

# ESTIMACIÓN DE MÁXIMA LQ-VEROSIMILITUD EN MODELOS CON ERRORES EN LAS VARIABLES FUNCIONALES

Lucas Guarracino y Patricia Giménez

Depto de Matemática. FCEyN. Universidad Nacional de Mar del Plata

Reunión anual de la Unión Matemática Argentina. Bahía  
Blanca, Septiembre de 2016



- 1 Motivación y definición del estimador de máxima Lq-verosimilitud.

- 1 Motivación y definición del estimador de máxima Lq-verosimilitud.
- 2 Propiedades.

- 1 Motivación y definición del estimador de máxima Lq-verosimilitud.
- 2 Propiedades.
- 3 Aplicación.

- 1 Motivación y definición del estimador de máxima Lq-verosimilitud.
- 2 Propiedades.
- 3 Aplicación.
- 4 Estudio de simulación.

# Medidas de divergencia

Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \longrightarrow \mathbb{R}_{\geq 0}$  tal que

## Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \longrightarrow \mathbb{R}_{\geq 0}$  tal que

①  $\mathcal{D}(f, g) \geq 0$ .

## Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \rightarrow \mathbb{R}_{\geq 0}$  tal que

- 1  $\mathcal{D}(f, g) \geq 0$ .
- 2  $\mathcal{D}(f, g) = 0$  si y solo si  $f = g$ .

## Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \longrightarrow \mathbb{R}_{\geq 0}$  tal que

- 1  $\mathcal{D}(f, g) \geq 0$ .
- 2  $\mathcal{D}(f, g) = 0$  si y solo si  $f = g$ .

## Divergencia de Kullback-Leibler

## Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \longrightarrow \mathbb{R}_{\geq 0}$  tal que

- 1  $\mathcal{D}(f, g) \geq 0$ .
- 2  $\mathcal{D}(f, g) = 0$  si y solo si  $f = g$ .

## Divergencia de Kullback-Leibler

$\mathcal{D}_{KL}(f, g)$

## Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \rightarrow \mathbb{R}_{\geq 0}$  tal que

- 1  $\mathcal{D}(f, g) \geq 0$ .
- 2  $\mathcal{D}(f, g) = 0$  si y solo si  $f = g$ .

## Divergencia de Kullback-Leibler

$$\mathcal{D}_{KL}(f, g) = E_F \left[ \log \left( \frac{f(\mathbf{X})}{g(\mathbf{X})} \right) \right]$$

## Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \longrightarrow \mathbb{R}_{\geq 0}$  tal que

- 1  $\mathcal{D}(f, g) \geq 0$ .
- 2  $\mathcal{D}(f, g) = 0$  si y solo si  $f = g$ .

## Divergencia de Kullback-Leibler

$$\mathcal{D}_{KL}(f, g) = E_F \left[ \log \left( \frac{f(\mathbf{X})}{g(\mathbf{X})} \right) \right] = \int_{\mathcal{X}} f(\mathbf{x}) \log \left( \frac{f(\mathbf{x})}{g(\mathbf{x})} \right) d\mu(\mathbf{x}).$$

# Medidas de divergencia

## Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \rightarrow \mathbb{R}_{\geq 0}$  tal que

- 1  $\mathcal{D}(f, g) \geq 0$ .
- 2  $\mathcal{D}(f, g) = 0$  si y solo si  $f = g$ .

## Divergencia de Kullback-Leibler

$$\mathcal{D}_{KL}(f, g) = E_F \left[ \log \left( \frac{f(\mathbf{X})}{g(\mathbf{X})} \right) \right] = \int_{\mathcal{X}} f(\mathbf{x}) \log \left( \frac{f(\mathbf{x})}{g(\mathbf{x})} \right) d\mu(\mathbf{x}).$$

## $\phi$ -divergencias

# Medidas de divergencia

## Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \rightarrow \mathbb{R}_{\geq 0}$  tal que

- 1  $\mathcal{D}(f, g) \geq 0$ .
- 2  $\mathcal{D}(f, g) = 0$  si y solo si  $f = g$ .

## Divergencia de Kullback-Leibler

$$\mathcal{D}_{KL}(f, g) = E_F \left[ \log \left( \frac{f(\mathbf{X})}{g(\mathbf{X})} \right) \right] = \int_{\mathcal{X}} f(\mathbf{x}) \log \left( \frac{f(\mathbf{x})}{g(\mathbf{x})} \right) d\mu(\mathbf{x}).$$

## $\phi$ -divergencias

$$\mathcal{D}_{\phi}(f, g)$$

## Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \rightarrow \mathbb{R}_{\geq 0}$  tal que

- 1  $\mathcal{D}(f, g) \geq 0$ .
- 2  $\mathcal{D}(f, g) = 0$  si y solo si  $f = g$ .

## Divergencia de Kullback-Leibler

$$\mathcal{D}_{KL}(f, g) = E_F \left[ \log \left( \frac{f(\mathbf{X})}{g(\mathbf{X})} \right) \right] = \int_{\mathcal{X}} f(\mathbf{x}) \log \left( \frac{f(\mathbf{x})}{g(\mathbf{x})} \right) d\mu(\mathbf{x}).$$

## $\phi$ -divergencias

$$\mathcal{D}_{\phi}(f, g) = E_G \left[ \phi \left( \frac{f(\mathbf{X})}{g(\mathbf{X})} \right) \right]$$

## Medida de divergencia entre densidades de probabilidad

$\mathcal{D}: \mathcal{G} \times \mathcal{G} \rightarrow \mathbb{R}_{\geq 0}$  tal que

- 1  $\mathcal{D}(f, g) \geq 0$ .
- 2  $\mathcal{D}(f, g) = 0$  si y solo si  $f = g$ .

## Divergencia de Kullback-Leibler

$$\mathcal{D}_{KL}(f, g) = E_F \left[ \log \left( \frac{f(\mathbf{X})}{g(\mathbf{X})} \right) \right] = \int_{\mathcal{X}} f(\mathbf{x}) \log \left( \frac{f(\mathbf{x})}{g(\mathbf{x})} \right) d\mu(\mathbf{x}).$$

## $\phi$ -divergencias

$$\mathcal{D}_{\phi}(f, g) = E_G \left[ \phi \left( \frac{f(\mathbf{X})}{g(\mathbf{X})} \right) \right] = \int_{\mathcal{X}} g(\mathbf{x}) \phi \left( \frac{f(\mathbf{x})}{g(\mathbf{x})} \right) d\mu(\mathbf{x}).$$

# Medidas de divergencia

## $q$ -divergencia

## $q$ -divergencia

Tomando

$$\phi(x) = \begin{cases} \frac{1}{q(q-1)} [x^q - x - (q-1)(x-1)], & \text{si } q \neq 0, 1 \\ -x \log x + x - 1, & \text{si } q = 0 \\ x \log x - x + 1, & \text{si } q = 1 \end{cases}$$

## $q$ -divergencia

Tomando

$$\phi(x) = \begin{cases} \frac{1}{q(q-1)} [x^q - x - (q-1)(x-1)], & \text{si } q \neq 0, 1 \\ -x \log x + x - 1, & \text{si } q = 0 \\ x \log x - x + 1, & \text{si } q = 1 \end{cases}$$

se obtiene

$$\mathcal{D}_q(f, g)$$

## $q$ -divergencia

Tomando

$$\phi(x) = \begin{cases} \frac{1}{q(q-1)} [x^q - x - (q-1)(x-1)], & \text{si } q \neq 0, 1 \\ -x \log x + x - 1, & \text{si } q = 0 \\ x \log x - x + 1, & \text{si } q = 1 \end{cases}$$

se obtiene

$$\mathcal{D}_q(f, g) = -\frac{1}{q} E_F \left( \log_q \left[ \frac{g(\mathbf{X})}{f(\mathbf{X})} \right] \right)$$

## $q$ -divergencia

Tomando

$$\phi(x) = \begin{cases} \frac{1}{q(q-1)} [x^q - x - (q-1)(x-1)], & \text{si } q \neq 0, 1 \\ -x \log x + x - 1, & \text{si } q = 0 \\ x \log x - x + 1, & \text{si } q = 1 \end{cases}$$

se obtiene

$$\mathcal{D}_q(f, g) = -\frac{1}{q} E_F \left( \log_q \left[ \frac{g(\mathbf{X})}{f(\mathbf{X})} \right] \right) = -\frac{1}{q} \int_{\mathcal{X}} f(\mathbf{x}) \log_q \left[ \frac{g(\mathbf{x})}{f(\mathbf{x})} \right] d\mu(\mathbf{x}),$$

