

# Regresión No-paramétrica robusta

---

*Seminario del*

*Instituto de Matemática Aplicada del Litoral  
Mayo de 2010*

*Funcionales Robustos de Escala en  
Regresión No-paramétrica*

*por*

*Marcelo Ruiz*

*(UNRC)*

*en co-autoría con*

*Graciela Lina Boente (UBA-CONICET) y Ruben Zamar (University of British Columbia, Canadá)*

*(2008, Journal of Statistical Planning and Inference )*

---

---

# Sección A

El marco general. Preliminares.

# El modelo

Medimos  $x$  (posición) sin error en el intervalo  $[0, 1]$  y obtenemos una respuesta, aleatoria,  $Y_x$  (velocidad de una partícula).

Postulamos la relación

$$Y_x = g(x) + U_x \sigma(x), \quad i = 1, \dots, n,$$

donde  $U : (\Omega, \mathcal{A}, P) \rightarrow \mathbb{R}$  es el componente aleatorio (error) con

$$\mathbf{E}[U] = \int u dP(u) = 0 \text{ y } \mathbf{Var}[U] = \mathbf{E}[U - \mathbf{E}[U]]^2 = 1.$$

Así,

$$\mathbf{E}[Y_x] = g(x) \text{ y } \mathbf{Var}[Y_x] = \sigma^2(x)$$

$g$  es la función de regresión y  $\sigma(x)$  es la función de escala. Ambas desconocidas, satisfaciendo  $g \in \mathcal{G}$  y  $\sigma \in \Sigma$ , con  $\mathcal{G}$  y  $\Sigma$  clases de funciones suaves.

# El problema de estimación

Dadas  $n$  observaciones  $(x_1, Y_1) \dots (x_n, Y_n)$  y  $x \in (0, 1)$ , queremos hallar estimadores

$$\begin{aligned}\hat{g}_n(x, (x_1, Y_1) \dots (x_n, Y_n)) &= \hat{g}_n(x) \\ \hat{\sigma}_n(x, (x_1, Y_1) \dots (x_n, Y_n)) &= \hat{\sigma}_n(x)\end{aligned}$$

de  $g(x)$  y  $\sigma(x)$ , respectivamente.

Dos estrategias

- Estimación simultánea de regresión y escala, o
- Estimación preliminar de la escala



Optamos por la **segunda estrategia** y cuando la **función de escala es constante**.

# Comenzamos por lo más simple

Las funciones de regresión y de escala constantes y  $U_i \sim N(0, 1)$ :

$$Y_i = \mu_0 + U_i\sigma, \quad i = 1, \dots, n$$

Como

$$\frac{1}{(n-1)} \sum_{i=1}^{n-1} \left( \frac{U_{i+1} - U_i}{\sqrt{2}} \right)^2 \xrightarrow{a.s.} \mathbf{E} \left( \frac{U_2 - U_1}{\sqrt{2}} \right)^2 = 1$$

Entonces

$$\frac{1}{(n-1)} \sum_{i=1}^{n-1} \left( \frac{Y_{i+1} - Y_i}{\sqrt{2}} \right)^2 \approx \sigma^2$$

# Estimador de Rice

El siguiente será el modelo del resto de la exposición

$$Y_i = g(x_i) + U_i\sigma, \quad i = 1, \dots, n$$

entonces

$$Y_{i+1} - Y_i = (g(x_{i+1}) - g(x_i)) + \sigma(U_{i+1} - U_i) \approx \sigma(U_{i+1} - U_i)$$

luego si  $U_i \sim F_0 = N(0, 1)$  el estimador de Rice de la varianza

$$\begin{aligned}\hat{\sigma}_{R,n}^2 &= \frac{1}{(n-1)} \sum_{i=1}^{n-1} \left( \frac{Y_{i+1} - Y_i}{\sqrt{2}} \right)^2 \\ &\approx \sigma^2 \frac{1}{(n-1)} \sum_{i=1}^{n-1} \left( \frac{U_{i+1} - U_i}{\sqrt{2}} \right)^2 \\ &\approx \sigma^2\end{aligned}$$

# Falta de robustez de los estimadores tipo Rice

Si  $\exists i_0 : Y_{i_0} \rightarrow \infty$  entonces  $\hat{\sigma}_{R,n}^2 \rightarrow \infty$

Es decir, frente a observaciones atípicas el estimador basado en el cuadrado de las diferencias se quiebra.

