

# Funciones de influencia

Gabriel V. Montes-Rojas

# Derivadas direccionales de estadísticos de distribución

- Sea  $y$  una variable aleatoria con función de distribución  $F(y)$  y con densidad  $F'(y) = f(y)$ .
- Sea  $T(F)$  un estadístico de distribución que es infinitesimalmente robusto. Ejemplos: media, cuantil  $\tau$ , Gini.
- La función de influencia es la derivada direccional de  $T(F)$  evaluada en  $F$ , que mide el efecto de una perturbación en  $F$ . La definición de **derivada direccional** es la siguiente: Si  $H$  es otra distribución, si los datos siguen una distribución *un poco* diferente de  $F$ , pero que se “aproxima a”  $F$ , entonces medir la influencia de usar  $H$  en vez de  $F$  es la derivada direccional de  $T$  en  $F$  en la dirección de  $H$ :

$$IF(T) = \nabla T_{F \rightarrow H} = \frac{d}{dt} T(tH + (1-t)F)|_{t=0} = \lim_{t \rightarrow 0} \frac{T(tH + (1-t)F) - T(F)}{t}$$

- Otra forma de verlo es asumir que  $x$  es un valor adicional en una muestra grande que “perturba” la distribución con masa de probabilidad  $\delta_x$ .  $H$  es entonces  $H(y) = 1[x \geq y]$  y  $h(y)$  es una función de densidad que es cero excepto en  $x$ . Entonces,

$$IF(x; T; F) = \lim_{t \rightarrow 0} \frac{T(t\delta_x + (1-t)F) - T(F)}{t}$$

# Derivadas direccionales de estadísticos de distribución

- Una propiedad de IF es  $E[IF(X; T; F)] = \int_{-\infty}^{\infty} IF(x; T; F)f(x)dx = 0$ .
- Entonces definamos la función de influencia recentrada (recentered influence function, RIF)

$$RIF(x; T; F) = T(F) + IF(x; T; F)$$

Tenemos que  $E[RIF(x; T; F)] = E[T(F)] + \int_{-\infty}^{\infty} IF(x; T; F)f(x)dx = T(F)$ .

# Jackknife

- Una forma empírica de aproximar y estimar la IF es usar el método llamado *jackknife*.
- Definamos  $T_n$  como el estimador de una muestra empírica  $F_n, \{y_1, y_2, \dots, y_n\}$ . Entonces el pseudo-valor jackknife de la observación  $i$  es  $T_{ni}^* = nT_n - (n-1)T_{n-1}(y_1, y_2, \dots, y_{i-1}, y_{i+1}, \dots, y_n) = nT_n - (n-1)T_{n-1}$ . Entonces una aproximación a IF es usar  $F_n$  en vez de  $F$  y  $-1/(n-1)$  en vez de  $t$ , tal que

$$IF(y_i; T; F_n) = \frac{T\left(\frac{n}{n-1}F_n - \frac{1}{n-1}\delta_{y_i}\right) - T(F_n)}{-1/(n-1)} = (n-1)(T_n - T_{n-1}) = T_{ni}^* - T_n$$

## IF y RIF de la media

- Sea  $y$  una variable aleatoria con media  $\mu_F = E[y] = T_\mu(F)$ .



$$IF(T_\mu) = \nabla T_{\mu, F \rightarrow H} = \lim_{t \rightarrow 0} \frac{T_\mu(tH + (1-t)F) - T_\mu(F)}{t} = \mu_H - \mu_F$$



$$IF(x; T_\mu; F) = x - \mu_F$$



$$RIF(x; T_\mu; F) = x$$

Esto muestra que la influencia de una observación puede ser tan grande como sea esa observación.

