

# Predicciones usando distorsiones bivariates y regresión cuantílica

Jorge Navarro<sup>1</sup>  
Universidad de Murcia, Murcia, Spain.



---

<sup>1</sup>Supported by Ministerio de Ciencia e Innovación of Spain under grant PID2019-108079GB-C22/AEI/10.13039/501100011033.

# Referencias

- ▶ La conferencia se basa en el artículo:

# Referencias

- ▶ La conferencia se basa en el artículo:
- ▶ Navarro J, Calì C, Longobardi M, Durante F (2022). Distortion Representations of Multivariate Distributions. Statistical Methods & Applications. Published online first Jan. 2022. DOI: 10.1007/s10260-021-00613-2.

# Outline

## Distribuciones distorsionadas

Univariantes

Multivariantes

Regresión cuantílica

## Ejemplos

Ejemplos

Datos pareados

Predicciones

# Distribuciones distorsionadas

# Notación

- ▶  $X$  variable aleatoria (tiempo de vida) sobre  $(\Omega, \mathcal{S}, \Pr)$ .

# Notación

- ▶  $X$  variable aleatoria (tiempo de vida) sobre  $(\Omega, \mathcal{S}, \Pr)$ .
- ▶ Función de distribución  $F(t) = \Pr(X \leq t)$ .

## Notación

- ▶  $X$  variable aleatoria (tiempo de vida) sobre  $(\Omega, \mathcal{S}, \Pr)$ .
- ▶ Función de distribución  $F(t) = \Pr(X \leq t)$ .
- ▶ Función de fiabilidad o supervivencia  
 $\bar{F}(t) = \Pr(X > t) = 1 - F(t)$ .

## Notación

- ▶  $X$  variable aleatoria (tiempo de vida) sobre  $(\Omega, \mathcal{S}, \Pr)$ .
- ▶ Función de distribución  $F(t) = \Pr(X \leq t)$ .
- ▶ Función de fiabilidad o supervivencia  
 $\bar{F}(t) = \Pr(X > t) = 1 - F(t)$ .
- ▶ Función de densidad (PDF)  $f(t) = F'(t) = -\bar{F}'(t)$ .

## Distribuciones distorsionadas univariantes

- ▶ Las distribuciones distorsionadas univariantes fueron introducidas por Wang (1996) y Yaari (1987) en el contexto de la teoría de decisión bajo riesgos. Mencionar también la referencia española (INE) Miras (1991).

## Distribuciones distorsionadas univariantes

- ▶ Las distribuciones distorsionadas univariantes fueron introducidas por Wang (1996) y Yaari (1987) en el contexto de la teoría de decisión bajo riesgos. Mencionar también la referencia española (INE) Miras (1991).
- ▶ El proposito es permitir un cambio (distorsión) en la distribución inicial (histórica) del riesgo.

# Distribuciones distorsionadas univariantes

- ▶ Las distribuciones distorsionadas univariantes fueron introducidas por Wang (1996) y Yaari (1987) en el contexto de la teoría de decisión bajo riesgos. Mencionar también la referencia española (INE) Miras (1991).
- ▶ El propósito es permitir un cambio (distorsión) en la distribución inicial (histórica) del riesgo.
- ▶ La **distribución distorsionada** (DD) asociada a  $F$  y a una función de distorsión creciente y continua  $q : [0, 1] \rightarrow [0, 1]$  verificando  $q(0) = 0$  y  $q(1) = 1$  es

$$F_q(t) = q(F(t)), \text{ for all } t \in \mathbb{R}. \quad (1.1)$$

# Propiedades

- ▶ Si  $q$  es una distorsión, entonces  $F_q$  es una función de distribución para toda distribución  $F$ .

# Propiedades

- ▶ Si  $q$  es una distorsión, entonces  $F_q$  es una función de distribución para toda distribución  $F$ .
- ▶ De (1.1), las funciones de fiabilidad  $\bar{F} = 1 - F$  y  $\bar{F}_q = 1 - F_q$  verifican

$$\bar{F}_q(t) = \bar{q}(\bar{F}(t)), \text{ para todo } t \in \mathbb{R}, \quad (1.2)$$

donde  $\bar{q}(u) := 1 - q(1 - u)$  se llama *distorsión dual*.

# Propiedades

- ▶ Si  $q$  es una distorsión, entonces  $F_q$  es una función de distribución para toda distribución  $F$ .
- ▶ De (1.1), las funciones de fiabilidad  $\bar{F} = 1 - F$  y  $\bar{F}_q = 1 - F_q$  verifican

$$\bar{F}_q(t) = \bar{q}(\bar{F}(t)), \text{ para todo } t \in \mathbb{R}, \quad (1.2)$$

donde  $\bar{q}(u) := 1 - q(1 - u)$  se llama *distorsión dual*.

- ▶ Las representaciones (1.1) son (1.2) equivalentes.

# Propiedades

- ▶ Si  $q$  es una distorsión, entonces  $F_q$  es una función de distribución para toda distribución  $F$ .
- ▶ De (1.1), las funciones de fiabilidad  $\bar{F} = 1 - F$  y  $\bar{F}_q = 1 - F_q$  verifican

$$\bar{F}_q(t) = \bar{q}(\bar{F}(t)), \text{ para todo } t \in \mathbb{R}, \quad (1.2)$$

donde  $\bar{q}(u) := 1 - q(1 - u)$  se llama *distorsión dual*.

- ▶ Las representaciones (1.1) son (1.2) equivalentes.
- ▶ La densidad de  $F_q$  es

$$f_q(t) = q'(F(t))f(t) = \bar{q}'(\bar{F}(t))f(t).$$

# Generalized distorted distributions

- ▶ Este concepto se extendió en Navarro, del Águila, Sordo and Suárez-Llorens (2016) mediante:

# Generalized distorted distributions

- ▶ Este concepto se extendió en Navarro, del Águila, Sordo and Suárez-Llorens (2016) mediante:
- ▶ Llamamos **distribución distorsionada generalizada** asociada a  $n$  distribuciones  $F_1, \dots, F_n$  y a una distorsión creciente y continua  $Q : [0, 1]^n \rightarrow [0, 1]$  tal que  $Q(0, \dots, 0) = 0$  y  $Q(1, \dots, 1) = 1$  a

$$F_Q(t) = Q(F_1(t), \dots, F_n(t)), \text{ para todo } t \in \mathbb{R}. \quad (1.3)$$

## Generalized distorted distributions

- ▶ Este concepto se extendió en Navarro, del Águila, Sordo and Suárez-Llorens (2016) mediante:
- ▶ Llamamos **distribución distorsionada generalizada** asociada a  $n$  distribuciones  $F_1, \dots, F_n$  y a una distorsión creciente y continua  $Q : [0, 1]^n \rightarrow [0, 1]$  tal que  $Q(0, \dots, 0) = 0$  y  $Q(1, \dots, 1) = 1$  a

$$F_Q(t) = Q(F_1(t), \dots, F_n(t)), \text{ para todo } t \in \mathbb{R}. \quad (1.3)$$

- ▶ Aplicaciones: Modelo de Riesgo Proporcional (PHR) de Cox, Modelo de Riesgo Reverso Proporcional (PRHR), Estadísticos Ordenados, Valores Record, Mixturas, Sistemas Coherentes, ver Navarro (2022).