Las observaciones son atípicas (outliers o inliers) cuando

$$U \sim G \neq F_0 \text{ y } G \in \mathcal{P}_\epsilon(F_0),$$

un entorno de contaminación de tamaño  $\epsilon$ :

$$\mathcal{P}_\epsilon(F_0) = \{G : G = (1 - \epsilon)F_0 + \epsilon H; H \in \mathcal{D}\}$$

con  $\mathcal{D}$  la colección de distribuciones sobre  $\mathbb{R}$ ,  $\epsilon \in [0, 1/2)$  fijo.

# Estimadores como solución de ecuaciones

$\hat{\sigma}_{R,n}$  es solución de la ecuación no lineal

$$\frac{1}{n-1} \sum_{i=1}^{n-1} \chi \left( \frac{Y_{i+1} - Y_i}{a \hat{\sigma}_{R,n}} \right) = b,$$

con  $\chi(x) = x^2$  y las constantes  $a = \sqrt{2}$  y  $b = 1/2$  satisfacen las condiciones

$$(C.A.) \quad E \left[ \chi \left( \frac{Z_2 - Z_1}{a} \right) \right] = b \text{ y } E [\chi(Z_1)] = b,$$

$Z_1, Z_2$  v.a.'s i.i.d con  $Z_1 \sim N(0, 1)$ .

## *M*–estimadores

Para estimar robustamente la escala en el modelo homoscedástico

$$Y_i = g(x_i) + \sigma U_i, \quad i = 1, \dots, n.$$

con  $U_i \sim G \in \mathcal{P}_\epsilon(F_0)$

👉 Nuestra propuesta:

*M*–estimadores de escala basados en las diferencias sucesivas de las respuestas

$$\hat{\sigma}_{M,n} = \inf \left\{ s > 0 : \frac{1}{n-1} \sum_{i=1}^{n-1} \chi \left( \frac{Y_i^*}{as} \right) \leq b \right\}$$

con  $\{Y_i^* = Y_{i+1} - Y_i\}_{i=1}^{n-1} \dots$

## ... $M$ -estimadores

siendo

- $\chi$  una función de escores: par,  $\chi(0) = 0$ , no decreciente en  $\mathbb{R}^+$ , con  $0 < \|\chi\|_\infty$ ;
- $a \in (0, \infty)$  y  $b \in (0, 1)$  constantes tales que

$$E[\chi(Z_1)] = b \quad \text{y} \quad E\left[\chi\left(\frac{Z_1^*}{a}\right)\right] = b,$$

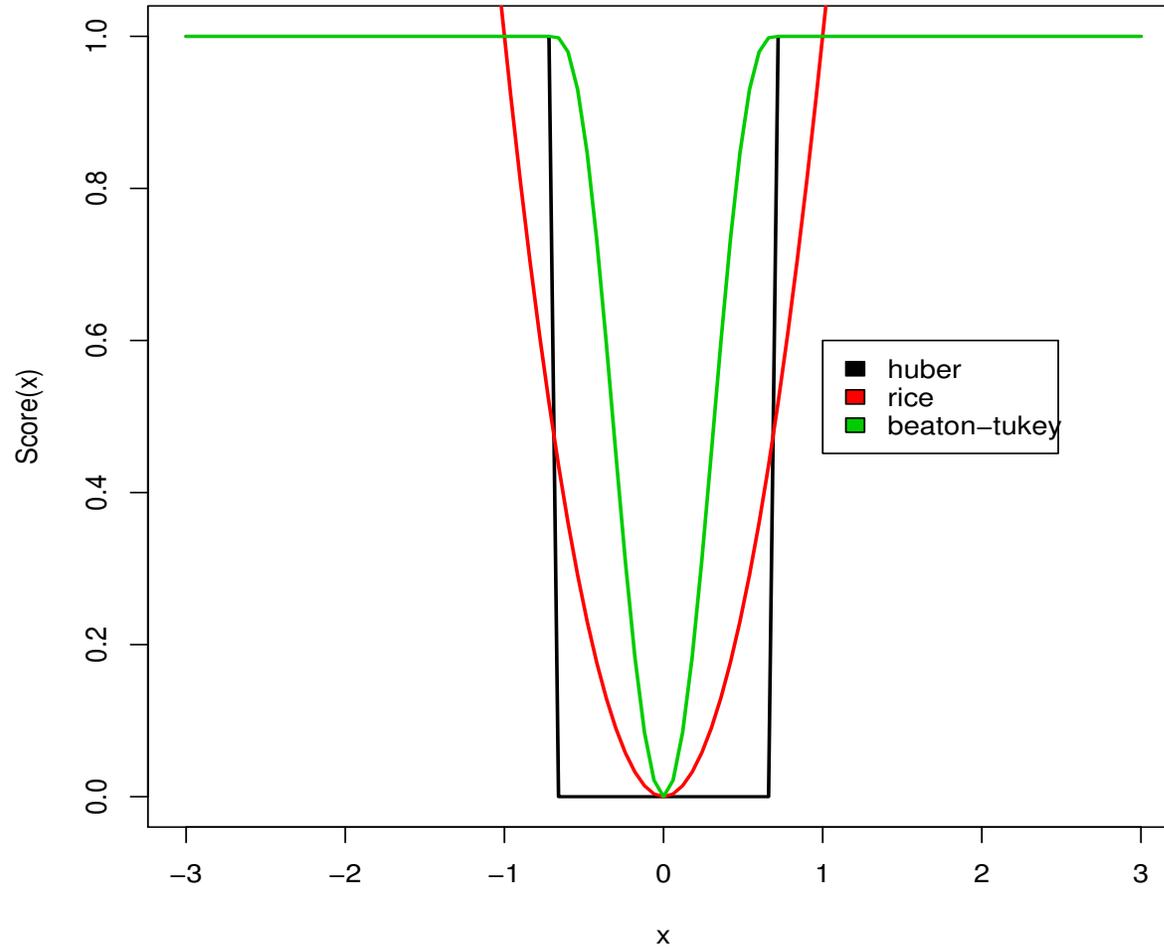
$Z_1^* = Z_2 - Z_1$ ,  $\{Z_i\}_{i=1,2}$  v.a.'s i.i.d. con  $Z_1 \sim F_0$ .