## $q$ -divergencia

Tomando

$$\phi(x) = \begin{cases} \frac{1}{q(q-1)} [x^q - x - (q-1)(x-1)], & \text{si } q \neq 0, 1 \\ -x \log x + x - 1, & \text{si } q = 0 \\ x \log x - x + 1, & \text{si } q = 1 \end{cases}$$

se obtiene

$$\mathcal{D}_q(f, g) = -\frac{1}{q} E_F \left( \log_q \left[ \frac{g(\mathbf{X})}{f(\mathbf{X})} \right] \right) = -\frac{1}{q} \int_{\mathcal{X}} f(\mathbf{x}) \log_q \left[ \frac{g(\mathbf{x})}{f(\mathbf{x})} \right] d\mu(\mathbf{x}),$$

donde

$$\log_q x = \begin{cases} \frac{x^{1-q} - 1}{1 - q}, & \text{si } q \neq 1 \\ \log x, & \text{si } q = 1 \end{cases}$$

# Medidas de divergencia

Si  $q = 1$ , entonces  $\log_q = \log$  y  $\mathcal{D}_q(f, g) = \mathcal{D}_{KL}(f, g)$ .

# Construcción del estimador para una muestra i.i.d.

# Construcción del estimador para una muestra i.i.d.

Modelamos la densidad  $g$  con un modelo estadístico paramétrico  $\mathcal{F}_\theta$ , minimizando  $\mathcal{D}_q(g, f_\theta)$  respecto a  $\theta$ , donde

# Construcción del estimador para una muestra i.i.d.

Modelamos la densidad  $g$  con un modelo estadístico paramétrico  $\mathcal{F}_\theta$ , minimizando  $\mathcal{D}_q(g, f_\theta)$  respecto a  $\theta$ , donde

- 1  $g$  es la verdadera densidad desconocida que genera los datos.

# Construcción del estimador para una muestra i.i.d.

Modelamos la densidad  $g$  con un modelo estadístico paramétrico  $\mathcal{F}_\theta$ , minimizando  $\mathcal{D}_q(g, f_\theta)$  respecto a  $\theta$ , donde

- 1  $g$  es la verdadera densidad desconocida que genera los datos.
- 2  $f_\theta$  es una densidad perteneciente a  $\mathcal{F}_\theta$ .

# Construcción del estimador para una muestra i.i.d.

Modelamos la densidad  $g$  con un modelo estadístico paramétrico  $\mathcal{F}_\theta$ , minimizando  $\mathcal{D}_q(g, f_\theta)$  respecto a  $\theta$ , donde

- 1  $g$  es la verdadera densidad desconocida que genera los datos.
- 2  $f_\theta$  es una densidad perteneciente a  $\mathcal{F}_\theta$ .

A partir de una muestra aleatoria  $\mathbf{Z}_1, \dots, \mathbf{Z}_n$  proveniente de la distribución desconocida  $G$ , queremos minimizar la versión empírica de la  $q$ -divergencia

# Construcción del estimador para una muestra i.i.d.

Modelamos la densidad  $g$  con un modelo estadístico paramétrico  $\mathcal{F}_\theta$ , minimizando  $\mathcal{D}_q(g, f_\theta)$  respecto a  $\theta$ , donde

- 1  $g$  es la verdadera densidad desconocida que genera los datos.
- 2  $f_\theta$  es una densidad perteneciente a  $\mathcal{F}_\theta$ .

A partir de una muestra aleatoria  $\mathbf{Z}_1, \dots, \mathbf{Z}_n$  proveniente de la distribución desconocida  $G$ , queremos minimizar la versión empírica de la  $q$ -divergencia

$$\mathcal{D}_q(\hat{g}, f_\theta) = -\frac{1}{q} E_{\hat{G}} \left( \log_q \left[ \frac{f_\theta(\mathbf{X})}{\hat{g}(\mathbf{X})} \right] \right),$$

# Construcción del estimador para una muestra i.i.d.

Modelamos la densidad  $g$  con un modelo estadístico paramétrico  $\mathcal{F}_\theta$ , minimizando  $\mathcal{D}_q(g, f_\theta)$  respecto a  $\theta$ , donde

- 1  $g$  es la verdadera densidad desconocida que genera los datos.
- 2  $f_\theta$  es una densidad perteneciente a  $\mathcal{F}_\theta$ .

A partir de una muestra aleatoria  $\mathbf{Z}_1, \dots, \mathbf{Z}_n$  proveniente de la distribución desconocida  $G$ , queremos minimizar la versión empírica de la  $q$ -divergencia

$$\mathcal{D}_q(\hat{g}, f_\theta) = -\frac{1}{q} E_{\hat{G}} \left( \log_q \left[ \frac{f_\theta(\mathbf{X})}{\hat{g}(\mathbf{X})} \right] \right),$$

donde

# Construcción del estimador para una muestra i.i.d.

Modelamos la densidad  $g$  con un modelo estadístico paramétrico  $\mathcal{F}_\theta$ , minimizando  $\mathcal{D}_q(g, f_\theta)$  respecto a  $\theta$ , donde

- 1  $g$  es la verdadera densidad desconocida que genera los datos.
- 2  $f_\theta$  es una densidad perteneciente a  $\mathcal{F}_\theta$ .

A partir de una muestra aleatoria  $\mathbf{Z}_1, \dots, \mathbf{Z}_n$  proveniente de la distribución desconocida  $G$ , queremos minimizar la versión empírica de la  $q$ -divergencia

$$\mathcal{D}_q(\hat{g}, f_\theta) = -\frac{1}{q} E_{\hat{G}} \left( \log_q \left[ \frac{f_\theta(\mathbf{X})}{\hat{g}(\mathbf{X})} \right] \right),$$

donde

- 1  $\hat{G}$  es la distribución empírica de la muestra.

# Construcción del estimador para una muestra i.i.d.

Modelamos la densidad  $g$  con un modelo estadístico paramétrico  $\mathcal{F}_\theta$ , minimizando  $\mathcal{D}_q(g, f_\theta)$  respecto a  $\theta$ , donde

- 1  $g$  es la verdadera densidad desconocida que genera los datos.
- 2  $f_\theta$  es una densidad perteneciente a  $\mathcal{F}_\theta$ .

A partir de una muestra aleatoria  $\mathbf{Z}_1, \dots, \mathbf{Z}_n$  proveniente de la distribución desconocida  $G$ , queremos minimizar la versión empírica de la  $q$ -divergencia

$$\mathcal{D}_q(\hat{g}, f_\theta) = -\frac{1}{q} E_{\hat{G}} \left( \log_q \left[ \frac{f_\theta(\mathbf{X})}{\hat{g}(\mathbf{X})} \right] \right),$$

donde

- 1  $\hat{G}$  es la distribución empírica de la muestra.
- 2  $\hat{g}$  es algún estimador no paramétrico de  $g$  en base a la muestra.

# Construcción del estimador para una muestra i.i.d.

# Construcción del estimador para una muestra i.i.d.

Complicaciones al estimar  $g$  en problemas multivariados:

# Construcción del estimador para una muestra i.i.d.

Complicaciones al estimar  $g$  en problemas multivariados:

- 1 Difícil selección del ancho de banda.

# Construcción del estimador para una muestra i.i.d.

Complicaciones al estimar  $g$  en problemas multivariados:

- 1 Difícil selección del ancho de banda.
- 2 Presición del estimador dependiente de la convergencia del estimador de  $g$ .

Complicaciones al estimar  $g$  en problemas multivariados:

- 1 Difícil selección del ancho de banda.
- 2 Presición del estimador dependiente de la convergencia del estimador de  $g$ .

Ferrari y Laveccia (2012):

# Construcción del estimador para una muestra i.i.d.

Complicaciones al estimar  $g$  en problemas multivariados:

- 1 Difícil selección del ancho de banda.
- 2 Presición del estimador dependiente de la convergencia del estimador de  $g$ .

Ferrari y Laveccia (2012): Si cambiamos  $g$  por  $g^{(\frac{1}{q})}$ , obtenemos

Complicaciones al estimar  $g$  en problemas multivariados:

- 1 Difícil selección del ancho de banda.
- 2 Presición del estimador dependiente de la convergencia del estimador de  $g$ .