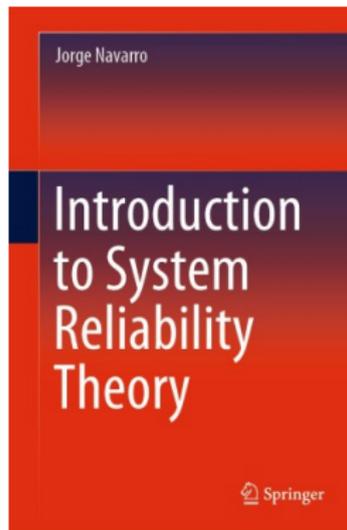


Figura: Publicidad de mi nuevo libro :-)

## Notación

- ▶  $(X_1, \dots, X_n)$  vector aleatorio sobre  $(\Omega, \mathcal{S}, \Pr)$ .

## Notación

- ▶  $(X_1, \dots, X_n)$  vector aleatorio sobre  $(\Omega, \mathcal{S}, \Pr)$ .
- ▶ Función de distribución conjunta

$$F(x_1, \dots, x_n) = \Pr(X_1 \leq x_1, \dots, X_n \leq x_n).$$

## Notación

- ▶  $(X_1, \dots, X_n)$  vector aleatorio sobre  $(\Omega, \mathcal{S}, \Pr)$ .
- ▶ Función de distribución conjunta

$$F(x_1, \dots, x_n) = \Pr(X_1 \leq x_1, \dots, X_n \leq x_n).$$

- ▶ Representación con cópulas (teorema de Sklar)

$$F(x_1, \dots, x_n) = C(F_1(x_1), \dots, F_n(x_n)),$$

donde  $F_1, \dots, F_n$  son las distribuciones marginales y  $C$  es una cópula.

# Notación

- ▶  $(X_1, \dots, X_n)$  vector aleatorio sobre  $(\Omega, \mathcal{S}, \Pr)$ .
- ▶ Función de distribución conjunta

$$F(x_1, \dots, x_n) = \Pr(X_1 \leq x_1, \dots, X_n \leq x_n).$$

- ▶ Representación con cópulas (teorema de Sklar)

$$F(x_1, \dots, x_n) = C(F_1(x_1), \dots, F_n(x_n)),$$

donde  $F_1, \dots, F_n$  son las distribuciones marginales y  $C$  es una cópula.

- ▶ Hay una representación similar para la función de supervivencia conjunta

$$\bar{F}(x_1, \dots, x_n) = \Pr(X_1 > x_1, \dots, X_n > x_n) = \hat{C}(\bar{F}_1(x_1), \dots, \bar{F}_n(x_n)),$$

donde  $\hat{C}$  es la copula de supervivencia.

## Definición de distorsiones multivariantes

Definición (Navarro, Calì, Longobardi and Durante (2021))

Una función de distribución multivariante  $F$  es una **distribución distorsionada multivariante (MDD)** de las distribuciones univariantes  $G_1, \dots, G_n$  si existe una **distorsión**  $D : [0, 1]^n \rightarrow [0, 1]$  tal que

$$F(x_1, \dots, x_n) = D(G_1(x_1), \dots, G_n(x_n)), \quad \forall x_1, \dots, x_n \in \mathbb{R}. \quad (1.4)$$

Usaremos la notación  $F \equiv MDD(G_1, \dots, G_n)$ , cuando  $F$  es una MDD de  $G_1, \dots, G_n$ .

# Definition

## Definición

Una función continua  $D : [0, 1]^n \rightarrow [0, 1]$  es una **distorsión  $n$ -dimensional** ( $D \in \mathcal{D}_n$ ) si

- (i)  $D(u_1, \dots, u_{i-1}, 0, u_{i+1}, \dots, u_n) = 0$  para todo  $u_1, \dots, u_n \in [0, 1]$ .
- (ii)  $D(1, \dots, 1) = 1$ .
- (iii)  $D$  es  $n$ -creciente, es decir, para todo  $x = (x_1, \dots, x_n)$  y  $y = (y_1, \dots, y_n)$  con  $x_i \leq y_i$ , se verifica  $\Delta_{x,y}^y D \geq 0$ , donde

$$\Delta_{(x_1, \dots, x_n)}^{(y_1, \dots, y_n)} D := \sum_{z_i \in \{x_i, y_i\}} (-1)^{1(z_1, \dots, z_n)} D(z_1, \dots, z_n),$$

con  $1(z_1, \dots, z_n) = \sum_{i=1}^n 1(z_i = x_i)$  y  $1(A) = 1$  (respectivamente, 0) si  $A$  es cierta (respectivamente, falsa).

## Propiedades principales

- ▶ El teorema de Sklar asegura que la representación con cópulas siempre existe.

## Propiedades principales

- ▶ El teorema de Sklar asegura que la representación con cópulas siempre existe.
- ▶ Si las marginales son continuas, la representación (la cópula) es única.

## Propiedades principales

- ▶ El teorema de Sklar asegura que la representación con cópulas siempre existe.
- ▶ Si las marginales son continuas, la representación (la cópula) es única.
- ▶ Se tiene un resultado similar para distorsiones.

# Teorema similar al teorema de Sklar

## Proposición

Sea  $(X_1, \dots, X_n)$  con distribución  $F$  y sean  $G_1, \dots, G_n$  distribuciones continuas. Supongamos que  $G_i$  es estrictamente creciente en el soporte de  $X_i$  para  $i = 1, \dots, n$ . Entonces existe una única distorsión  $D \in \mathcal{D}_n$  tal que

$$F(x_1, \dots, x_n) = D(G_1(x_1), \dots, G_n(x_n))$$

para todo  $(x_1, \dots, x_n) \in \mathbb{R}^n$ .

# Construcción de modelos multivariantes

## Proposición

Si  $D \in \mathcal{D}_n$ , entonces

$$D(G_1(x_1), \dots, G_n(x_n))$$

es una distribución multivariante para todas las distribuciones multivariantes  $G_1, \dots, G_n$ .