**Nota:** Bajo ciertas condiciones sobre  $\chi$ ,  $\hat{\sigma}_{M,n}$  es la única solución positiva de

$$\frac{1}{n-1} \sum_{i=1}^{n-1} \chi\left(\frac{Y_i^*}{as}\right) = b.$$

# Escores

Ejemplos típicos de funciones de escores



# Ejemplos

- “Estimador de Rice”.

$$\chi(x) = x^2, b = 1 \text{ y } a = \sqrt{2}$$

$$\hat{\sigma}_{R,n} = \left( \frac{1}{2(n-1)} \sum_{i=1}^{n-1} (Y_i^*)^2 \right)^{1/2},$$

- “Estimador de Boente, Fraiman y Meloche”.

$$\chi(x) = I_{\{y: |y| > \Phi^{-1}(3/4)\}}(x), b = 1/2 \text{ y } a = \sqrt{2}$$

$$\hat{\sigma}_{MAD,n} = \frac{q_{1/2}}{\sqrt{2}\Phi^{-1}(3/4)}$$

## ... Ejemplos

- “Estimador primer cuartil”.

$$\chi(x) = I_{\{y: |y| > \Phi^{-1}(5/8)\}}(x), \quad b = 3/4 \text{ y } a = \sqrt{2}$$

$$\hat{\sigma}_{\text{PC},n} = \frac{q_{1/4}}{\sqrt{2}\Phi^{-1}(5/8)},$$

- “ $M$ –estimador con función de Beaton-Tukey”,  $\hat{\sigma}_{\text{BT},n}$ .

$$\chi(x) = \chi_c(x) = \begin{cases} 3(x/c)^2 - 3(x/c)^4 + (x/c)^6 & \text{si } |x| \leq c \\ 1 & \text{si } |x| > c \end{cases}$$

con  $c = 0.70417$ ,  $b = 3/4$  y  $a = \sqrt{2}$ .

# $M$ –funcionales de escala

Huber (en el 64) define el  $M$ – funcional de escala,

$$S : \mathcal{D} \longrightarrow \mathbb{R}_0^+,$$

como

$$S(F) = \inf \left\{ s > 0 : E \left[ \chi \left( \frac{X}{as} \right) \right] \leq b \right\}.$$

Bajo ciertas condiciones sobre la función de escores,  $\chi$ ,

$S(F)$  es la única solución positiva de  $E \left[ \chi \left( \frac{X}{as} \right) \right] = b$ .