Ferrari y Laveccia (2012): Si cambiamos  $g$  por  $g^{(\frac{1}{q})}$ , obtenemos

$$\mathcal{D}_q(g^{(\frac{1}{q})}, f_\theta) = cte \left( \mathcal{H}_q(g, f_\theta) - \mathcal{H}_q(g, g^{(\frac{1}{q})}) \right),$$

Complicaciones al estimar  $g$  en problemas multivariados:

- 1 Difícil selección del ancho de banda.
- 2 Presición del estimador dependiente de la convergencia del estimador de  $g$ .

Ferrari y Laveccia (2012): Si cambiamos  $g$  por  $g^{(\frac{1}{q})}$ , obtenemos

$$\mathcal{D}_q(g^{(\frac{1}{q})}, f_\theta) = cte \left( \mathcal{H}_q(g, f_\theta) - \mathcal{H}_q(g, g^{(\frac{1}{q})}) \right),$$

donde

- 1  $\mathcal{H}_q(g, f) = -E_G [\log_q f(\mathbf{X})]$

Complicaciones al estimar  $g$  en problemas multivariados:

- 1 Difícil selección del ancho de banda.
- 2 Presición del estimador dependiente de la convergencia del estimador de  $g$ .

Ferrari y Laveccia (2012): Si cambiamos  $g$  por  $g^{(\frac{1}{q})}$ , obtenemos

$$\mathcal{D}_q(g^{(\frac{1}{q})}, f_\theta) = cte \left( \mathcal{H}_q(g, f_\theta) - \mathcal{H}_q(g, g^{(\frac{1}{q})}) \right),$$

donde

- 1  $\mathcal{H}_q(g, f) = -E_G [\log_q f(\mathbf{X})]$  ( $q$ -entropía cruzada).

Complicaciones al estimar  $g$  en problemas multivariados:

- 1 Difícil selección del ancho de banda.
- 2 Presición del estimador dependiente de la convergencia del estimador de  $g$ .

Ferrari y Laveccia (2012): Si cambiamos  $g$  por  $g^{(\frac{1}{q})}$ , obtenemos

$$\mathcal{D}_q(g^{(\frac{1}{q})}, f_\theta) = cte \left( \mathcal{H}_q(g, f_\theta) - \mathcal{H}_q(g, g^{(\frac{1}{q})}) \right),$$

donde

- 1  $\mathcal{H}_q(g, f) = -E_G [\log_q f(\mathbf{X})]$  ( $q$ -entropía cruzada).
- 2  $g^{(\frac{1}{q})}(x) = \frac{g(x)^{\frac{1}{q}}}{\int g(x)^{\frac{1}{q}} dx}$

Complicaciones al estimar  $g$  en problemas multivariados:

- 1 Difícil selección del ancho de banda.
- 2 Presición del estimador dependiente de la convergencia del estimador de  $g$ .

Ferrari y Laveccia (2012): Si cambiamos  $g$  por  $g^{(\frac{1}{q})}$ , obtenemos

$$\mathcal{D}_q(g^{(\frac{1}{q})}, f_\theta) = cte \left( \mathcal{H}_q(g, f_\theta) - \mathcal{H}_q(g, g^{(\frac{1}{q})}) \right),$$

donde

- 1  $\mathcal{H}_q(g, f) = -E_G [\log_q f(\mathbf{X})]$  ( $q$ -entropía cruzada).
- 2  $g^{(\frac{1}{q})}(x) = \frac{g(x)^{\frac{1}{q}}}{\int g(x)^{\frac{1}{q}} dx}$  (transformación potencia de  $g$ )

# Construcción del estimador para una muestra i.i.d.

Entonces, minimizar  $\mathcal{D}_q(g^{(\frac{1}{q})}, f_\theta)$  es equivalente a minimizar  $\mathcal{H}_q(g, f_\theta)$ .

Entonces, minimizar  $\mathcal{D}_q(g^{(\frac{1}{q})}, f_\theta)$  es equivalente a minimizar  $\mathcal{H}_q(g, f_\theta)$ . Se evita el problema de estimar  $g$ , aunque se cambia de densidad objetivo.

Entonces, minimizar  $\mathcal{D}_q(g^{(\frac{1}{q})}, f_\theta)$  es equivalente a minimizar  $\mathcal{H}_q(g, f_\theta)$ . Se evita el problema de estimar  $g$ , aunque se cambia de densidad objetivo.

Definimos al estimador de máxima L $q$ -verosimilitud (mínima  $q$ -entropía) como

Entonces, minimizar  $\mathcal{D}_q(g^{(\frac{1}{q})}, f_\theta)$  es equivalente a minimizar  $\mathcal{H}_q(g, f_\theta)$ . Se evita el problema de estimar  $g$ , aunque se cambia de densidad objetivo.

Definimos al estimador de máxima L $q$ -verosimilitud (mínima  $q$ -entropía) como

$$\hat{\theta}_q^* = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q [f(z_i; \theta)] \right\}.$$

Entonces, minimizar  $\mathcal{D}_q(g^{(\frac{1}{q})}, f_\theta)$  es equivalente a minimizar  $\mathcal{H}_q(g, f_\theta)$ . Se evita el problema de estimar  $g$ , aunque se cambia de densidad objetivo.

Definimos al estimador de máxima L $q$ -verosimilitud (mínima  $q$ -entropía) como

$$\hat{\theta}_q^* = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q [f(z_i; \theta)] \right\}.$$

En notación funcional

$$T_q^*(H) = \theta_q^* = \operatorname{argmax}_{\theta \in \Theta} E_H \{ \log_q [f(\mathbf{Z}; \theta)] \}.$$

# Construcción del estimador para una muestra i.i.d.

Observaciones:

Observaciones:

- 1  $T_q^*$  no es Fisher-consistente, pues  $T_q^*(F_\theta) \neq \theta$ .

Observaciones:

- 1  $T_q^*$  no es Fisher-consistente, pues  $T_q^*(F_\theta) \neq \theta$ .
- 2  $T_q^*(F_\theta)$  es el parámetro de  $f_\theta^{(q)}$ , siempre que esta transformación sea cerrada en el modelo.

Observaciones:

- 1  $T_q^*$  no es Fisher-consistente, pues  $T_q^*(F_\theta) \neq \theta$ .
- 2  $T_q^*(F_\theta)$  es el parámetro de  $f_\theta^{(q)}$ , siempre que esta transformación sea cerrada en el modelo.
- 3  $\hat{\theta}_q^*$  es consistente para  $T_q^*(G)$ .

Observaciones:

- 1  $T_q^*$  no es Fisher-consistente, pues  $T_q^*(F_\theta) \neq \theta$ .
- 2  $T_q^*(F_\theta)$  es el parámetro de  $f_\theta^{(q)}$ , siempre que esta transformación sea cerrada en el modelo.
- 3  $\hat{\theta}_q^*$  es consistente para  $T_q^*(G)$ .
- 4 Por ser un  $M$ -estimador,  $\hat{\theta}_q^*$  tiene distribución asintótica conocida.

Observaciones:

- 1  $T_q^*$  no es Fisher-consistente, pues  $T_q^*(F_\theta) \neq \theta$ .
- 2  $T_q^*(F_\theta)$  es el parámetro de  $f_\theta^{(q)}$ , siempre que esta transformación sea cerrada en el modelo.
- 3  $\hat{\theta}_q^*$  es consistente para  $T_q^*(G)$ .
- 4 Por ser un  $M$ -estimador,  $\hat{\theta}_q^*$  tiene distribución asintótica conocida.

Si está bien definida la biyección  $\tau_q$  en el espacio paramétrico de manera que  $T_q^*(F_\theta) = \tau_q^{-1}(\theta)$  entonces definimos al estimador de mínima  $q$ -divergencia mediante:  $\hat{\theta}_q = \tau_q(\hat{\theta}_q^*)$ ,

Observaciones:

- 1  $T_q^*$  no es Fisher-consistente, pues  $T_q^*(F_\theta) \neq \theta$ .
- 2  $T_q^*(F_\theta)$  es el parámetro de  $f_\theta^{(q)}$ , siempre que esta transformación sea cerrada en el modelo.
- 3  $\hat{\theta}_q^*$  es consistente para  $T_q^*(G)$ .
- 4 Por ser un  $M$ -estimador,  $\hat{\theta}_q^*$  tiene distribución asintótica conocida.