## Relación con la cópula

### Proposición

Sea  $(X_1, \dots, X_n)$  con una distribución continua  $F$ . Sean  $G_1, \dots, G_n$  distribuciones continuas tales que  $F \equiv MDD(G_1, \dots, G_n)$  con distorsión  $D$ . Entonces

$$D(u_1, \dots, u_n) = C(F_1(G_1^{-1}(u_1)), \dots, F_n(G_n^{-1}(u_n)))$$

para todo  $(u_1, \dots, u_n) \in [0, 1]^n$ , donde  $G_i^{-1}$  es la cuasi-inversa de  $G_i$  y  $F_i$  es la marginal  $i$ -ésima de  $F$  para  $i = 1, \dots, n$ .

# Representación para supervivencias.

## Proposición

Sea  $(X_1, \dots, X_n)$  con distribución  $F$ . Si se cumple (1.4) para  $G_1, \dots, G_n$  y  $D \in \mathcal{D}_n$ , entonces

$$\bar{F}(x_1, \dots, x_n) = \hat{D}(\bar{G}_1(x_1), \dots, \bar{G}_n(x_n)) \quad (1.5)$$

para todo  $x_1, \dots, x_n$ , donde  $\bar{G}_i = 1 - G_i$  y  $\hat{D} \in \mathcal{D}_n$  (distorsión dual o de supervivencia).

## Distribuciones marginales

- ▶ Una propiedad importante de  $F \equiv MDD(G_1, \dots, G_n)$  es que todas sus marginales también son MDD de  $G_1, \dots, G_n$ .

## Distribuciones marginales

- ▶ Una propiedad importante de  $F \equiv MDD(G_1, \dots, G_n)$  es que todas sus marginales también son MDD de  $G_1, \dots, G_n$ .
- ▶ Por ejemplo, si  $F_{1, \dots, m}$  es la distribución de  $(X_1, \dots, X_m)$ , entonces

$$F_{1, \dots, m}(x_1, \dots, x_m) = D_{1, \dots, m}(G_1(x_1), \dots, G_m(x_m)) \quad (1.6)$$

para todo  $(x_1, \dots, x_m) \in \mathbb{R}^m$ , donde

$$D_{1, \dots, m}(u_1, \dots, u_m) := D(u_1, \dots, u_m, 1, \dots, 1)$$

para  $(u_1, \dots, u_m) \in [0, 1]^m$  y  $D_{1, \dots, m} \in \mathcal{D}_m$ .

## Distribuciones marginales univariantes.

- ▶ In particular, la marginal de  $X_i$  es

$$F_i(x_i) = D(1, \dots, 1, G_i(x_i), 1, \dots, 1) = D_i(G_i(x_i)) \quad (1.7)$$

para todo  $x_i \in \mathbb{R}$ , donde

$$D_i(u) := D(1, \dots, 1, u, 1, \dots, 1)$$

y  $u$  se pone en la posición  $i$ -ésima.

# Distribuciones marginales univariantes.

- ▶ In particular, la marginal de  $X_i$  es

$$F_i(x_i) = D(1, \dots, 1, G_i(x_i), 1, \dots, 1) = D_i(G_i(x_i)) \quad (1.7)$$

para todo  $x_i \in \mathbb{R}$ , donde

$$D_i(u) := D(1, \dots, 1, u, 1, \dots, 1)$$

y  $u$  se pone en la posición  $i$ -ésima.

- ▶ Se tiene  $G_i = F_i$  para un  $i \in \{1, \dots, n\}$  si y solo si  $D_i(u) = u$  para todo  $u \in [0, 1]$ .

## Función de densidad conjunta

Si  $F$  es abs, continua con densidad  $f$ , tenemos

$$f(x_1, \dots, x_n) = \partial_{1, \dots, n} F(x_1, \dots, x_n) \text{ (a.e.)}.$$

### Proposición

Si  $F \equiv MDD(G_1, \dots, G_n)$ ,  $G_1, \dots, G_n$  tienen densidades  $g_1, \dots, g_n$ , y la distorsión  $D$  tiene derivadas de orden  $n$ , entonces

$$f(x_1, \dots, x_n) = g_1(x_1) \dots g_n(x_n) \partial_{1, \dots, n} D(G_1(x_1), \dots, G_n(x_n)) \text{ (a.e.)}.$$

## Distribuciones condicionadas

- ▶ Todas las distribuciones condicionadas de  $F \equiv MDD(G_1, \dots, G_n)$  tienen representaciones MDD.

## Distribuciones condicionadas

- ▶ Todas las distribuciones condicionadas de  $F \equiv MDD(G_1, \dots, G_n)$  tienen representaciones MDD.
- ▶ Solo consideramos la distribución  $F_{2|1}$  de  $(X_2|X_1 = x_1)$ .

## Distribuciones condicionadas

- ▶ Todas las distribuciones condicionadas de  $F \equiv MDD(G_1, \dots, G_n)$  tienen representaciones MDD.
- ▶ Solo consideramos la distribución  $F_{2|1}$  de  $(X_2|X_1 = x_1)$ .

### Proposición

Sea  $(X_1, X_2)$  con  $F \equiv MDD(G_1, G_2)$  para  $D \in \mathcal{D}_2$  con derivadas continuas de orden 2, entonces

$$F_{2|1}(x_2|x_1) = D_{2|1}(G_2(x_2)|G_1(x_1)) \quad (1.8)$$

siempre que  $\lim_{v \rightarrow 0^+} \partial_1 D(G_1(x_1), v) = 0$ , donde

$$D_{2|1}(v|G_1(x_1)) = \frac{\partial_1 D(G_1(x_1), v)}{\partial_1 D(G_1(x_1), 1)}$$

para  $0 < v < 1$  y  $x_1$  tales que  $\partial_1 D(G_1(x_1), 1) > 0$ .

## Regresión cuantílica (QR) teórica

- ▶ La **curva de regresión (media)** para predecir  $X_2$  a partir de  $X_1$  es

$$\tilde{m}_{2|1}(x_1) = E(X_2|X_1 = x_1)$$

## Regresión cuantílica (QR) teórica

- ▶ La **curva de regresión (media)** para predecir  $X_2$  a partir de  $X_1$  es

$$\tilde{m}_{2|1}(x_1) = E(X_2|X_1 = x_1)$$

- ▶ Otra opción es usar la **curva de regresión mediana**

$$m_{2|1}(x_1) := F_{2|1}^{-1}(0,5|x_1)$$

(ver Koenker (2005) o Nelsen (2006), p. 217).

## Regresión cuantílica (QR) teórica

- ▶ La **curva de regresión (media)** para predecir  $X_2$  a partir de  $X_1$  es

$$\tilde{m}_{2|1}(x_1) = E(X_2|X_1 = x_1)$$

- ▶ Otra opción es usar la **curva de regresión mediana**

$$m_{2|1}(x_1) := F_{2|1}^{-1}(0,5|x_1)$$

(ver Koenker (2005) o Nelsen (2006), p. 217).

