

Predicciones usando distorsiones bivariates y regresión cuantílica

Jorge Navarro¹
Universidad de Murcia, Murcia, Spain.



¹Supported 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, Cali 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).

- ▶ La función cuantílica $F_{2|1}^{-1}$ también se puede usar para obtener bandas de confianza α 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 $\beta_2 - \beta_1 = \alpha$.

Bandas de confianza teóricas

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

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

Bandas de confianza teóricas

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

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

- ▶ Esta función se puede usar para obtener la curva de regresión mediana como

$$m_{2|1}(x_1) = G_2^{-1}(D_{2|1}^{-1}(0,5|G_1(x_1))).$$

Bandas de confianza teóricas

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

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

- ▶ Esta función se puede usar para obtener la curva de regresión mediana como

$$m_{2|1}(x_1) = G_2^{-1}(D_{2|1}^{-1}(0,5|G_1(x_1))).$$

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

$$\left[G_2^{-1}(D_{2|1}^{-1}(0,25|G_1(x_1))), G_2^{-1}(D_{2|1}^{-1}(0,75|G_1(x_1))) \right]$$

y

$$\left[G_2^{-1}(D_{2|1}^{-1}(0,05|G_1(x_1))), G_2^{-1}(D_{2|1}^{-1}(0,95|G_1(x_1))) \right].$$

Regresión cuantílica (QR) práctica

- ▶ En la práctica debemos estimar los parámetros del modelo o estimar esas curvas de forma no-paramétrica usando QR a partir de una muestra de datos de (X_1, X_2) :
 $(x_1(i), x_2(i)), i = 1, \dots, n.$

Regresión cuantílica (QR) práctica

- ▶ En la práctica debemos estimar los parámetros del modelo o estimar esas curvas de forma no-paramétrica usando QR a partir de una muestra de datos de (X_1, X_2) :
 $(x_1(i), x_2(i)), i = 1, \dots, n$.
- ▶ La mediana de X_1 se obtiene minimizando:

$$J(a) = \sum_i |x_1(i) - a| = \sum_{i: x_1(i) > a} (x_1(i) - a) + \sum_{i: x_1(i) < a} (a - x_1(i)).$$

Regresión cuantílica (QR) práctica

- ▶ En la práctica debemos estimar los parámetros del modelo o estimar esas curvas de forma no-paramétrica usando QR a partir de una muestra de datos de (X_1, X_2) :
 $(x_1(i), x_2(i)), i = 1, \dots, n$.
- ▶ La mediana de X_1 se obtiene minimizando:

$$J(a) = \sum_i |x_1(i) - a| = \sum_{i: x_1(i) > a} (x_1(i) - a) + \sum_{i: x_1(i) < a} (a - x_1(i)).$$

- ▶ La curva mediana lineal $m(x) = a + bx$ se obtiene minimizando

$$J(a, b) = \sum_{i: x_2(i) > a + bx_1(i)} (x_2(i) - a - bx_1(i)) + \sum_{i: x_2(i) < a + bx_1(i)} (a + bx_1(i) - x_2(i))$$

usando programación lineal (ver Koenker (2005)).

Regresión cuantílica (QR) práctica

- Análogamente el cuantil $\hat{x}_q = F_{X_1}^{-1}(q)$ para $0 < q < 1$ de X_1 se obtiene minimizando:

$$J_q(a) = q \sum_{i: x_1(i) > a} (x_1(i) - a) + (1 - q) \sum_{i: x_1(i) < a} (a - x_1(i)).$$

Regresión cuantílica (QR) práctica

- ▶ Análogamente el cuantil $\hat{x}_q = F_{X_1}^{-1}(q)$ para $0 < q < 1$ de X_1 se obtiene minimizando:

$$J_q(a) = q \sum_{i:x_1(i)>a} (x_1(i) - a) + (1 - q) \sum_{i:x_1(i)<a} (a - x_1(i)).$$

- ▶ La curva q-cuantil lineal $m_q(x) = a_q + b_q x$ se obtiene minimizando en a y b :

$$q \sum_{i:x_2(i)>a+bx_1(i)} (x_2(i) - a - bx_1(i)) + (1 - q) \sum_{i:x_2(i)<a+bx_1(i)} (a + bx_1(i) - x_2(i))$$

usando programación lineal (ver Koenker (2005)).

Regresión cuantílica (QR) práctica

- ▶ El paquete `quantreg` de R (Rstudio) permite obtener estas soluciones.