Si está bien definida la biyección  $\tau_q$  en el espacio paramétrico de manera que  $T_q^*(F_\theta) = \tau_q^{-1}(\theta)$  entonces definimos al estimador de mínima  $q$ -divergencia mediante:  $\hat{\theta}_q = \tau_q(\hat{\theta}_q^*)$ , o en notación funcional:  $T_q(H) = \tau_q(T_q^*(H))$ .

Observaciones:

- 1  $T_q^*$  no es Fisher-consistente, pues  $T_q^*(F_\theta) \neq \theta$ .
- 2  $T_q^*(F_\theta)$  es el parámetro de  $f_\theta^{(q)}$ , siempre que esta transformación sea cerrada en el modelo.
- 3  $\hat{\theta}_q^*$  es consistente para  $T_q^*(G)$ .
- 4 Por ser un  $M$ -estimador,  $\hat{\theta}_q^*$  tiene distribución asintótica conocida.

Si está bien definida la biyección  $\tau_q$  en el espacio paramétrico de manera que  $T_q^*(F_\theta) = \tau_q^{-1}(\theta)$  entonces definimos al estimador de mínima  $q$ -divergencia mediante:  $\hat{\theta}_q = \tau_q(\hat{\theta}_q^*)$ , o en notación funcional:  $T_q(H) = \tau_q(T_q^*(H))$ .

Las propiedades de  $T_q$  y  $\hat{\theta}_q$  se deducen inmediatamente de las de  $T_q^*$  y  $\hat{\theta}_q^*$  a través de  $\tau_q$ .

# Muestra no idénticamente distribuída

# Muestra no idénticamente distribuída

Si cada elemento  $Z_i$  de la muestra tiene distribución  $G_i$ , modelamos cada  $g_i$  con un modelo estadístico paramétrico  $\mathcal{F}_{i,\theta}$ , todos con el mismo espacio parametral, y definimos el estimador de máxima  $Lq$ -verosimilitud mediante

# Muestra no idénticamente distribuída

Si cada elemento  $\mathbf{Z}_i$  de la muestra tiene distribución  $G_i$ , modelamos cada  $g_i$  con un modelo estadístico paramétrico  $\mathcal{F}_{i,\theta}$ , todos con el mismo espacio parametral, y definimos el estimador de máxima  $L_q$ -verosimilitud mediante

$$\hat{\theta}_q^* = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q [f_i(\mathbf{z}_i; \theta)] \right\},$$

# Muestra no idénticamente distribuída

Si cada elemento  $\mathbf{Z}_i$  de la muestra tiene distribución  $G_i$ , modelamos cada  $g_i$  con un modelo estadístico paramétrico  $\mathcal{F}_{i,\theta}$ , todos con el mismo espacio parametral, y definimos el estimador de máxima  $Lq$ -verosimilitud mediante

$$\hat{\theta}_q^* = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q [f_i(\mathbf{z}_i; \theta)] \right\},$$

o en notación funcional

# Muestra no idénticamente distribuida

Si cada elemento  $\mathbf{Z}_i$  de la muestra tiene distribución  $G_i$ , modelamos cada  $g_i$  con un modelo estadístico paramétrico  $\mathcal{F}_{i,\theta}$ , todos con el mismo espacio parametral, y definimos el estimador de máxima  $Lq$ -verosimilitud mediante

$$\hat{\theta}_q^* = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q [f_i(\mathbf{z}_i; \theta)] \right\},$$

o en notación funcional

$$T_q^*(H_1, \dots, H_n) = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n E_{H_i} [\log_q f_i(\mathbf{Z}_i; \theta)] \right\}.$$

# Modelo de calibración comparativa

# Modelo de calibración comparativa

Sea  $\mathbf{Z}_1 = (X_1, \mathbf{Y}_1^t)^t, \dots, \mathbf{Z}_n = (X_n, \mathbf{Y}_n^t)^t$  una muestra aleatoria, con

# Modelo de calibración comparativa

Sea  $\mathbf{Z}_1 = (X_1, \mathbf{Y}_1^t)^t, \dots, \mathbf{Z}_n = (X_n, \mathbf{Y}_n^t)^t$  una muestra aleatoria, con

$$\begin{cases} \mathbf{Y}_i = \boldsymbol{\alpha} + \xi_i \boldsymbol{\beta} + \boldsymbol{\epsilon}_i \\ X_i = \xi_i + U_i \end{cases},$$

# Modelo de calibración comparativa

Sea  $\mathbf{Z}_1 = (X_1, \mathbf{Y}_1^t)^t, \dots, \mathbf{Z}_n = (X_n, \mathbf{Y}_n^t)^t$  una muestra aleatoria, con

$$\begin{cases} \mathbf{Y}_i = \boldsymbol{\alpha} + \xi_i \boldsymbol{\beta} + \boldsymbol{\epsilon}_i \\ X_i = \xi_i + U_i \end{cases},$$

donde  $\boldsymbol{\epsilon}_i \sim \mathbf{N}_p(\mathbf{0}, \phi \mathbf{Id}_p)$  y  $U_i \sim N(0, \phi)$  son independientes.

# Modelo de calibración comparativa

Sea  $\mathbf{Z}_1 = (X_1, \mathbf{Y}_1^t)^t, \dots, \mathbf{Z}_n = (X_n, \mathbf{Y}_n^t)^t$  una muestra aleatoria, con

$$\begin{cases} \mathbf{Y}_i = \boldsymbol{\alpha} + \xi_i \boldsymbol{\beta} + \boldsymbol{\epsilon}_i \\ X_i = \xi_i + U_i \end{cases},$$

donde  $\boldsymbol{\epsilon}_i \sim \mathbf{N}_p(\mathbf{0}, \phi \mathbf{Id}_p)$  y  $U_i \sim N(0, \phi)$  son independientes. Entonces

# Modelo de calibración comparativa

Sea  $\mathbf{Z}_1 = (X_1, \mathbf{Y}_1^t)^t, \dots, \mathbf{Z}_n = (X_n, \mathbf{Y}_n^t)^t$  una muestra aleatoria, con

$$\begin{cases} \mathbf{Y}_i = \boldsymbol{\alpha} + \xi_i \boldsymbol{\beta} + \boldsymbol{\epsilon}_i \\ X_i = \xi_i + U_i \end{cases},$$

donde  $\boldsymbol{\epsilon}_i \sim \mathbf{N}_p(\mathbf{0}, \phi \mathbf{I}_p)$  y  $U_i \sim N(0, \phi)$  son independientes. Entonces

①  $X_i \sim N(\xi_i, \phi)$ .

# Modelo de calibración comparativa

Sea  $\mathbf{Z}_1 = (X_1, \mathbf{Y}_1^t)^t, \dots, \mathbf{Z}_n = (X_n, \mathbf{Y}_n^t)^t$  una muestra aleatoria, con

$$\begin{cases} \mathbf{Y}_i = \boldsymbol{\alpha} + \xi_i \boldsymbol{\beta} + \boldsymbol{\epsilon}_i \\ X_i = \xi_i + U_i \end{cases},$$

donde  $\boldsymbol{\epsilon}_i \sim \mathbf{N}_p(\mathbf{0}, \phi \mathbf{Id}_p)$  y  $U_i \sim N(0, \phi)$  son independientes.

Entonces

- 1  $X_i \sim N(\xi_i, \phi)$ .
- 2  $\mathbf{Y}_i \sim \mathbf{N}_p(\boldsymbol{\alpha} + \xi_i \boldsymbol{\beta}, \phi \mathbf{Id}_p)$ .

# Modelo de calibración comparativa

Sea  $\mathbf{Z}_1 = (X_1, \mathbf{Y}_1^t)^t, \dots, \mathbf{Z}_n = (X_n, \mathbf{Y}_n^t)^t$  una muestra aleatoria, con

$$\begin{cases} \mathbf{Y}_i = \boldsymbol{\alpha} + \xi_i \boldsymbol{\beta} + \boldsymbol{\epsilon}_i \\ X_i = \xi_i + U_i \end{cases},$$

donde  $\boldsymbol{\epsilon}_i \sim \mathbf{N}_p(\mathbf{0}, \phi \mathbf{Id}_p)$  y  $U_i \sim N(0, \phi)$  son independientes.