## Regresión cuantílica (QR) teórica

- ▶ La **curva de regresión (media)** para predecir  $X_2$  a partir de  $X_1$  es

$$\tilde{m}_{2|1}(x_1) = E(X_2|X_1 = x_1)$$

- ▶ Otra opción es usar la **curva de regresión mediana**

$$m_{2|1}(x_1) := F_{2|1}^{-1}(0,5|x_1)$$

(ver Koenker (2005) o Nelsen (2006), p. 217).

- ▶ La función cuantílica  $F_{2|1}^{-1}$  se puede calcular de (1.8) como

$$F_{2|1}^{-1}(q|x_1) = G_2^{-1}(D_{2|1}^{-1}(q|G_1(x_1))), \quad 0 < q < 1.$$

## Confidence bands

- ▶ Esta función también se puede usar para obtener bandas de confianza  $\alpha$  para esas predicciones con

$$\left[ F_{2|1}^{-1}(\beta_1|x_1), F_{2|1}^{-1}(\beta_2|x_1) \right]$$

tomando  $0 \leq \beta_1 < \beta_2 \leq 1$  tales que  $\beta_2 - \beta_1 = \alpha$ .

## Confidence bands

- ▶ Esta función también se puede usar para obtener bandas de confianza  $\alpha$  para esas predicciones con

$$\left[ F_{2|1}^{-1}(\beta_1|x_1), F_{2|1}^{-1}(\beta_2|x_1) \right]$$

tomando  $0 \leq \beta_1 < \beta_2 \leq 1$  tales que  $\beta_2 - \beta_1 = \alpha$ .

- ▶ Por ejemplo, las bandas de confianza 50 % y 90 % centradas para  $(X_2|X_1 = x_1)$  son

$$\left[ F_{2|1}^{-1}(0,25|x_1), F_{2|1}^{-1}(0,75|x_1) \right]$$

y

$$\left[ F_{2|1}^{-1}(0,05|x_1), F_{2|1}^{-1}(0,95|x_1) \right].$$

# Ejemplos

# Ejemplos

- ▶ Tiempos de vida residuales. Si  $X_1, \dots, X_n$  son tiempos de vida, entonces

$$X_t = (X_1 - t, \dots, X_n - t | X_1 > t, \dots, X_n > t)$$

tienen una distribución distorsionada a partir de las de  $(X_i - t | X_i > t)$ .

# Ejemplos

- ▶ Tiempos de vida residuales. Si  $X_1, \dots, X_n$  son tiempos de vida, entonces

$$X_t = (X_1 - t, \dots, X_n - t | X_1 > t, \dots, X_n > t)$$

tienen una distribución distorsionada a partir de las de  $(X_i - t | X_i > t)$ .

- ▶ Estadísticos ordenados  $IID \sim F$  (datos censurados)

# Ejemplos

- ▶ Tiempos de vida residuales. Si  $X_1, \dots, X_n$  son tiempos de vida, entonces

$$X_t = (X_1 - t, \dots, X_n - t | X_1 > t, \dots, X_n > t)$$

tienen una distribución distorsionada a partir de las de  $(X_i - t | X_i > t)$ .

- ▶ Estadísticos ordenados  $IID \sim F$  (datos censurados)
- ▶ Valores record  $IID \sim F$ , ver Navarro (2021).

# Ejemplos

- ▶ Tiempos de vida residuales. Si  $X_1, \dots, X_n$  son tiempos de vida, entonces

$$X_t = (X_1 - t, \dots, X_n - t | X_1 > t, \dots, X_n > t)$$

tienen una distribución distorsionada a partir de las de  $(X_i - t | X_i > t)$ .

- ▶ Estadísticos ordenados  $IID \sim F$  (datos censurados)
- ▶ Valores record  $IID \sim F$ , ver Navarro (2021).
- ▶ Sistemas coherentes.

# Ejemplos

- ▶ Tiempos de vida residuales. Si  $X_1, \dots, X_n$  son tiempos de vida, entonces

$$X_t = (X_1 - t, \dots, X_n - t | X_1 > t, \dots, X_n > t)$$

tienen una distribución distorsionada a partir de las de  $(X_i - t | X_i > t)$ .

- ▶ Estadísticos ordenados  $IID \sim F$  (datos censurados)
- ▶ Valores record  $IID \sim F$ , ver Navarro (2021).
- ▶ Sistemas coherentes.
- ▶ Datos pareados

## Datos pareados

- ▶ Supongamos que  $X$  e  $Y$  son ID y tienen una distribución continua  $F$ . Entonces

$$F_{X,Y}(x, y) = C(F(x), F(y)).$$

## Datos pareados

- ▶ Supongamos que  $X$  e  $Y$  son ID y tienen una distribución continua  $F$ . Entonces

$$F_{X,Y}(x, y) = C(F(x), F(y)).$$

- ▶ Incluso podemos suponer que  $C$  es simétrica, es decir,  $(X, Y)$  is intercambiable (EXC).

## Datos pareados

- ▶ Supongamos que  $X$  e  $Y$  son ID y tienen una distribución continua  $F$ . Entonces

$$F_{X,Y}(x, y) = C(F(x), F(y)).$$

- ▶ Incluso podemos suponer que  $C$  es simétrica, es decir,  $(X, Y)$  is intercambiable (EXC).
- ▶ Supongamos que  $L = \min(X, Y)$  es conocido y que queremos predecir  $U = \max(X, Y)$ .

## Datos pareados

- ▶ Supongamos que  $X$  e  $Y$  son ID y tienen una distribución continua  $F$ . Entonces

$$F_{X,Y}(x, y) = C(F(x), F(y)).$$

- ▶ Incluso podemos suponer que  $C$  es simétrica, es decir,  $(X, Y)$  is intercambiable (EXC).
- ▶ Supongamos que  $L = \min(X, Y)$  es conocido y que queremos predecir  $U = \max(X, Y)$ .
- ▶ Para eso necesitamos la distribución condicionada

$$G_{2|1}(s|t) := \Pr(U \leq s | L = t), \quad s \geq t.$$

- ▶ Queremos obtener una representación MDD para  $(L, U)$  usando  $F$  y  $C$ .