## ... $M$ –funcionales de escala

En nuestro problema,  $S$  opera sobre convoluciones de las distribuciones de los errores:

si  $U_i \sim G$  y  $G \in \mathcal{P}_\epsilon(F_0)$  consideramos  $S(G_\sigma^*)$  donde  $G_\sigma^*$  es la f.d. de  $\sigma U_1^* = \sigma(U_2 - U_1)$ .

Observar que:

✓ **Consistencia Fisher:**  $\forall \sigma > 0, S(F_{0,\sigma}^*) = \sigma$ .

✓ **Equivariancia a transformaciones de escala:**

$$\forall \sigma > 0 : S(G_\sigma^*) = \sigma S(G^*).$$

✓ Si  $F_n(y) = \frac{1}{n-1} \sum_{i=1}^{n-1} I_{(-\infty, y]}(Y_i^*)$ ,  $S(F_n) = \hat{\sigma}_{M,n}$ .

# Consistencia fuerte y normalidad asintótica

**Teorema:** Bajo las hipótesis

➔  $\chi$  es continua, acotada con  $\|\chi\|_\infty = 1$ , par,  $\chi(0) = 0$  y estrictamente creciente sobre el conjunto  $\{x : 0 < \chi(x) < 1\}$ .

➔  $M_n = \max_{1 \leq i \leq n-1} (x_{i+1} - x_i) \rightarrow 0$ .

➔ La función de regresión,  $g$ , es continua.

la sucesión de  $M$ -estimadores converge casi seguramente al valor del funcional en  $G_\sigma^*$ , es decir

$$\forall G \in \mathcal{P}_\epsilon(F_0) : S(F_n) = \hat{\sigma}_{M,n} \xrightarrow{c.s.} S(G_\sigma^*).$$

# Normalidad asintótica

**Teorema:** Si son válidas las hipótesis **H.1.**,  
**H.4.** Continuidad Lipschitz de  $g$ .

**H.6.**  $M_n = \max_{1 \leq i \leq n-1} |x_{i+1} - x_i| = O(n^{-1})$ , y

**H.7.**  $\chi$  es de clase  $C^2$  y las funciones  $\chi_1(u) = u\chi'(u)$  y  
 $\chi_2(u) = u^2\chi''(u)$  están acotadas.

**entonces**

$$n^{1/2} (\hat{\sigma}_{M,n} - S(G_\sigma^*)) \xrightarrow{d} N(0, v),$$

donde...

## ... Normalidad asintótica

... la **varianza asintótica** es  $v = v_1/v_2^2$ , siendo

$$v_1 = \text{Var} \left[ \chi \left( \frac{\sigma U_1^*}{aS(G_\sigma^*)} \right) \right] + 2 \text{Cov} \left[ \chi \left( \frac{\sigma U_1^*}{aS(G_\sigma^*)} \right), \chi \left( \frac{\sigma U_2^*}{aS(G_\sigma^*)} \right) \right]$$

$$v_2 = E \left[ \chi' \left( \frac{\sigma U_1^*}{aS(G_\sigma^*)} \right) \left( \frac{\sigma U_1^*}{a(S(G_\sigma^*))^2} \right) \right].$$

# Sección B

## Sesgo Máximo y Punto de Ruptura

# Robustez: Sesgo Máximo

En ausencia de contaminación ( $\epsilon = 0$ ) estimamos asintóticamente sin sesgo:

$$S(G_\sigma^*) = \sigma \text{ si } G = F_0$$

Cuando hay contaminación en los datos ( $\epsilon > 0$ ), en general,  $\{\hat{\sigma}_{M,n}\}_{n \geq 1}$  es asintóticamente sesgado

$$S(G_\sigma^*) \neq \sigma \text{ si } G \neq F_0$$

# Robustez: Sesgo Máximo

¿Cómo cuantificamos el sesgo?

☞ Sesgo Asintótico:

$$B(S(G_\sigma^*)) = (S(G_\sigma^*)/\sigma) - 1.$$

☞ Sesgo Asintótico Generalizado (podemos pesar inliers y outliers de forma diferencial):

$$B_g(S(G_\sigma^*)) = \begin{cases} L_1 \left( \frac{S(G_\sigma^*)}{\sigma} \right), & \text{si } 0 < S(G_\sigma^*) \leq \sigma, \\ L_2 \left( \frac{S(G_\sigma^*)}{\sigma} \right), & \text{si } \sigma < S(G_\sigma^*) < +\infty. \end{cases}$$

# Robustez: Sesgo Máximo

Para cuantificar robustez necesitamos mirar en  $\mathcal{P}_\epsilon(F_0)$



Máximo sesgo asintótico generalizado

$$\bar{B}_g(\epsilon) = \sup_{G \in \mathcal{P}_\epsilon(F_0)} B_g(S(G_\sigma^*)).$$

Por la equivariancia del funcional  $S(\cdot)$

$$\bar{B}_g(\epsilon) = \sup_{G \in \mathcal{P}_\epsilon(F_0)} B_g(S(G_\sigma^*)) = \sup_{G \in \mathcal{P}_\epsilon(F_0)} B_g(S(G^*)).$$



Asumimos que  $\sigma = 1$ .