Entonces

- 1  $X_i \sim N(\xi_i, \phi)$ .
- 2  $\mathbf{Y}_i \sim \mathbf{N}_p(\boldsymbol{\alpha} + \xi_i \boldsymbol{\beta}, \phi \mathbf{Id}_p)$ .
- 3  $\mathbf{Z}_i \sim \mathbf{N}_{p+1}(\boldsymbol{\mu}_i, \phi \mathbf{Id}_{p+1})$ , con  $\boldsymbol{\mu}_i = (\xi_i, \boldsymbol{\alpha}^t + \xi_i \boldsymbol{\beta}^t)^t$ .

# Modelo de calibración comparativa

Sea  $\mathbf{Z}_1 = (X_1, \mathbf{Y}_1^t)^t, \dots, \mathbf{Z}_n = (X_n, \mathbf{Y}_n^t)^t$  una muestra aleatoria, con

$$\begin{cases} \mathbf{Y}_i = \boldsymbol{\alpha} + \xi_i \boldsymbol{\beta} + \boldsymbol{\epsilon}_i \\ X_i = \xi_i + U_i \end{cases},$$

donde  $\boldsymbol{\epsilon}_i \sim \mathbf{N}_p(\mathbf{0}, \phi \mathbf{I}_p)$  y  $U_i \sim N(0, \phi)$  son independientes.

Entonces

- 1  $X_i \sim N(\xi_i, \phi)$ .
- 2  $\mathbf{Y}_i \sim \mathbf{N}_p(\boldsymbol{\alpha} + \xi_i \boldsymbol{\beta}, \phi \mathbf{I}_p)$ .
- 3  $\mathbf{Z}_i \sim \mathbf{N}_{p+1}(\boldsymbol{\mu}_i, \phi \mathbf{I}_{p+1})$ , con  $\boldsymbol{\mu}_i = (\xi_i, \boldsymbol{\alpha}^t + \xi_i \boldsymbol{\beta}^t)^t$ .
- 4  $\boldsymbol{\theta} = (\boldsymbol{\alpha}^t, \boldsymbol{\beta}^t, \phi)^t$  : parámetro estructural.

# Modelo de calibración comparativa

Sea  $\mathbf{Z}_1 = (X_1, \mathbf{Y}_1^t)^t, \dots, \mathbf{Z}_n = (X_n, \mathbf{Y}_n^t)^t$  una muestra aleatoria, con

$$\begin{cases} \mathbf{Y}_i = \boldsymbol{\alpha} + \xi_i \boldsymbol{\beta} + \boldsymbol{\epsilon}_i \\ X_i = \xi_i + U_i \end{cases},$$

donde  $\boldsymbol{\epsilon}_i \sim \mathbf{N}_p(\mathbf{0}, \phi \mathbf{I}_p)$  y  $U_i \sim N(0, \phi)$  son independientes.

Entonces

- 1  $X_i \sim N(\xi_i, \phi)$ .
- 2  $\mathbf{Y}_i \sim \mathbf{N}_p(\boldsymbol{\alpha} + \xi_i \boldsymbol{\beta}, \phi \mathbf{I}_p)$ .
- 3  $\mathbf{Z}_i \sim \mathbf{N}_{p+1}(\boldsymbol{\mu}_i, \phi \mathbf{I}_{p+1})$ , con  $\boldsymbol{\mu}_i = (\xi_i, \boldsymbol{\alpha}^t + \xi_i \boldsymbol{\beta}^t)^t$ .
- 4  $\boldsymbol{\theta} = (\boldsymbol{\alpha}^t, \boldsymbol{\beta}^t, \phi)^t$  : parámetro estructural.
- 5  $\xi_i$ 's : parámetros incidentales.

# Modelo de calibración comparativa

Sea  $\mathbf{Z}_1 = (X_1, \mathbf{Y}_1^t)^t, \dots, \mathbf{Z}_n = (X_n, \mathbf{Y}_n^t)^t$  una muestra aleatoria, con

$$\begin{cases} \mathbf{Y}_i = \boldsymbol{\alpha} + \xi_i \boldsymbol{\beta} + \boldsymbol{\epsilon}_i \\ X_i = \xi_i + U_i \end{cases},$$

donde  $\boldsymbol{\epsilon}_i \sim \mathbf{N}_p(\mathbf{0}, \phi \mathbf{I}_p)$  y  $U_i \sim N(0, \phi)$  son independientes.

Entonces

- 1  $X_i \sim N(\xi_i, \phi)$ .
- 2  $\mathbf{Y}_i \sim \mathbf{N}_p(\boldsymbol{\alpha} + \xi_i \boldsymbol{\beta}, \phi \mathbf{I}_p)$ .
- 3  $\mathbf{Z}_i \sim \mathbf{N}_{p+1}(\boldsymbol{\mu}_i, \phi \mathbf{I}_{p+1})$ , con  $\boldsymbol{\mu}_i = (\xi_i, \boldsymbol{\alpha}^t + \xi_i \boldsymbol{\beta}^t)^t$ .
- 4  $\boldsymbol{\theta} = (\boldsymbol{\alpha}^t, \boldsymbol{\beta}^t, \phi)^t$  : parámetro estructural.
- 5  $\xi_i$ 's : parámetros incidentales.

La muestra no es idénticamente distribuída.

# Modelo de calibración comparativa

$$f_i(\mathbf{z}; \boldsymbol{\theta}) = (2\pi\phi)^{-\frac{p+1}{2}} \exp \left\{ -\frac{1}{2\phi} \|\mathbf{z} - \boldsymbol{\mu}_i\|^2 \right\}.$$

$$f_i(\mathbf{z}; \boldsymbol{\theta}) = (2\pi\phi)^{-\frac{p+1}{2}} \exp \left\{ -\frac{1}{2\phi} \|\mathbf{z} - \boldsymbol{\mu}_i\|^2 \right\}.$$

EMLqV de los parámetros incidentales

$$\hat{\xi}_i = \frac{1}{c} ((\mathbf{y}_i - \boldsymbol{\alpha})^t \boldsymbol{\beta} + x_i),$$

$$f_i(\mathbf{z}; \boldsymbol{\theta}) = (2\pi\phi)^{-\frac{p+1}{2}} \exp \left\{ -\frac{1}{2\phi} \|\mathbf{z} - \boldsymbol{\mu}_i\|^2 \right\}.$$

EMLqV de los parámetros incidentales

$$\hat{\xi}_i = \frac{1}{c} ((\mathbf{y}_i - \boldsymbol{\alpha})^t \boldsymbol{\beta} + x_i),$$

con  $c = 1 + \boldsymbol{\beta}^t \boldsymbol{\beta}$ .

$$f_i(\mathbf{z}; \boldsymbol{\theta}) = (2\pi\phi)^{-\frac{p+1}{2}} \exp \left\{ -\frac{1}{2\phi} \|\mathbf{z} - \boldsymbol{\mu}_i\|^2 \right\}.$$

EMLqV de los parámetros incidentales

$$\hat{\xi}_i = \frac{1}{c} ((\mathbf{y}_i - \boldsymbol{\alpha})^t \boldsymbol{\beta} + x_i),$$

con  $c = 1 + \boldsymbol{\beta}^t \boldsymbol{\beta}$ .

Densidad perfilada

$$\tilde{f}_i(\mathbf{z}; \boldsymbol{\theta}) = (2\pi\phi)^{-\frac{p+1}{2}} \exp \left\{ -\frac{1}{2\phi} [\mathbf{y} - (\boldsymbol{\alpha} + x\boldsymbol{\beta})]^t \mathbf{B} [\mathbf{y} - (\boldsymbol{\alpha} + x\boldsymbol{\beta})] \right\},$$

$$f_i(\mathbf{z}; \boldsymbol{\theta}) = (2\pi\phi)^{-\frac{p+1}{2}} \exp \left\{ -\frac{1}{2\phi} \|\mathbf{z} - \boldsymbol{\mu}_i\|^2 \right\}.$$

EMLqV de los parámetros incidentales

$$\hat{\xi}_i = \frac{1}{c} ((\mathbf{y}_i - \boldsymbol{\alpha})^t \boldsymbol{\beta} + x_i),$$

con  $c = 1 + \boldsymbol{\beta}^t \boldsymbol{\beta}$ .