# Datos pareados

- La distribución  $G(x, y) = \Pr(L \leq x, U \leq y)$  de  $(L, U)$  es

$$G(x, y) = \begin{cases} C(F(y), F(y)) & y \leq x; \\ C(F(x), F(y)) + C(F(y), F(x)) - C(F(x), F(x)) & y > x. \end{cases}$$

# Datos pareados

- ▶ La distribución  $G(x, y) = \Pr(L \leq x, U \leq y)$  de  $(L, U)$  es

$$G(x, y) = \begin{cases} C(F(y), F(y)) & y \leq x; \\ C(F(x), F(y)) + C(F(y), F(x)) - C(F(x), F(x)) & y > x. \end{cases}$$

- ▶ Entonces  $G(x, y) = D(F(x), F(y))$  con

$$D(u, v) = \begin{cases} C(v, v) & \text{for } v \leq u; \\ C(u, v) + C(v, u) - C(u, u) & \text{for } u < v. \end{cases} \quad (2.1)$$

# Datos pareados

- ▶ Las marginales de  $(L, U)$  son

$$G_1(x) := \Pr(L \leq x) = D(F(x), 1) = D_1(F(x)),$$

$$G_2(y) := \Pr(U \leq y) = D(1, F(y)) = D_2(F(y)),$$

donde

$$D_1(u) = D(u, 1) = 2u - C(u, u)$$

y

$$D_2(v) = D(1, v) = C(v, v)$$

para  $u, v \in [0, 1]$ .

# Datos pareados, caso IID

- ▶ Por ejemplo, si  $X$  e  $Y$  son IID, entonces

$$D_1(u) = D(u, 1) = 2u - u^2 \neq u$$

y

$$D_2(u) = D(1, u) = u^2 \neq u$$

para todo  $u \in (0, 1)$ .

# Datos pareados, caso IID

- ▶ Por ejemplo, si  $X$  e  $Y$  son IID, entonces

$$D_1(u) = D(u, 1) = 2u - u^2 \neq u$$

y

$$D_2(u) = D(1, u) = u^2 \neq u$$

para todo  $u \in (0, 1)$ .

- ▶ La distorsión es

$$D(u, v) = \begin{cases} v^2 & \text{para } v \leq u; \\ 2uv - u^2 & \text{para } u < v. \end{cases} \quad (2.2)$$

# Datos pareados, caso IID

- ▶ Por ejemplo, si  $X$  e  $Y$  son IID, entonces

$$D_1(u) = D(u, 1) = 2u - u^2 \neq u$$

y

$$D_2(u) = D(1, u) = u^2 \neq u$$

para todo  $u \in (0, 1)$ .

- ▶ La distorsión es

$$D(u, v) = \begin{cases} v^2 & \text{para } v \leq u; \\ 2uv - u^2 & \text{para } u < v. \end{cases} \quad (2.2)$$

- ▶ La función  $D$  no es una cópula y las marginales  $G_1$  y  $G_2$  de  $(L, U)$  no se usan (usamos  $F$ ).

# Datos pareados, distribución condicionada

- De (1.8), la distribución de  $(U|L = x)$  se puede poner como

$$G_{2|1}(y|x) = D_{2|1}(F(y)|F(x)) \quad (2.3)$$

para  $y \geq x$ , donde

$$D_{2|1}(v|F(x)) := \frac{\partial_1 D(F(x), v)}{\partial_1 D(F(x), 1)},$$

$$\partial_1 D(u, v) = \partial_1 C(u, v) + \partial_2 C(v, u) - \partial_1 C(u, u) - \partial_2 C(u, u), \text{ si } v > u.$$

# Datos pareados, distribución condicionada

- ▶ De (1.8), la distribución de  $(U|L = x)$  se puede poner como

$$G_{2|1}(y|x) = D_{2|1}(F(y)|F(x)) \quad (2.3)$$

para  $y \geq x$ , donde

$$D_{2|1}(v|F(x)) := \frac{\partial_1 D(F(x), v)}{\partial_1 D(F(x), 1)},$$

$$\partial_1 D(u, v) = \partial_1 C(u, v) + \partial_2 C(v, u) - \partial_1 C(u, u) - \partial_2 C(u, u), \text{ si } v > u.$$

- ▶ En el caso EXC,  $\partial_1 D(u, v) = 2\partial_1 C(u, v) - 2\partial_1 C(u, u)$  para  $u \leq v \leq 1$ .

# Datos pareados, distribución condicionada

- ▶ De (1.8), la distribución de  $(U|L = x)$  se puede poner como

$$G_{2|1}(y|x) = D_{2|1}(F(y)|F(x)) \quad (2.3)$$

para  $y \geq x$ , donde

$$D_{2|1}(v|F(x)) := \frac{\partial_1 D(F(x), v)}{\partial_1 D(F(x), 1)},$$

$\partial_1 D(u, v) = \partial_1 C(u, v) + \partial_2 C(v, u) - \partial_1 C(u, u) - \partial_2 C(u, u)$ , si  $v > u$ .

- ▶ En el caso EXC,  $\partial_1 D(u, v) = 2\partial_1 C(u, v) - 2\partial_1 C(u, u)$  para  $u \leq v \leq 1$ .
- ▶ En el caso IID,  $\partial_1 D(u, v) = 2(v - u)$  para  $u \leq v \leq 1$ .

## Curvas QR exactas. Caso IID.

- ▶ Sea  $(X_i, Y_i)$  una muestra de  $(X, Y)$  donde  $X, Y$  son  $\text{IID} \sim F$ .

## Curvas QR exactas. Caso IID.

- ▶ Sea  $(X_i, Y_i)$  una muestra de  $(X, Y)$  donde  $X, Y$  son  $\text{IID} \sim F$ .
- ▶ Sean  $L_i = \min(X_i, Y_i)$  y  $U_i = \max(X_i, Y_i)$ .

## Curvas QR exactas. Caso IID.

- ▶ Sea  $(X_i, Y_i)$  una muestra de  $(X, Y)$  donde  $X, Y$  son  $\text{IID} \sim F$ .
- ▶ Sean  $L_i = \min(X_i, Y_i)$  y  $U_i = \max(X_i, Y_i)$ .
- ▶  $L_i$  y  $U_i$  son dependientes (pareados).