# Robustez: Sesgo Máximo

¿Cuál es la **relación** entre **robustez** y **máximo sesgo asintótico** (generalizado)?

La sucesión de  $M$ -estimadores,  $\{\hat{\sigma}_{M,n}\}_{n \geq 1}$ , **es asintóticamente robusta** si

$$\exists \epsilon \in (0, 1/2] : \bar{B}_g(\epsilon) < \infty$$

## ... Robustez: Sesgo Máximo

Por la equivariancia del  $M$ -funcional y por la monotonía de  $L_1$  y  $L_2$  se deduce que

$$\bar{B}_g(\epsilon) = \text{máx} \left\{ L_1 \left( \inf_{G \in \mathcal{P}_\epsilon(F_0)} S(G^*) \right), L_2 \left( \sup_{G \in \mathcal{P}_\epsilon(F_0)} S(G^*) \right) \right\}$$

Se determina  $\epsilon$  tal que

$$\inf_{G \in \mathcal{P}_\epsilon(F_0)} S(G^*) > 0 \text{ y } \sup_{G \in \mathcal{P}_\epsilon(F_0)} S(G^*) < \infty$$

# Robustez: condiciones de finitud del $\overline{B}_g(\epsilon)$

La constante de ajuste  $b$  determina la robustez de los  $M$ -estimadores:

**Teorema.** Asumamos H.1.,

**H.8.**  $H \in \mathcal{D}_0$  la colección de las f.d. absolutamente continuas.

**H.9.**  $F_0$  posee densidad estrictamente positiva, unimodal y simétrica.

Entonces  $\overline{B}_g(\epsilon) < \infty$

- ✓ para  $b = 3/4$  si  $\epsilon < 1/2$ ;
- ✓ para  $b \in (0, 3/4)$  si  $\epsilon < 1 - \sqrt{1 - b}$ ;
- ✓ para  $b \in (3/4, 1)$  si  $\epsilon < \sqrt{1 - b}$ .

# Robustez: punto de ruptura asintótico

El punto de ruptura asintótico de  $\{\hat{\sigma}_{M,n}\}_{n \geq 1}$

$$\epsilon^* = \epsilon^*(\{\hat{\sigma}_{M,n}\}_{n \geq 1}) = \inf \{ \epsilon \in (0, 1/2] : \bar{B}_g(\epsilon) = \infty \}.$$

**Teorema.**  $\epsilon^*(\{\hat{\sigma}_{M,n}\}_{n \geq 1})$  satisface

- ✓ Si  $b = 3/4$ , entonces  $\epsilon^* = 1/2$ .
- ✓ Si  $b \in (0, 3/4)$ , entonces  $\epsilon^* = 1 - \sqrt{1 - b}$ .
- ✓ Si  $b \in (3/4, 1)$ , entonces  $\epsilon^* = \sqrt{1 - b}$ .



El máximo punto de ruptura asintótico que puede ser alcanzado, cuando  $b$  varía en el  $(0, 1)$ , es  $\epsilon_{opt}^* = 1/2$  y se alcanza en  $b = 3/4$ .

# Robustez: observaciones

- ✓  $\epsilon^*$  se considera bajo el **modelo de contaminaciones independientes**.
- ✓ La Hipótesis **H.8.** no es muy restrictiva.
- ✓ Para los estimadores introducidos en los ejemplos:

$$\epsilon^*(\{\hat{\sigma}_{R,n}\}_{n \geq 1}) = 0, \quad \epsilon^*(\{\hat{\sigma}_{MAD,n}\}_{n \geq 1}) \approx 0.29$$

$$\epsilon^*(\{\hat{\sigma}_{PC,n}\}_{n \geq 1}) \approx 1/2, \quad \epsilon^*(\{\hat{\sigma}_{BT,n}\}_{n \geq 1}) = 1/2.$$