Densidad perfilada

$$\tilde{f}_i(\mathbf{z}; \boldsymbol{\theta}) = (2\pi\phi)^{-\frac{p+1}{2}} \exp \left\{ -\frac{1}{2\phi} [\mathbf{y} - (\boldsymbol{\alpha} + x\boldsymbol{\beta})]^t \mathbf{B} [\mathbf{y} - (\boldsymbol{\alpha} + x\boldsymbol{\beta})] \right\},$$

donde  $\mathbf{B} = \frac{1}{c} (\mathbf{Id}_p - \boldsymbol{\beta}\boldsymbol{\beta}^t)$ .

# Modelo de calibración comparativa

## EMLqV en el modelo de calibración comparativa

## EMLqV en el modelo de calibración comparativa

$$\hat{\theta}_q^\dagger = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q \left[ \tilde{f}_i(\mathbf{z}_i; \theta) \right] \right\}.$$

## EMLqV en el modelo de calibración comparativa

$$\hat{\theta}_q^\dagger = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q \left[ \tilde{f}_i(\mathbf{z}_i; \theta) \right] \right\}.$$

En notación funcional

## EMLqV en el modelo de calibración comparativa

$$\hat{\theta}_q^\dagger = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q \left[ \tilde{f}_i(\mathbf{z}_i; \theta) \right] \right\}.$$

En notación funcional

$$T_q^\dagger(H_1, \dots, H_n) = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n E_{H_i} \left[ \log_q \tilde{f}_i(\mathbf{z}; \theta) \right] \right\}.$$

## EMLqV en el modelo de calibración comparativa

$$\hat{\theta}_q^\dagger = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q \left[ \tilde{f}_i(\mathbf{z}_i; \theta) \right] \right\}.$$

En notación funcional

$$T_q^\dagger(H_1, \dots, H_n) = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n E_{H_i} \left[ \log_q \tilde{f}_i(\mathbf{z}; \theta) \right] \right\}.$$

## Ecuación de estimación

## EMLqV en el modelo de calibración comparativa

$$\hat{\theta}_q^\dagger = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q \left[ \tilde{f}_i(\mathbf{z}_i; \theta) \right] \right\}.$$

En notación funcional

$$T_q^\dagger(H_1, \dots, H_n) = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n E_{H_i} \left[ \log_q \tilde{f}_i(\mathbf{z}; \theta) \right] \right\}.$$

## Ecuación de estimación

$$\sum_{i=1}^n \mathbf{u}_i^\dagger(\mathbf{Z}_i; \theta)$$

## EMLqV en el modelo de calibración comparativa

$$\hat{\theta}_q^\dagger = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q \left[ \tilde{f}_i(\mathbf{z}_i; \theta) \right] \right\}.$$

En notación funcional

$$T_q^\dagger(H_1, \dots, H_n) = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n E_{H_i} \left[ \log_q \tilde{f}_i(\mathbf{z}; \theta) \right] \right\}.$$

## Ecuación de estimación

$$\sum_{i=1}^n \mathbf{u}_i^\dagger(\mathbf{Z}_i; \theta) = \sum_{i=1}^n \tilde{f}_i(\mathbf{Z}_i; \theta)^{1-q} \tilde{\mathbf{u}}_i(\mathbf{Z}_i; \theta)$$

## EMLqV en el modelo de calibración comparativa

$$\hat{\theta}_q^\dagger = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q \left[ \tilde{f}_i(\mathbf{z}_i; \theta) \right] \right\}.$$

En notación funcional

$$T_q^\dagger(H_1, \dots, H_n) = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n E_{H_i} \left[ \log_q \tilde{f}_i(\mathbf{z}; \theta) \right] \right\}.$$

## Ecuación de estimación

$$\sum_{i=1}^n \mathbf{u}_i^\dagger(\mathbf{Z}_i; \theta) = \sum_{i=1}^n \tilde{f}_i(\mathbf{Z}_i; \theta)^{1-q} \tilde{\mathbf{u}}_i(\mathbf{Z}_i; \theta) = \mathbf{0},$$

## EMLqV en el modelo de calibración comparativa

$$\hat{\theta}_q^\dagger = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n \log_q \left[ \tilde{f}_i(\mathbf{z}_i; \theta) \right] \right\}.$$

En notación funcional

$$T_q^\dagger(H_1, \dots, H_n) = \operatorname{argmax}_{\theta \in \Theta} \left\{ \sum_{i=1}^n E_{H_i} \left[ \log_q \tilde{f}_i(\mathbf{z}; \theta) \right] \right\}.$$

## Ecuación de estimación

$$\sum_{i=1}^n \mathbf{u}_i^\dagger(\mathbf{Z}_i; \theta) = \sum_{i=1}^n \tilde{f}_i(\mathbf{Z}_i; \theta)^{1-q} \tilde{\mathbf{u}}_i(\mathbf{Z}_i; \theta) = \mathbf{0},$$

con  $\tilde{\mathbf{u}}_i = \frac{\partial}{\partial \theta} \log \tilde{f}_i$ .

# EMLqV de los parámetros incidentales

Asumimos la existencia de un único  $\theta_q^\dagger$ , independiente del índice  $i$ , tal que para todo  $i \in \mathbb{N}$

Asumimos la existencia de un único  $\theta_q^\dagger$ , independiente del índice  $i$ , tal que para todo  $i \in \mathbb{N}$

$$E_{G_i} \left[ \mathbf{u}_i^\dagger(\mathbf{Z}_i; \theta_q^\dagger) \right] = \mathbf{0}.$$

Asumimos la existencia de un único  $\theta_q^\dagger$ , independiente del índice  $i$ , tal que para todo  $i \in \mathbb{N}$

$$E_{G_i} \left[ \mathbf{u}_i^\dagger(\mathbf{Z}_i; \theta_q^\dagger) \right] = \mathbf{0}.$$

Bajo condiciones de regularidad

# EMLqV de los parámetros incidentales

- 1  $\hat{\theta}_q^\dagger$  converge en probabilidad a  $\theta_q^\dagger$ .

- 1  $\hat{\theta}_q^\dagger$  converge en probabilidad a  $\theta_q^\dagger$ .
- 2  $\hat{\theta}_q^\dagger$  es asintóticamente normal con media  $\theta_q^\dagger$  y matriz de covarianza asintótica  $\frac{1}{n} \mathbf{V}_n^\dagger(\theta_q^\dagger)$ ,

- 1  $\hat{\theta}_q^\dagger$  converge en probabilidad a  $\theta_q^\dagger$ .
- 2  $\hat{\theta}_q^\dagger$  es asintóticamente normal con media  $\theta_q^\dagger$  y matriz de covarianza asintótica  $\frac{1}{n} \mathbf{V}_n^\dagger(\theta_q^\dagger)$ , siendo

$$\mathbf{V}_n^\dagger(\theta) = \left[ \boldsymbol{\Psi}_n^\dagger(\theta) \right]^{-1} \boldsymbol{\Omega}_n^\dagger(\theta) \left[ \boldsymbol{\Psi}_n^\dagger(\theta)^t \right]^{-1},$$

- 1  $\hat{\theta}_q^\dagger$  converge en probabilidad a  $\theta_q^\dagger$ .
- 2  $\hat{\theta}_q^\dagger$  es asintóticamente normal con media  $\theta_q^\dagger$  y matriz de covarianza asintótica  $\frac{1}{n} \mathbf{V}_n^\dagger(\theta_q^\dagger)$ , siendo

$$\mathbf{V}_n^\dagger(\theta) = \left[ \boldsymbol{\Psi}_n^\dagger(\theta) \right]^{-1} \boldsymbol{\Omega}_n^\dagger(\theta) \left[ \boldsymbol{\Psi}_n^\dagger(\theta)^t \right]^{-1},$$

donde

$$\boldsymbol{\Omega}_n^\dagger(\theta) = \frac{1}{n} \sum_{i=1}^n E_{G_i} \left[ \mathbf{u}_i^\dagger(\mathbf{Z}_i; \theta) \mathbf{u}_i^\dagger(\mathbf{Z}_i; \theta)^t \right]$$

- 1  $\hat{\theta}_q^\dagger$  converge en probabilidad a  $\theta_q^\dagger$ .
- 2  $\hat{\theta}_q^\dagger$  es asintóticamente normal con media  $\theta_q^\dagger$  y matriz de covarianza asintótica  $\frac{1}{n} \mathbf{V}_n^\dagger(\theta_q^\dagger)$ , siendo

$$\mathbf{V}_n^\dagger(\theta) = \left[ \boldsymbol{\Psi}_n^\dagger(\theta) \right]^{-1} \boldsymbol{\Omega}_n^\dagger(\theta) \left[ \boldsymbol{\Psi}_n^\dagger(\theta)^t \right]^{-1},$$

donde

$$\boldsymbol{\Omega}_n^\dagger(\theta) = \frac{1}{n} \sum_{i=1}^n E_{G_i} \left[ \mathbf{u}_i^\dagger(\mathbf{Z}_i; \theta) \mathbf{u}_i^\dagger(\mathbf{Z}_i; \theta)^t \right]$$

y

$$\boldsymbol{\Psi}_n^\dagger(\theta) = \frac{1}{n} \sum_{i=1}^n E_{G_i} \left[ \mathbf{l}_i^\dagger(\mathbf{Z}_i; \theta) \right].$$

# EMLqV de los parámetros incidentales

Supongamos que estamos en la situación ideal en que cada  $g_i \in \mathcal{F}_{i,\theta}$ , es decir, existe  $\theta_0$  y  $\xi_1^0, \dots, \xi_n^0$  tales que  $g_i = f_{i,\theta_0}$ ,  $\forall i = 1, \dots, n$ .