## Curvas QR exactas. Caso IID.

- ▶ Sea  $(X_i, Y_i)$  una muestra de  $(X, Y)$  donde  $X, Y$  son  $\text{IID} \sim F$ .
- ▶ Sean  $L_i = \min(X_i, Y_i)$  y  $U_i = \max(X_i, Y_i)$ .
- ▶  $L_i$  y  $U_i$  son dependientes (pareados).
- ▶ De (2.3), la distribución de  $(U|L = x)$  es

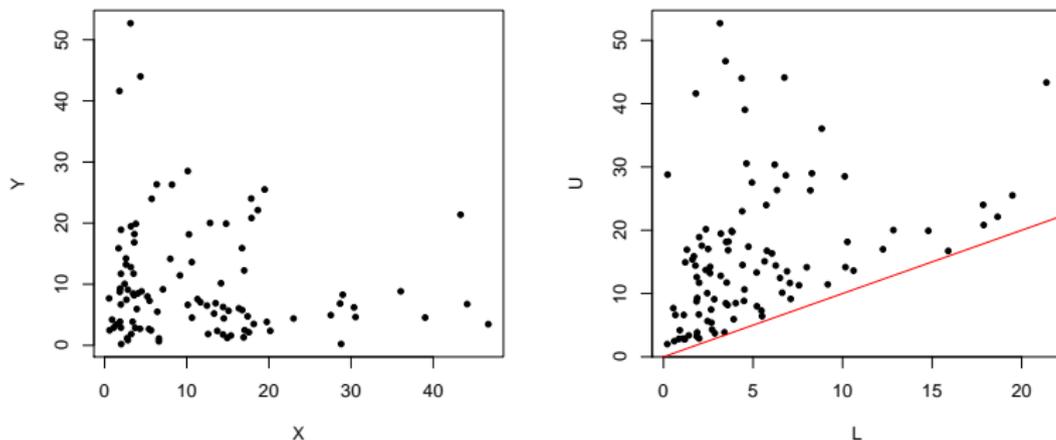
$$G_{2|1}(y|x) = D_{2|1}(F(y)|F(x)) \quad (2.4)$$

para  $y \geq x$ , donde

$$D_{2|1}(v|F(x)) = \frac{v - F(x)}{\bar{F}(x)}$$

para  $F(x) \leq v \leq 1$ .

# Datos pareados. Caso IID exponencial.



**Figura:** Datos de dos distribuciones exponenciales independientes de media  $\mu = 10$  (izquierda) y datos pareados asociados (derecha).

## Datos pareados. Caso IID exponencial.

- ▶ La función  $F_{2|1}^{-1}$  se puede calcular como

$$F_{2|1}^{-1}(q|x) = F^{-1}(D_{2|1}^{-1}(q|F(x)))$$

para  $0 < v < 1$ , donde  $D_{2|1}^{-1}(q|F(x)) = F(x) + q\bar{F}(x)$ .

# Datos pareados. Caso IID exponencial.

- ▶ La función  $F_{2|1}^{-1}$  se puede calcular como

$$F_{2|1}^{-1}(q|x) = F^{-1}(D_{2|1}^{-1}(q|F(x)))$$

para  $0 < v < 1$ , donde  $D_{2|1}^{-1}(q|F(x)) = F(x) + q\bar{F}(x)$ .

- ▶ Si  $\bar{F}(x) = \exp(-x/\mu)$ , entonces  $F^{-1}(y) = -\mu \log(1 - y)$  y

$$F_{2|1}^{-1}(q|x) = -\mu \log\left((1 - q)e^{-x/\mu}\right) = x - \mu \log(1 - q).$$

# Datos pareados. Caso IID exponencial.

- ▶ La función  $F_{2|1}^{-1}$  se puede calcular como

$$F_{2|1}^{-1}(q|x) = F^{-1}(D_{2|1}^{-1}(q|F(x)))$$

para  $0 < v < 1$ , donde  $D_{2|1}^{-1}(q|F(x)) = F(x) + q\bar{F}(x)$ .

- ▶ Si  $\bar{F}(x) = \exp(-x/\mu)$ , entonces  $F^{-1}(y) = -\mu \log(1 - y)$  y

$$F_{2|1}^{-1}(q|x) = -\mu \log\left((1 - q)e^{-x/\mu}\right) = x - \mu \log(1 - q).$$

- ▶ Entonces la curva QR es

$$m(x) = x - \mu \log(0,5).$$

# Datos pareados. Caso IID exponencial.

- ▶ La banda de confianza 90 % centrada es

$$[x - \mu \log(0,05), x - \mu \log(0,95)].$$

## Datos pareados. Caso IID exponencial.

- ▶ La banda de confianza 90 % centrada es

$$[x - \mu \log(0,05), x - \mu \log(0,95)].$$

- ▶ La de confianza 50 % se obtiene de forma similar.

## Datos pareados. Caso IID exponencial.

- ▶ La banda de confianza 90 % centrada es

$$[x - \mu \log(0,05), x - \mu \log(0,95)].$$

- ▶ La de confianza 50 % se obtiene de forma similar.
- ▶ Aquí podemos preferir la banda inferior al 90 % dada por

$$[x, x - \mu \log(0,90)].$$

## Datos pareados. Caso IID exponencial.

- ▶ La banda de confianza 90 % centrada es

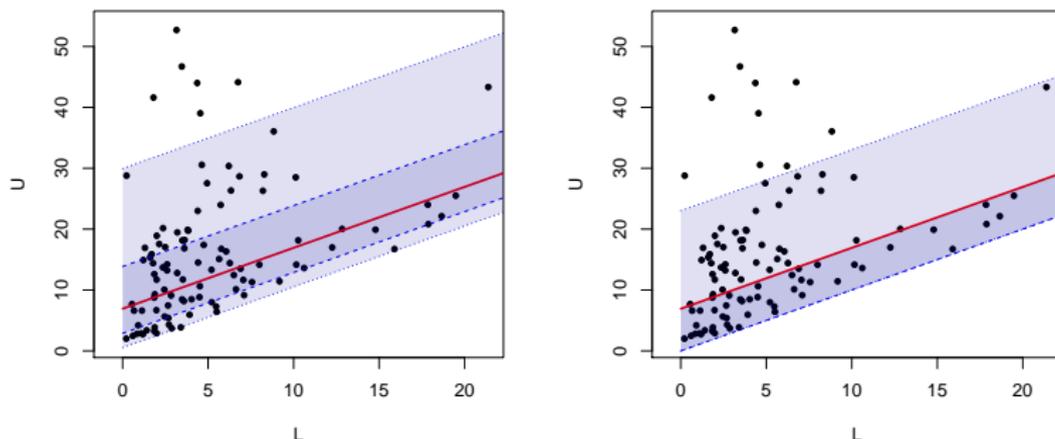
$$[x - \mu \log(0,05), x - \mu \log(0,95)].$$

- ▶ La de confianza 50 % se obtiene de forma similar.
- ▶ Aquí podemos preferir la banda inferior al 90 % dada por

$$[x, x - \mu \log(0,90)].$$

- ▶ Las podemos ver en las gráficas siguientes.

## Datos pareados. Caso IID exponencial.



**Figura:** Curvas QR para los datos pareados  $(L, U)$  asociados a datos independientes  $(X, Y)$  con exponenciales de media  $\mu = 10$  junto con las bandas de confianza 50 % y 90 % centradas (izquierda) e inferiores (derecha).

# Predicciones

- ▶ La primera pareja de valores en nuestra muestra es  $L_1 = 10,15771$  y  $U_1 = 14,17195$ .