# Sección C

## El funcional para muestras finitas

# Simulación Monte Carlo: objetivos

Evaluación del comportamiento de los estimadores

$$\hat{\sigma}_{R,n}, \hat{\sigma}_{MAD,n}, \hat{\sigma}_{PC,n} \text{ y } \hat{\sigma}_{BT,n}$$

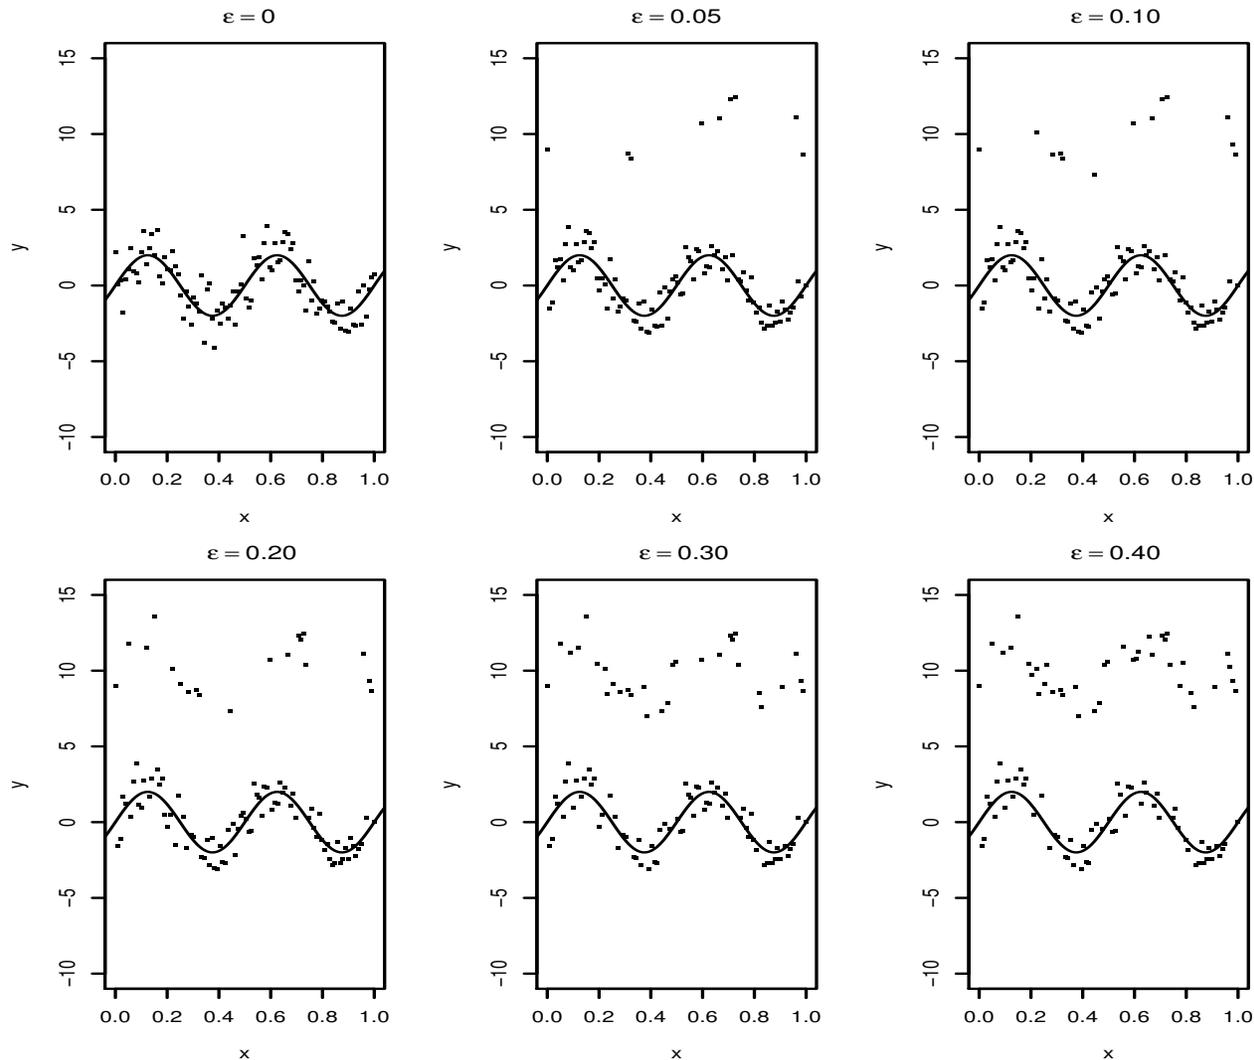


Objetivos

- ✓ Investigar las propiedades de **eficiencia** cuando  $\epsilon = 0$ .
- ✓ Comparar los **errores cuadráticos medios (E.C.M.) estimados** en presencia de outliers.
- ✓ Estudiar si el **incremento de E.C.M.** puede atribuirse al **sesgo y/o la varianza**.

