas el  $\text{EML}_q\mathbf{V} \hat{\boldsymbol{\theta}}^*$  converge en probabilidad a  $\boldsymbol{\theta}^\dagger$  y es asintóticamente normal.
- ▶ Si  $\boldsymbol{\theta}^\dagger = \rho(\boldsymbol{\theta}^*)$ , entonces  $\hat{\boldsymbol{\theta}} = \eta_q(\hat{\boldsymbol{\theta}}^*)$  es estimador consistente de  $\boldsymbol{\theta}^0$ , donde  $\eta_q = \tau_{q,1} \circ \rho^{-1}$
- ▶ Para  $0 < q < 1$  el estimador tiene buenas propiedades de robustez.  $q$  controla el balance entre eficiencia y robustez.

# Resultados

- ▶ Bajo condiciones de regularidad apropiadas el  $\text{EML}_q\mathbf{V} \hat{\boldsymbol{\theta}}^*$  converge en probabilidad a  $\boldsymbol{\theta}^\dagger$  y es asintóticamente normal.
- ▶ Si  $\boldsymbol{\theta}^\dagger = \rho(\boldsymbol{\theta}^*)$ , entonces  $\hat{\boldsymbol{\theta}} = \eta_q(\hat{\boldsymbol{\theta}}^*)$  es estimador consistente de  $\boldsymbol{\theta}^0$ , donde  $\eta_q = \tau_{q,1} \circ \rho^{-1}$
- ▶ Para  $0 < q < 1$  el estimador tiene buenas propiedades de robustez.  $q$  controla el balance entre eficiencia y robustez.
- ▶ El EMV es obtenido como caso particular cuando  $q = 1$ .

# Resultados

- ▶ Bajo condiciones de regularidad apropiadas el  $\text{EML}_q\text{V } \hat{\theta}^*$  converge en probabilidad a  $\theta^\dagger$  y es asintóticamente normal.
- ▶ Si  $\theta^\dagger = \rho(\theta^*)$ , entonces  $\hat{\theta} = \eta_q(\hat{\theta}^*)$  es estimador consistente de  $\theta^0$ , donde  $\eta_q = \tau_{q,1} \circ \rho^{-1}$
- ▶ Para  $0 < q < 1$  el estimador tiene buenas propiedades de robustez.  $q$  controla el balance entre eficiencia y robustez.
- ▶ El EMV es obtenido como caso particular cuando  $q = 1$ .
- ▶ Se obtiene un algoritmo de estimación iterativo de re-ponderación, basado en una versión ponderada del score usual.

# Resultados

- ▶ Bajo condiciones de regularidad apropiadas el  $\text{EML}_{qV} \hat{\theta}^*$  converge en probabilidad a  $\theta^\dagger$  y es asintóticamente normal.
- ▶ Si  $\theta^\dagger = \rho(\theta^*)$ , entonces  $\hat{\theta} = \eta_q(\hat{\theta}^*)$  es estimador consistente de  $\theta^0$ , donde  $\eta_q = \tau_{q,1} \circ \rho^{-1}$
- ▶ Para  $0 < q < 1$  el estimador tiene buenas propiedades de robustez.  $q$  controla el balance entre eficiencia y robustez.
- ▶ El EMV es obtenido como caso particular cuando  $q = 1$ .
- ▶ Se obtiene un algoritmo de estimación iterativo de re-ponderación, basado en una versión ponderada del score usual.
- ▶ La elección de un valor apropiado del parámetro  $q$  puede basarse por ejemplo en alguna técnica numérica como bootstrap, validación cruzada o BIC. En aplicación, dada una grilla de valores  $Q = \{q_1, \dots, q_m\}$ , proponemos elegir

$$q_{\text{opt}} = \arg \min_{q \in Q} \widehat{\text{ECM}}(\hat{\theta}_{(q)}),$$

donde  $\widehat{\text{ECM}}$  es el error cuadrático medio del estimador calculado mediante bootstrap paramétrico.

# Aplicación:

## Modelo de regresión lineal simple con errores en las variables

$$Y_j = \alpha + \beta\xi_j + e_j,$$

$$X_j = \xi_j + u_j, \quad \xi_j \text{ constantes fijas desconocidas, } j = 1, \dots, n,$$

donde  $e_j \sim N(0, \sigma_e^2)$  y  $u_j \sim N(0, \sigma_u^2)$  son independientes.

Asumimos  $\lambda = \sigma_e^2 / \sigma_u^2$  conocida para identificabilidad del modelo.

Sin pérdida de generalidad consideramos  $\lambda = 1$ , luego  $\sigma_e^2 = \sigma_u^2 = \phi$ .

# Aplicación:

## Modelo de regresión lineal simple con errores en las variables

$$Y_j = \alpha + \beta \xi_j + e_j,$$

$$X_j = \xi_j + u_j, \quad \xi_j \text{ constantes fijas desconocidas, } j = 1, \dots, n,$$

donde  $e_j \sim N(0, \sigma_e^2)$  y  $u_j \sim N(0, \sigma_u^2)$  son independientes.

Asumimos  $\lambda = \sigma_e^2 / \sigma_u^2$  conocida para identificabilidad del modelo.