# Predicciones

- ▶ La primera pareja de valores en nuestra muestra es  $L_1 = 10,15771$  y  $U_1 = 14,17195$ .
- ▶ La predicción de  $U_1$  en  $L_1$  es

$$m(L_1) = m(10,15771) = 10,15771 - \mu \log(0,5) = 17,08918.$$

# Predicciones

- ▶ La primera pareja de valores en nuestra muestra es  $L_1 = 10,15771$  y  $U_1 = 14,17195$ .
- ▶ La predicción de  $U_1$  en  $L_1$  es

$$m(L_1) = m(10,15771) = 10,15771 - \mu \log(0,5) = 17,08918.$$

- ▶ El intervalo de confianza 90 % centrado para esta predicción es  $[10,67064, 40,11503]$ .

# Predicciones

- ▶ La primera pareja de valores en nuestra muestra es  $L_1 = 10,15771$  y  $U_1 = 14,17195$ .
- ▶ La predicción de  $U_1$  en  $L_1$  es

$$m(L_1) = m(10,15771) = 10,15771 - \mu \log(0,5) = 17,08918.$$

- ▶ El intervalo de confianza 90 % centrado para esta predicción es  $[10,67064, 40,11503]$ .
- ▶ El del 50 % es  $[13,03453, 24,02065]$ .

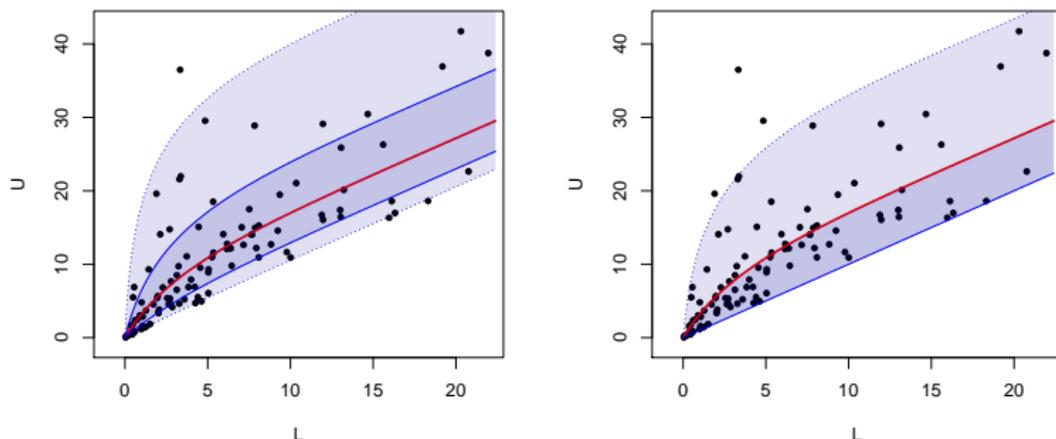
# Predicciones

- ▶ La primera pareja de valores en nuestra muestra es  $L_1 = 10,15771$  y  $U_1 = 14,17195$ .
- ▶ La predicción de  $U_1$  en  $L_1$  es

$$m(L_1) = m(10,15771) = 10,15771 - \mu \log(0,5) = 17,08918.$$

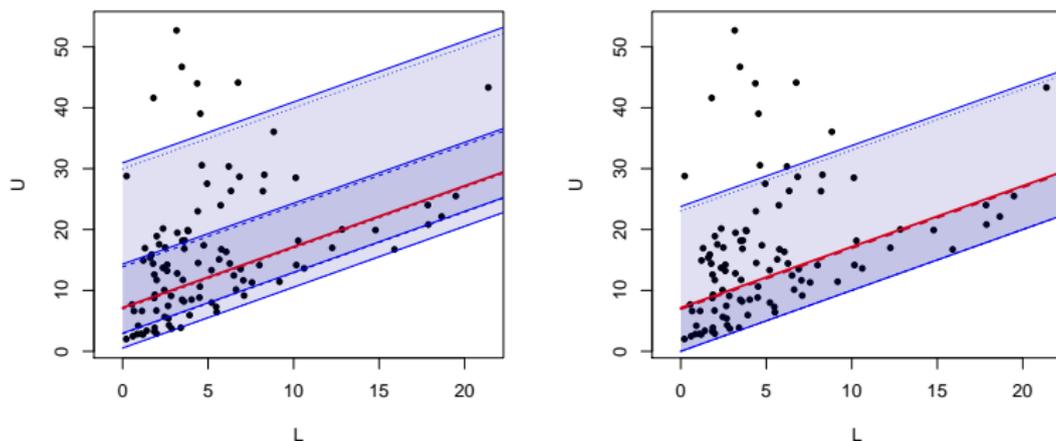
- ▶ El intervalo de confianza 90 % centrado para esta predicción es  $[10,67064, 40,11503]$ .
- ▶ El del 50 % es  $[13,03453, 24,02065]$ .
- ▶ Ambos contienen al verdadero valor de  $U_1$ .

## QR para datos dependientes EXC exponenciales



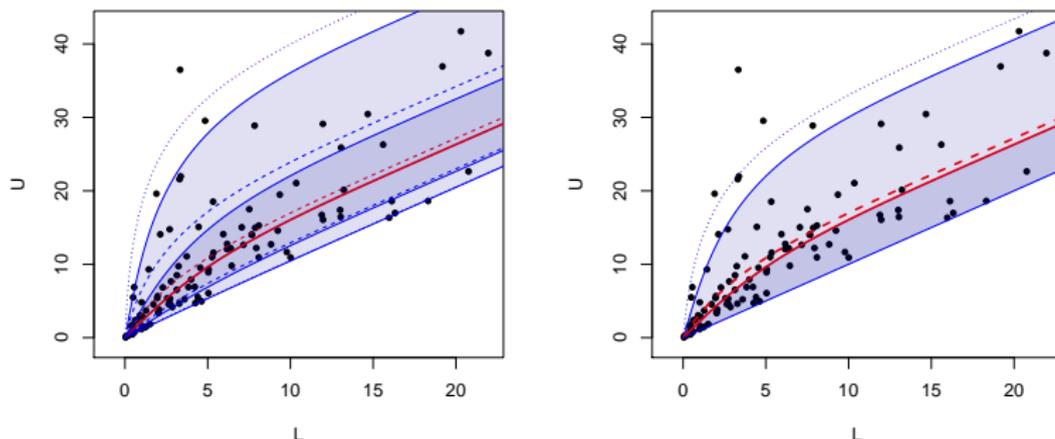
**Figura:** Curvas QR para los datos pareados  $(L, U)$  cuando  $(X, Y)$  son exponenciales y dependientes con una copula tipo Clayton con bandas de confianza centradas (izquierda) o inferiores (derecha).