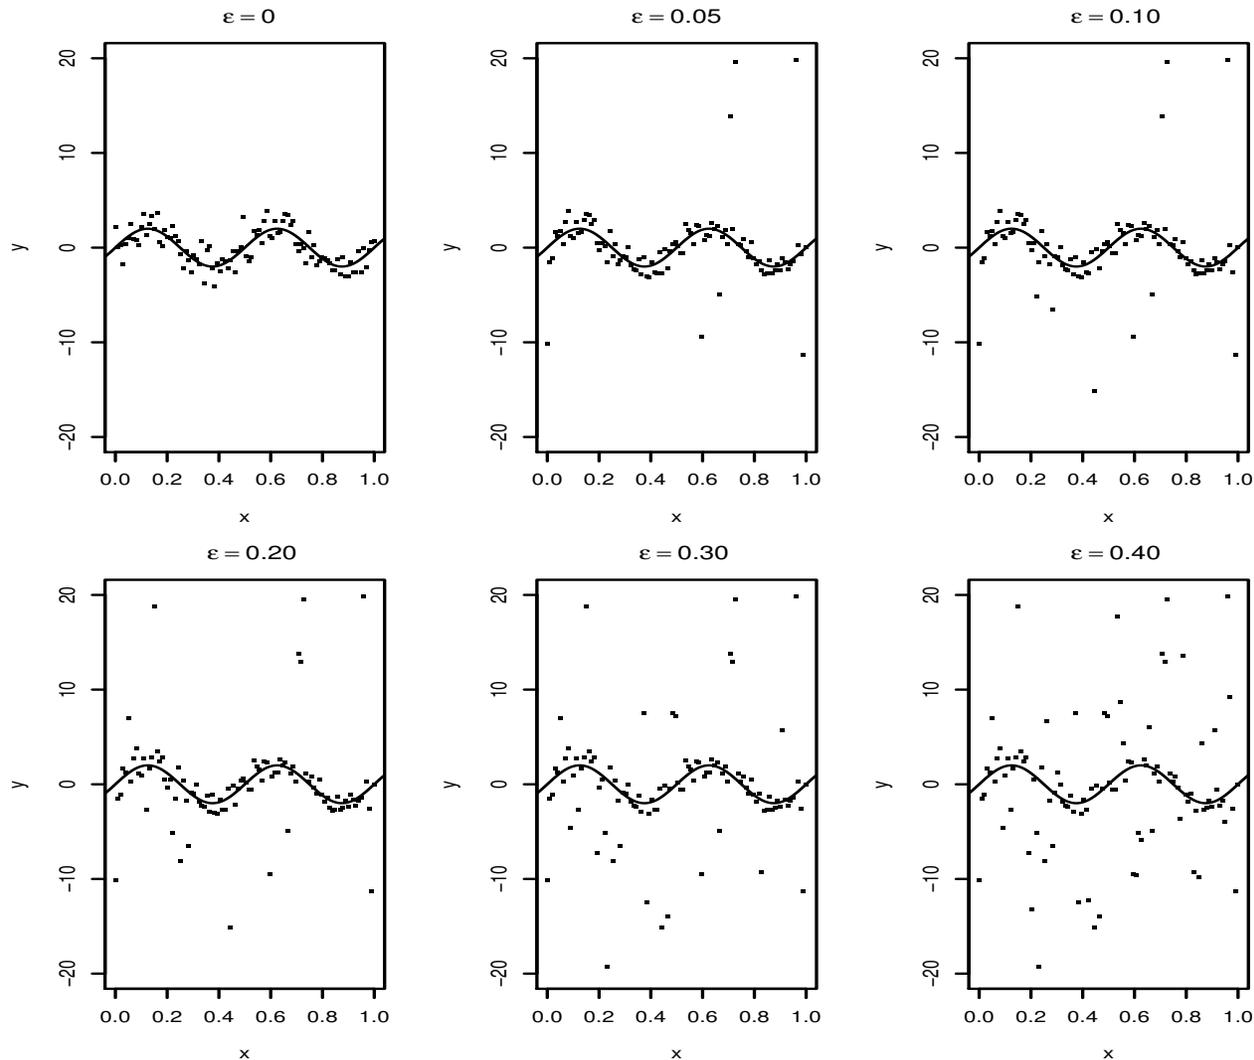
# Simulación Monte Carlo: gráficos de modelos