IF y RIF del cuantil  $\tau$ 

- Sea  $y$  una variable aleatoria con cuantil  $\tau$ ,  $q_\tau = T_{q_\tau}(F) = F^{-1}(\tau)$ .



$$IF(T_{q_\tau}) = [\tau - H(q_\tau)]/f(q_\tau)$$

Prueba: Sea  $w(t)$  el cuantil  $\tau$  de  $tH + (1-t)F$ , tal que  $tH(w(t)) + (1-t)F(w(t)) = \tau$  y además  $w(0) = q_\tau$ .

$$\frac{d\tau}{dt} = 0 = H(w(t)) - F(w(t)) + w'(t)[th(w(t)) + (1-t)f(w(t))]$$

tal que

$$w'(t) = \frac{F(w(t)) - H(w(t))}{th(w(t)) + (1-t)f(w(t))}.$$

Entonces,

$$IF(T_{q_\tau}) = \nabla T_{q_\tau, F \rightarrow H} = w'(0) = [\tau - H(q_\tau)]/f(q_\tau),$$

$$RIF(x; T_{q_\tau}; F) = q_\tau + \frac{\tau - 1[y \leq \tau]}{f(q_\tau)}.$$

# IF y RIF de la varianza

- Sea  $y$  una variable aleatoria con varianza  
 $\sigma_F^2 = \int (y - \mu_F)^2 f(y) dy = \int (y - \mu_F)^2 dF.$



$$IF(T_{\sigma_F^2}) = \sigma_H^2 - \sigma_F^2 + (\mu_H - \mu_F)^2$$

Prueba:

$$\begin{aligned} \frac{d}{dt} \int (y - t\mu_H - (1-t)\mu_F)^2 [th(y) + (1-t)f(y)] dy \Big|_{t=0} &= \int (y - \mu_F)^2 (dH - dF) + (\mu_F - \mu_H) \int (y - \mu_F)^2 dF \\ &= -\sigma_F^2 + \int (y - \mu_F)^2 dH = -\sigma_F^2 + \int (y - \mu_H + \mu_H + \mu_F)^2 dH = \sigma_H^2 - \sigma_F^2 + (\mu_H - \mu_F)^2 \end{aligned}$$

$$RIF(x; T_{q_\tau}; F) = (x - \mu_F)^2$$

## IF y RIF del Gini

- Sea  $y$  una variable aleatoria con dominio en  $\mathbb{R}^+$ . El coeficiente de Gini es una medida estándar de la desigualdad. La forma más fácil de entender es a partir de la curva de Lorenz (el porcentaje acumulado hasta distintos niveles de  $y$ ), ver gráfico.

$$G_F = \frac{1}{2\mu_F} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x)f(y)|x-y|dx dy = \frac{1}{\mu_F} \int F(y)(1-F(y))dy$$

$$= \frac{1}{2\mu_F} \int_0^1 \int_0^1 |Q_y(\tau_1) - Q_y(\tau_2)|d\tau_1 d\tau_2$$

$$IF(T_{G_F}) = \frac{\mu_F - \mu_H}{\mu_F} G_F + \frac{1}{\mu_F} \int [H(y) - F(y)][1 - 2F(y)]dy$$

**Prueba:** Notemos que  $\mu_F G_F = \int F(y)(1-F(y))dy$ , entonces definamos  $\mu_{tH+(1-t)F} G_{tH+(1-t)F} = \int (tH(y) + (1-t)F(y))(1-tH(y) - (1-t)F(y))dy$ . Tomemos derivadas con respecto a  $t$ , y evaluemos en  $t=0$ :

$$\frac{d}{dt} [\mu_{tH+(1-t)F} G_{tH+(1-t)F}]|_{t=0} = (\mu_H - \mu_F)G_F + \mu_F IF(T_{G_F})$$

$$\frac{d}{dt} \left[ \int tH(y) + (1-t)F(y)(1-tH(y) + (1-t)F(y))dy \right]|_{t=0} = \int [H(y) - F(y)][1 - 2F(y)]dy$$



## IF y RIF del Gini

- $IF(x; T_G; F) = -\frac{\mu_F + x}{\mu_F} G_F + 1 - \frac{x}{\mu_F} + \frac{2}{\mu_F} \int_0^x F(y) dy$
- $RIF(x; T_G; F) = -\frac{x}{\mu_F} G_F + 1 - \frac{x}{\mu_F} + \frac{2}{\mu_F} \int_0^x F(y) dy$