Supongamos que estamos en la situación ideal en que cada  $g_i \in \mathcal{F}_{i,\theta}$ , es decir, existe  $\theta_0$  y  $\xi_1^0, \dots, \xi_n^0$  tales que  $g_i = f_{i,\theta_0}$ ,  $\forall i = 1, \dots, n$ . En este contexto se puede calcular  $\theta_q^\dagger$  y la matriz de covarianza asintótica, a saber

Supongamos que estamos en la situación ideal en que cada  $g_i \in \mathcal{F}_{i,\theta}$ , es decir, existe  $\theta_0$  y  $\xi_1^0, \dots, \xi_n^0$  tales que  $g_i = f_{i,\theta_0}$ ,  $\forall i = 1, \dots, n$ . En este contexto se puede calcular  $\theta_q^\dagger$  y la matriz de covarianza asintótica, a saber

$$\begin{cases} \alpha^\dagger = \alpha_0 \\ \beta^\dagger = \beta_0 \\ \phi^\dagger = k\phi_0 \end{cases}$$

Supongamos que estamos en la situación ideal en que cada  $\mathbf{g}_i \in \mathcal{F}_{i,\theta}$ , es decir, existe  $\theta_0$  y  $\xi_1^0, \dots, \xi_n^0$  tales que  $\mathbf{g}_i = f_{i,\theta_0}$ ,  $\forall i = 1, \dots, n$ . En este contexto se puede calcular  $\theta_q^\dagger$  y la matriz de covarianza asintótica, a saber

$$\begin{cases} \alpha^\dagger = \alpha_0 \\ \beta^\dagger = \beta_0 \\ \phi^\dagger = k\phi_0 \end{cases}$$

$$\frac{1}{n} \mathbf{V}_n^\dagger(\theta^\dagger) = \frac{\phi_0^2}{n} \left( \frac{a^{(1)}}{c^{(1)}} \right)^2 \frac{c^{(2)}}{a^{(2)}} \begin{pmatrix} \mathbf{K} \otimes \mathbf{B}^{-1} & \mathbf{0} \\ \mathbf{0} & \frac{4\phi^{\dagger 2} t}{(p+1)^2} \end{pmatrix}$$

# Función de influencia

# Función de influencia

Como  $T_q^\dagger$  es un  $M$ -estimador, la función de influencia al contaminar el dato  $i_0$  con una distribución degenerada con masa uno en el punto de contaminación  $\mathbf{t}_{i_0}$  toma la forma

Como  $T_q^\dagger$  es un  $M$ -estimador, la función de influencia al contaminar el dato  $i_0$  con una distribución degenerada con masa uno en el punto de contaminación  $\mathbf{t}_{i_0}$  toma la forma

$$IF(T_q^\dagger; \mathbf{t}_{i_0}; G_1, \dots, G_n) = -\frac{1}{n} \left[ \Psi_n(\theta_q^\dagger) \right]^{-1} \mathbf{u}_i^\dagger(\mathbf{t}_{i_0}, \theta_q^\dagger)$$

# Función de influencia

Como  $T_q^\dagger$  es un  $M$ -estimador, la función de influencia al contaminar el dato  $i_0$  con una distribución degenerada con masa uno en el punto de contaminación  $\mathbf{t}_{i_0}$  toma la forma

$$IF(T_q^\dagger; \mathbf{t}_{i_0}; G_1, \dots, G_n) = -\frac{1}{n} \left[ \Psi_n(\theta_q^\dagger) \right]^{-1} \mathbf{u}_i^\dagger(\mathbf{t}_{i_0}, \theta_q^\dagger)$$

En general no es acotada, pero para el modelo de calibración comparativa se observa que los puntos con residuos grandes (alejados del modelo) tienen muy poca influencia.

# Algunos estudios de simulación

## EFICIENCIA

## EFICIENCIA

$q$	1	0.99	0.98	0.95	0.90	0.85	0.80	0.75
$\text{ARE}(\hat{\beta}^\dagger)$	100	99.96	99.82	98.88	95.56	90.13	82.81	73.85
$\text{ARE}(\hat{\phi}^\dagger)$	100	99.91	99.64	97.78	91.35	81.45	69.13	55.64

**Table:** Eficiencia relativa asintótica de los estimadores de máxima  $L_q$ -verosimilitud  $\hat{\alpha}^\dagger$ ,  $\hat{\beta}^\dagger$  y  $\hat{\phi}^\dagger$  para varios valores de  $q$  ( $p = 2$ )

# Algunos estudios de simulación

## ROBUSTEZ

## ROBUSTEZ

Para explorar la estabilidad de los estimadores bajo contaminación consideramos el modelo de calibración comparativa con  $p = 2$ .

## ROBUSTEZ

Para explorar la estabilidad de los estimadores bajo contaminación consideramos el modelo de calibración comparativa con  $p = 2$ . Fijamos  $n = 50$ ,  $\alpha_0 = (0, 0)^t$ ,  $\beta_0 = (1, 1)^t$  y consideramos dos valores de  $\phi_0$  : 0.1 y 0.5.

## ROBUSTEZ

Para explorar la estabilidad de los estimadores bajo contaminación consideramos el modelo de calibración comparativa con  $p = 2$ . Fijamos  $n = 50$ ,  $\alpha_0 = (0, 0)^t$ ,  $\beta_0 = (1, 1)^t$  y consideramos dos valores de  $\phi_0$  : 0.1 y 0.5. Vamos a considerar solo contaminaciones en la variable  $x_i$  (o  $U_i$ ), de manera que  $\mathbf{e}_i \sim N_2(\mathbf{0}, \phi_0 \mathbf{Id}_2)$ .

## ROBUSTEZ

Para explorar la estabilidad de los estimadores bajo contaminación consideramos el modelo de calibración comparativa con  $p = 2$ . Fijamos  $n = 50$ ,  $\alpha_0 = (0, 0)^t$ ,  $\beta_0 = (1, 1)^t$  y consideramos dos valores de  $\phi_0$  : 0.1 y 0.5. Vamos a considerar solo contaminaciones en la variable  $x_i$  (o  $U_i$ ), de manera que  $\mathbf{e}_i \sim N_2(\mathbf{0}, \phi_0 \mathbf{Id}_2)$ .

①  $U_i \sim N(0, 1)$ .

## ROBUSTEZ

Para explorar la estabilidad de los estimadores bajo contaminación consideramos el modelo de calibración comparativa con  $p = 2$ . Fijamos  $n = 50$ ,  $\alpha_0 = (0, 0)^t$ ,  $\beta_0 = (1, 1)^t$  y consideramos dos valores de  $\phi_0$  : 0.1 y 0.5. Vamos a considerar solo contaminaciones en la variable  $x_i$  (o  $U_i$ ), de manera que  $\mathbf{e}_i \sim N_2(\mathbf{0}, \phi_0 \mathbf{Id}_2)$ .

- 1  $U_i \sim N(0, 1)$ . Este esquema representa el caso de un modelo puro.