Valores de las respuestas versus puntos del diseño para  $g(x) = \text{sen}(4\pi x)$ ,  $\sigma \equiv 1$ . La curva corresponde al gráfico de la función  $g$ . Modelo central  $F_0 = N(0, 1)$  y contaminación asimétrica  $H = N(10, 1)$ .



# Simulación Monte Carlo: gráficos de modelos

Valores de las respuestas versus puntos del diseño para  $g(x) = \text{sen}(4\pi x)$ ,  $\sigma \equiv 1$ . La curva corresponde al gráfico de la función  $g$ .  
Modelo central  $F_0 = N(0, 1)$  y contaminación simétrica  $H = N(0, 10)$ .



# Simulación Monte Carlo: Eficiencia estimada y exacta

Eficiencias de  $\hat{\sigma}_{\text{MAD},n}$ ,  $\hat{\sigma}_{\text{PC},n}$  y  $\hat{\sigma}_{\text{BT},n}$  relativas a  $\hat{\sigma}_{\text{R},n}$  con  $\epsilon = 0$ .

$n$	E.R. $(\hat{\sigma}_{\text{MAD},n}, \hat{\sigma}_{\text{R},n})$	E.R. $(\hat{\sigma}_{\text{PC},n}, \hat{\sigma}_{\text{R},n})$	E.R. $(\hat{\sigma}_{\text{BT},n}, \hat{\sigma}_{\text{R},n})$
20	0.350	0.139	0.200
50	0.426	0.192	0.276
100	0.451	0.206	0.286
Asintótica	0.454	0.214	0.297

# Simulación Monte Carlo: E.C.M.

Estimador	$\epsilon = 0.05$	$\epsilon = 0.10$	$\epsilon = 0.20$	$\epsilon = 0.30$
$H = N(0, 10)$				
$\hat{\sigma}_{R,n}$	2.319	5.452	12.78	20.770
$\hat{\sigma}_{MAD,n}$	0.038	0.100	0.485	2.106
$\hat{\sigma}_{PC,n}$	0.063	0.118	0.382	1.050
$\hat{\sigma}_{BT,n}$	0.047	0.098	0.356	1.055
$H = N(10, 1)$				
$\hat{\sigma}_{R,n}$	2.037	4.703	9.778	13.670
$\hat{\sigma}_{MAD,n}$	0.045	0.126	0.668	5.461
$\hat{\sigma}_{PC,n}$	0.069	0.135	0.412	0.897
$\hat{\sigma}_{BT,n}$	0.052	0.115	0.393	0.913
$H(y) = \Delta_{10}(y)$				
$\hat{\sigma}_{R,n}$	1.813	5.032	12.450	20.460
$\hat{\sigma}_{MAD,n}$	0.039	0.126	1.130	71.250
$\hat{\sigma}_{PC,n}$	0.063	0.138	0.668	3.576
$\hat{\sigma}_{BT,n}$	0.047	0.117	0.657	4.165

# Simulación Monte Carlo: análisis y conclusiones.

Conclusiones a partir del  $\widehat{\text{E.C.M.}}$ :

- ✓ Bajo contaminación,  $\hat{\sigma}_{R,n}$  tiene el peor desempeño.
- ✓ Para bajos niveles de  $\epsilon$ ,  $\hat{\sigma}_{\text{MAD},n}$  es ligeramente mejor que sus competidores robustos.
- ✓ Si  $\epsilon$  aumenta  $\hat{\sigma}_{\text{PC},n}$  y  $\hat{\sigma}_{\text{BT},n}$  se comportan
  - mejor que  $\hat{\sigma}_{\text{MAD},n}$  para contaminaciones simétricas.
  - sustancialmente mejor que  $\hat{\sigma}_{\text{MAD},n}$  para contaminaciones asimétricas e intercaladas.
- ✓ Para contaminaciones intercaladas todos los estimadores se deterioran a partir de  $\epsilon = 0.25$ .