# Curvas QR estimadas, caso IID exponencial



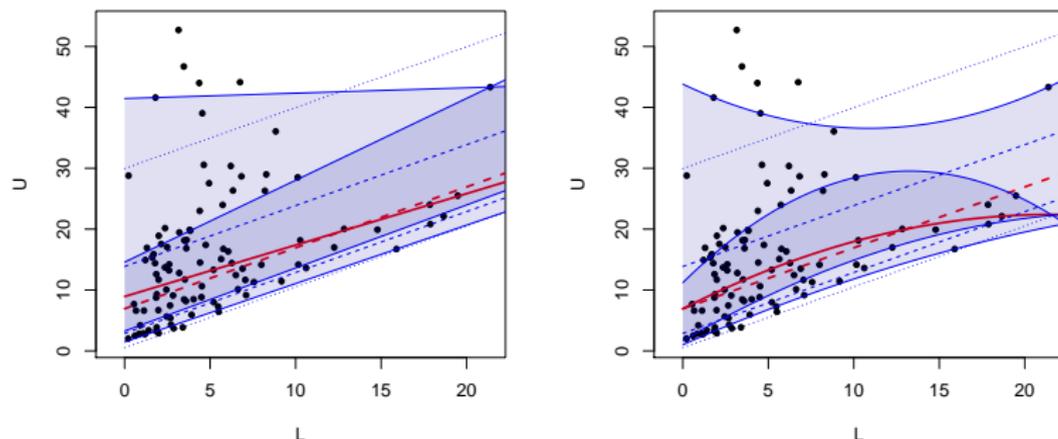
**Figura:** Curvas QR cuando se estiman las medias de las distribuciones exponenciales. Las líneas de puntos representan las curvas exactas.

# Curvas QR estimadas, caso EXC-Clayton



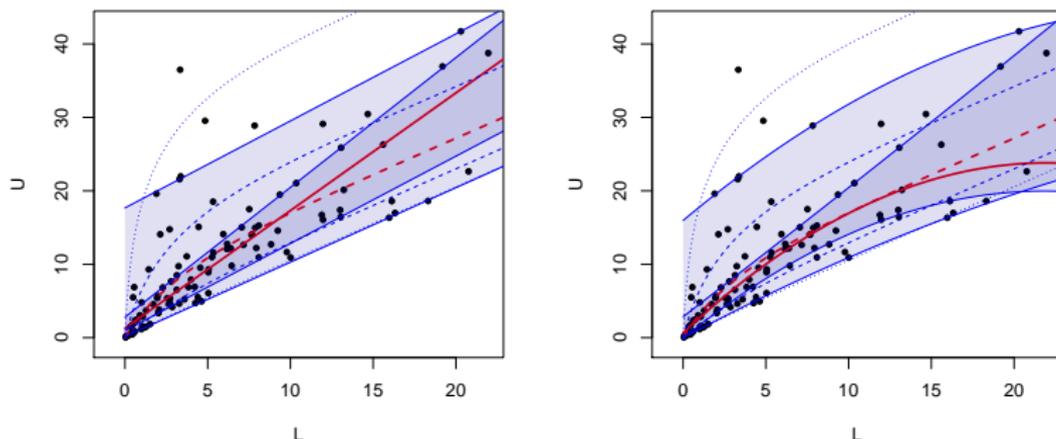
**Figura:** Curvas QR cuando se estiman las medias de las distribuciones exponenciales y el parámetro de la copula Clayton. Las líneas de puntos representan las curvas exactas.

## Curvas QR no paramétricas, caso IID



**Figura:** Curvas QR empíricas para los datos pareados  $(L, U)$  asociados a datos independientes  $(X, Y)$  exponenciales con medias  $\mu = 10$  y grado 1 (izquierda) y 2 (derecha).

## Curvas QR no paramétricas, caso EXC-Clayton



**Figura:** Curvas QR empíricas para los datos pareados  $(L, U)$  asociados a datos dependientes  $(X, Y)$  Clayton y exponenciales con medias  $\mu = 10$  y grado 1 (izquierda) y 2 (derecha).

## References

- Koenker R (2005). *Quantile Regression*. Cambridge University Press.
- Koenker R, Bassett Jr G (1978). Regression quantiles. *Econometrica* 46, 33–50.
- Miras, J. (1991). Deformación de funciones de distribución: una técnica estadística. *Estadística Española* Vol. 33, Núm. 127, 257–284.
- Navarro, J. (2021). Prediction of record values by using quantile regression curves and distortion functions. orge Navarro. To appear in *Metrika*. Published online first Nov. 2021. DOI: 10.1007/s00184-021-00847-w.
- Navarro J (2022). *Introduction to System Reliability Theory* Springer.
- Navarro J, Cali C, Longobardi M, Durante F (2021). Distortion Representations of Multivariate Distributions. *Statistical Methods & Applications*. Published online first Jan. 2022. DOI: 10.1007/s10260-021-00613-2.
- Navarro, J. and del Águila, Y. (2017). Stochastic comparisons of distorted distributions, coherent systems and mixtures with ordered components. *Metrika* 80, 627-648

- Navarro, J., del Águila, Y., Sordo, M.A. and Suárez-Llorens, A. (2013). Stochastic ordering properties for systems with dependent identically distributed components. *Applied Stochastic Models in Business and Industry* 29, 264–278.
- Navarro, J., del Águila, Y., Sordo, M.A. and Suárez-Llorens, A. (2014). Preservation of reliability classes under the formation of coherent systems. *Applied Stochastic Models in Business and Industry* 30, 444–454.
- Navarro, J., del Águila, Y., Sordo, M.A. and Suárez-Llorens, A. (2016). Preservation of stochastic orders under the formation of generalized distorted distributions. Applications to coherent systems. *Methodology and Computing in Applied Probability* 18, 529–545.
- Navarro, J. and Gomis, M.C. (2016). Comparisons in the mean residual life order of coherent systems with identically distributed components. *Applied Stochastic Models in Business and Industry* 32, 33–47.
- Nelsen RB (2006). An introduction to copulas. Second edition. Springer, New York.
- Wang, S. (1996). Premium calculation by transforming the layer premium density. *Astin Bulletin* 26, 71-92.
- Yaari, M.E. (1987). The dual theory of choice under risk. *Econometrica* 55, 95–115.

- ▶ Las transparencias y más referencias se pueden ver en mi página web:

*<https://webs.um.es/jorgenav>*

# Fin

- ▶ Las transparencias y más referencias se pueden ver en mi página web:

*<https://webs.um.es/jorgenav>*

- ▶ Gracias por su asistencia y atención!!

# Fin

- ▶ Las transparencias y más referencias se pueden ver en mi página web:

*<https://webs.um.es/jorgenav>*

- ▶ Gracias por su asistencia y atención!!
- ▶ Preguntas?