Sin pérdida de generalidad consideramos  $\lambda = 1$ , luego  $\sigma_e^2 = \sigma_u^2 = \phi$ .

$$\mathbf{Z}_j = \mathbf{a} + \mathbf{b}\xi_j + \boldsymbol{\epsilon}_j, \quad j = 1, \dots, n,$$

$$\mathbf{Z}_j \sim N_2(\boldsymbol{\mu}_j, \phi \mathbf{I}_2), \quad \text{donde } \boldsymbol{\mu}_j = \mathbf{a} + \mathbf{b}\xi_j$$

donde  $\mathbf{Z}_j = (X_j, Y_j)^T$  son observables y  $\boldsymbol{\epsilon}_j = (u_j, e_j)^T$  son errores i.i.d.,  $\mathbf{a} = (0, \alpha)^T$  y  $\mathbf{b} = (1, \beta)^T$ .

$\boldsymbol{\theta} = (\alpha, \beta, \phi)^T$  parámetro estructural,  $\xi_1, \dots, \xi_n$  parámetros incidentales

El EML $q$ V  $\hat{\boldsymbol{\theta}}^*$  es estimador consistente de  $\boldsymbol{\theta}^\dagger = (\alpha^0, \beta^0, (q - \frac{1}{2})\phi^0)^T$ ,  
asumiendo  $\frac{1}{2} < q \leq 1$ .

# Eficiencia relativa asintótica (ERA) respecto del EMV

La ERA de los EML $_q$ V de  $\alpha$  y  $\beta$  está dada por

$$[1 - 4(1 - q)^2]^{\frac{1}{2}+1} \times 100.$$

La ERA del EML $_q$ V de  $\phi$  está dada por

$$\frac{[1 - 4(1 - q)^2]^{\frac{1}{2}+2}}{1 + 4(1 - q)^2} \times 100.$$

ERA	$q$								
	1	0.99	0.98	0.95	0.90	0.85	0.80	0.75	0.70
$\alpha, \beta$	100	99.94	99.76	98.50	94.06	86.81	76.99	64.95	51.20
$\phi$	100	99.88	99.52	97.03	88.53	75.59	59.88	43.30	27.77

$$1 > q > 0$$

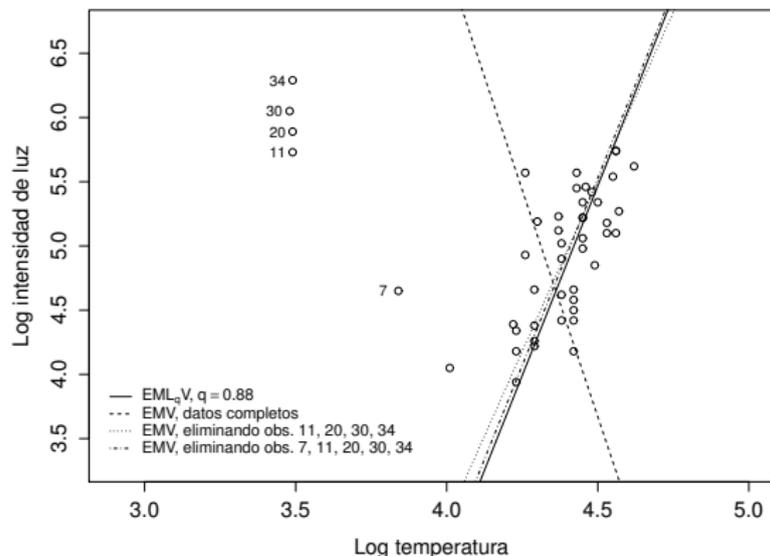
← eficiencia/robustez →

# Ejemplo numérico (Rousseeuw y Leroy, 1987)

Datos de Herzprung-Russell del grupo de estrellas CYG OB1 ( $n = 47$ )

$X$  : logaritmo de la temperatura efectiva en la superficie de la estrella

$Y$  : logaritmo de la intensidad de luz



	EMV	EML <sub>q</sub> V
<i>Datos completos</i>		
	$q=0.88$	
$\hat{\alpha}$	35.43	-21.09
$\hat{\beta}$	-7.06	5.90
$\hat{\phi}$	0.08	0.01
<i>Eliminando obs. 11,20,30,34</i>		
	$q=0.90$	
$\hat{\alpha}$	-18.26	-21.01
$\hat{\beta}$	5.28	5.88
$\hat{\phi}$	0.01	0.01
<i>Eliminando obs. 7,11,20,30,34</i>		
	$q=0.93$	
$\hat{\alpha}$	-20.75	-20.95
$\hat{\beta}$	5.84	5.87
$\hat{\phi}$	0.01	0.01

# Referencias

1. Cressie, N. y Read, T.R.C. (1984). Multinomial goodness-of-fit tests. *JRSS, B*, 46, 440-464.
2. Ferrari, D. y Yang, Y. (2010). Maximum  $L_q$ -likelihood estimation. *Annals of Statistics*, 38, 753-783.
3. Ferrari, D. y La Vecchia, D. (2012). On robust estimation via pseudo-additive information. *Biometrika*, 99, 238-244.
4. Havdra, J. y Charvat, F. (1967). Quantification method of classification processes: Concept of structural entropy. *Kibernetika*, 3, 30-35.
5. Rousseeuw, P.J. y Leroy, A.M. (1987). *Robust Regression and Outlier Detection*. John Wiley & Sons, NY.