## ROBUSTEZ

Para explorar la estabilidad de los estimadores bajo contaminación consideramos el modelo de calibración comparativa con  $p = 2$ . Fijamos  $n = 50$ ,  $\alpha_0 = (0, 0)^t$ ,  $\beta_0 = (1, 1)^t$  y consideramos dos valores de  $\phi_0$  : 0.1 y 0.5. Vamos a considerar solo contaminaciones en la variable  $x_i$  (o  $U_i$ ), de manera que  $\mathbf{e}_i \sim N_2(\mathbf{0}, \phi_0 \mathbf{Id}_2)$ .

- 1  $U_i \sim N(0, 1)$ . Este esquema representa el caso de un modelo puro.
- 2  $U_i \sim (1 - \epsilon)N(0, \phi_0) + \epsilon N(2, \phi_0)$

## ROBUSTEZ

Para explorar la estabilidad de los estimadores bajo contaminación consideramos el modelo de calibración comparativa con  $p = 2$ . Fijamos  $n = 50$ ,  $\alpha_0 = (0, 0)^t$ ,  $\beta_0 = (1, 1)^t$  y consideramos dos valores de  $\phi_0$  : 0.1 y 0.5. Vamos a considerar solo contaminaciones en la variable  $x_i$  (o  $U_i$ ), de manera que  $\mathbf{e}_i \sim N_2(\mathbf{0}, \phi_0 \mathbf{Id}_2)$ .

- 1  $U_i \sim N(0, 1)$ . Este esquema representa el caso de un modelo puro.
- 2  $U_i \sim (1 - \epsilon)N(0, \phi_0) + \epsilon N(2, \phi_0)$  , donde  $\epsilon$  es el porcentaje de contaminación.

## ROBUSTEZ

Para explorar la estabilidad de los estimadores bajo contaminación consideramos el modelo de calibración comparativa con  $p = 2$ . Fijamos  $n = 50$ ,  $\alpha_0 = (0, 0)^t$ ,  $\beta_0 = (1, 1)^t$  y consideramos dos valores de  $\phi_0$  : 0.1 y 0.5. Vamos a considerar solo contaminaciones en la variable  $x_i$  (o  $U_i$ ), de manera que  $\mathbf{e}_i \sim N_2(\mathbf{0}, \phi_0 \mathbf{Id}_2)$ .

- 1  $U_i \sim N(0, 1)$ . Este esquema representa el caso de un modelo puro.
- 2  $U_i \sim (1 - \epsilon)N(0, \phi_0) + \epsilon N(2, \phi_0)$  , donde  $\epsilon$  es el porcentaje de contaminación.

Usamos 1000 replicaciones para estimar sesgo y MSE (error cuadrático medio) de los estimadores.

## ROBUSTEZ

Para explorar la estabilidad de los estimadores bajo contaminación consideramos el modelo de calibración comparativa con  $p = 2$ . Fijamos  $n = 50$ ,  $\alpha_0 = (0, 0)^t$ ,  $\beta_0 = (1, 1)^t$  y consideramos dos valores de  $\phi_0$  : 0.1 y 0.5. Vamos a considerar solo contaminaciones en la variable  $x_i$  (o  $U_i$ ), de manera que  $\mathbf{e}_i \sim N_2(\mathbf{0}, \phi_0 \mathbf{Id}_2)$ .

- 1  $U_i \sim N(0, 1)$ . Este esquema representa el caso de un modelo puro.
- 2  $U_i \sim (1 - \epsilon)N(0, \phi_0) + \epsilon N(2, \phi_0)$ , donde  $\epsilon$  es el porcentaje de contaminación.

Usamos 1000 replicaciones para estimar sesgo y MSE (error cuadrático medio) de los estimadores. Consideramos  $\epsilon = 0, 0.05, 0.10, 0.15$  y  $0.20$  y valores de  $q = 0.75, 0.8, 0.85, 0.9, 0.95$  y  $1$ .

# Algunos estudios de simulación

$\phi_0$	$\epsilon$	$q$					
		1	0.95	0.90	0.85	0.80	0.75
0.1	0	<b>0.0168</b>	0.0171	0.0179	0.0192	0.0214	0.0249
	0.05	0.0581	0.0351	0.0234	<b>0.0215</b>	0.0227	0.0263
	0.10	0.1363	0.0877	0.0459	0.0271	<b>0.0252</b>	0.0290
	0.15	0.2436	0.1812	0.1084	0.0519	<b>0.0316</b>	0.0339
	0.20	0.3620	0.2967	0.2128	0.1163	0.0643	<b>0.0538</b>
0.5	0	<b>0.1007</b>	0.1025	0.1072	0.1155	0.1299	0.1595
	0.05	0.1339	0.1294	<b>0.1286</b>	0.1328	0.1442	0.1680
	0.10	0.2081	0.1936	0.1833	<b>0.1797</b>	0.1854	0.2057
	0.15	0.3113	0.2899	0.2716	0.2590	<b>0.2573</b>	0.2843
	0.20	0.4316	0.4072	0.3846	0.3663	<b>0.3560</b>	0.3643

Table: MSE simulado para el estimador de máxima  $L_q$ -verosimilitud  $\hat{\theta}_q^\dagger$

# Algunos estudios de simulación

Del análisis de la tabla anterior surge que:

Del análisis de la tabla anterior surge que:

- 1 Para cualquier nivel de contaminación  $\epsilon$  fijo y valor de  $q$  fijo, el MSE crece cuando la varianza del error de medición  $\phi_0$  crece.

Del análisis de la tabla anterior surge que:

- 1 Para cualquier nivel de contaminación  $\epsilon$  fijo y valor de  $q$  fijo, el MSE crece cuando la varianza del error de medición  $\phi_0$  crece.
- 2 Bajo el modelo puro ( $\epsilon = 0$ ), el EMV es el más eficiente (el mínimo MSE se da para  $q = 1$ ), como se esperaba.

Del análisis de la tabla anterior surge que:

- 1 Para cualquier nivel de contaminación  $\epsilon$  fijo y valor de  $q$  fijo, el MSE crece cuando la varianza del error de medición  $\phi_0$  crece.
- 2 Bajo el modelo puro ( $\epsilon = 0$ ), el EMV es el más eficiente (el mínimo MSE se da para  $q = 1$ ), como se esperaba.
- 3 Para  $\phi_0$  fijo, a medida que aumenta el nivel de contaminación decrece el valor de  $q$  para el cual MSE es mínimo.

Del análisis de la tabla anterior surge que:

- 1 Para cualquier nivel de contaminación  $\epsilon$  fijo y valor de  $q$  fijo, el MSE crece cuando la varianza del error de medición  $\phi_0$  crece.
- 2 Bajo el modelo puro ( $\epsilon = 0$ ), el EMV es el más eficiente (el mínimo MSE se da para  $q = 1$ ), como se esperaba.
- 3 Para  $\phi_0$  fijo, a medida que aumenta el nivel de contaminación decrece el valor de  $q$  para el cual MSE es mínimo.
- 4 Para un nivel de contaminación  $\epsilon$  fijo, el valor de  $q$  para el cual MSE es mínimo aumenta o permanece igual cuando  $\phi_0$  aumenta. Es decir, el valor de  $q$  que minimiza el MSE es una función no decreciente de  $\phi_0$ .

# Algunos estudios de simulación

La siguiente tabla muestra los valores de  $q$  que minimizan el error cuadrático medio (MSE) para distintos valores de  $\phi_0$  y niveles de contaminación  $\epsilon$ .

La siguiente tabla muestra los valores de  $q$  que minimizan el error cuadrático medio (MSE) para distintos valores de  $\phi_0$  y niveles de contaminación  $\epsilon$ .

$\phi_0$	$\epsilon$			
	0.05	0.10	0.15	0.20
0.1	0.85	0.82	0.80	0.76
0.3	0.86	0.80	0.77	0.75
0.5	0.92	0.85	0.82	0.79
0.7	0.95	0.90	0.87	0.86

Table: Valores de  $q$  óptimo

La siguiente tabla muestra los valores de  $q$  que minimizan el error cuadrático medio (MSE) para distintos valores de  $\phi_0$  y niveles de contaminación  $\epsilon$ .

$\phi_0$	$\epsilon$			
	0.05	0.10	0.15	0.20
0.1	0.85	0.82	0.80	0.76
0.3	0.86	0.80	0.77	0.75
0.5	0.92	0.85	0.82	0.79
0.7	0.95	0.90	0.87	0.86

Table: Valores de  $q$  óptimo