Regresión cuantílica (QR) práctica

- ▶ El paquete `quantreg` de R (Rstudio) permite obtener estas soluciones.
- ▶ Si los datos están en `x1` y `x2` basta hacer:

```
rq(x2~x1)  
plot(x1,x2)  
abline(rq(x2~x1),col='red')
```

Regresión cuantílica (QR) práctica

- ▶ El paquete `quantreg` de R (Rstudio) permite obtener estas soluciones.
- ▶ Si los datos están en `x1` y `x2` basta hacer:

```
rq(x2~x1)  
plot(x1,x2)  
abline(rq(x2~x1),col='red')
```
- ▶ La banda de confianza centrada al 90 % se obtiene con `rq(x2~x1,0.05)` y `rq(x2~x1,0.95)`

Regresión cuantílica (QR) práctica

- ▶ El paquete `quantreg` de R (Rstudio) permite obtener estas soluciones.
- ▶ Si los datos están en `x1` y `x2` basta hacer:
`rq(x2~x1)`
`plot(x1,x2)`
`abline(rq(x2~x1),col='red')`
- ▶ La banda de confianza centrada al 90 % se obtiene con `rq(x2~x1,0.05)` y `rq(x2~x1,0.95)`
- ▶ Y la banda de confianza centrada al 50 % se obtiene con `rq(x2~x1,0.25)` y `rq(x2~x1,0.75)`

Ejemplos

Tiempos de vida residuales

- ▶ 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 $(X_i - t | X_i > t)$.

Tiempos de vida residuales

- ▶ 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)

Tiempos de vida residuales

- ▶ 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).

Tiempos de vida residuales

- ▶ 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.

Tiempos de vida residuales

- ▶ 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

Tiempos de vida de sistemas

- ▶ Tiempos de vida de sistemas coherentes (conectividad en redes) $T_1 < T_2$ basados en los mismos componentes (X_1, \dots, X_n) .

Tiempos de vida de sistemas

- ▶ Tiempos de vida de sistemas coherentes (conectividad en redes) $T_1 < T_2$ basados en los mismos componentes (X_1, \dots, X_n) .
- ▶ Prededecir T_2 a partir de $T_1 = t$ para $t > 0$.

Tiempos de vida de sistemas

- ▶ Tiempos de vida de sistemas coherentes (conectividad en redes) $T_1 < T_2$ basados en los mismos componentes (X_1, \dots, X_n) .
- ▶ Prededecir T_2 a partir de $T_1 = t$ para $t > 0$.
- ▶ El caso más usual es $T_1 = \min(X_1, \dots, X_n)$.

Tiempos de vida de sistemas

- ▶ Tiempos de vida de sistemas coherentes (conectividad en redes) $T_1 < T_2$ basados en los mismos componentes (X_1, \dots, X_n) .
- ▶ Prededecir T_2 a partir de $T_1 = t$ para $t > 0$.
- ▶ El caso más usual es $T_1 = \min(X_1, \dots, X_n)$.
- ▶ Cuando los componentes tienen la misma función distribución G , (T_1, T_2) tienen una distribución distorsionada basada en G .

Tiempos de vida de sistemas

- ▶ Tiempos de vida de sistemas coherentes (conectividad en redes) $T_1 < T_2$ basados en los mismos componentes (X_1, \dots, X_n) .
- ▶ Prededecir T_2 a partir de $T_1 = t$ para $t > 0$.
- ▶ El caso más usual es $T_1 = \min(X_1, \dots, X_n)$.
- ▶ Cuando los componentes tienen la misma función distribución G , (T_1, T_2) tienen una distribución distorsionada basada en G .
- ▶ Esto también se puede aplicar a los datos ordenados (censurados) en una muestra (son sistemas k-out-of-n).

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

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

$\partial_1 D(u, v) = \partial_1 C(u, v) + \partial_2 C(v, u) - \partial_1 C(u, u) - \partial_2 C(u, u)$, 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 $u \leq v \leq 1$.

Predicciones



SOCIEDAD

Fernando Simón: "España no va a tener, como mucho, más allá de algún caso diagnosticado"

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

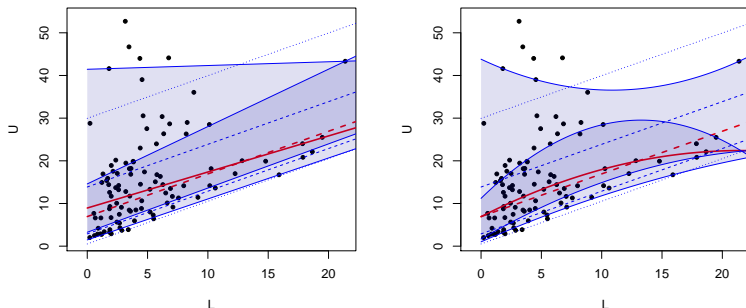


Figura: Curvas QR empíricas para los datos pareados (L, U) asociados a datos independientes (X, Y) exponenciales con medias $\mu = 10$ y grado 1 (izquierda) y 2 (derecha).

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.

Fin

- ▶ 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?