# IF y RIF de la tasa de pobreza

- Sea  $y$  una variable aleatoria con dominio en  $\mathbb{R}^+$  y sea  $z$  el valor de la canasta que define la línea de pobreza (el individuo  $i$  es pobre si  $y_i \leq z$ ). La tasa de pobreza es  $P_F = \int_0^z F(y) dy$ .
- $IF(T_P; F) = \frac{d}{dt} \int_0^z [th(y) + (1-t)f(y)] dy|_{t=0} = \int_0^z (dH - dF)$
- $RIF(x; T_P; F) = 1[x \leq z]$
- El índice  $FGT(\alpha)$  ( Foster, Greer, Thorbecke, 1984) de pobreza es  $T_{FGT_\alpha}(F) \int_0^z (1 - y/z)^\alpha f(y) dy$ , con  $\alpha \geq 0$ .
- $IF(T_{FGT_\alpha}; F) = \frac{d}{dt} \int_0^z (1 - y/z)^\alpha [th(y) + (1-t)f(y)] dy|_{t=0} = \int_0^z (1 - y/z)^\alpha h(y) dy - T_{FGT_\alpha}$
- $RIF(x; T_{FGT_\alpha}; F) = (1 - x/z)^\alpha 1[x \leq z]$

## Regresión RIF

- Las funciones RIF se pueden usar en modelos de regresión en modelos condicionales,  $Y|X$ .
- Estamos interesados en el efecto marginal de un cambio en  $X$ . Sea  $F_X$  la distribución de  $X$  y  $G_X$  una perturbación. Definamos  $G_Y^*$  como la distribución inducida en  $Y$  luego de un cambio en  $X$ .

$$F_Y(y) = \int F_{Y|X}^{-1}(y|X = x) \cdot dF_X(x)$$

$$G_Y^*(y) = \int F_{Y|X}^{-1}(y|X = x) \cdot dG_X(x)$$

- $T(F_Y) = \int RIF(y; T; F_Y) dF_Y(y) = \int \int RIF(y; T; F_Y) dF_{Y|X}(y|X = x) dF_X(x) = \int E[RIF(y; T; F_Y)|X = x] dF_X(x)$ . Entonces,

$$\frac{dIF(F_Y \rightarrow (1-t)F_Y + tG_Y^*)}{dt} \Big|_{t=0} = \int E[RIF(y; T; F_Y)|X = x] d(F_X - G_X)(x).$$

- Si  $X_j$  es continua, el cambio marginal es

$$\int dE[RIF(y; T; F_Y)|X = x] / dx d(F_X)(x).$$

# Regresión RIF

- Firpo, Fortin and Lemieux (2009) propone el siguiente modelo lineal:

$$E[RIF(Y; T)] = X\beta + \epsilon$$

para cualquier estadístico distribucional  $T(F_Y)$ .

- La IF de un criterio de evaluación social se puede ver como una medida local del impacto de una política. Rothe (2010) lo llama **efectos de política distribucional**.

# Regresión RIF

- Firpo, Fortin and Lemieux (2009) aplican este criterio a los cuantiles no condicionales, **unconditional quantile regression**.
- Para cuantiles no podemos usar la ley de esperanzas iteradas, tal que  $E[Y] = E[E(Y|X)]$  pero

$$F_Y^{-1}(\tau) \neq E_X[F_{Y|X}^{-1}(\tau|X)],$$

lo que significa que no podemos recuperar el efecto sobre los cuantiles no condicionales a través de cuantiles condicionales.

- Entonces proponen una regresión RIF de  $RIF(Y, \hat{q}_\tau)$  on  $X$ , donde  $\hat{q}_\tau$  es el cuantil  $\tau$  no condicional de  $Y$  y  $RIF()$  es la RIF de cuantiles.

# Regresión RIF

- Mirando a los resultados de cada individuo como una función de política y de los tipos de individuos, podemos usar la descomposición contrafactual a la Oaxaca-Blinder.
- Supongamos  $A$  y  $B$  dos grupos (tiempo  $t_0$  y  $t_1$ ; hombres y mujeres; sindicalizados y no sindicalizados). Entonces,

$$T(F_Y^B) - T(F_Y^A) = \bar{X}_B(\beta_B - \beta_A) + (\bar{X}_B - \bar{X}_A)\beta_A,$$

donde el primer término se refiere el **efecto explicado, dotación o composición** y el segundo como **efecto precio o no explicado**.

# RIFREG en STATA

- Usar el contenido de rifreg.zip en <https://faculty.arts.ubc.ca/nfortin/datahead.html>
- Copiar los comandos al mismo directorio en el que se va a trabajar.
- `rifreg Y X, quantile(0.1)`
- `rifreg Y X, quantile(0.5)`
- `rifreg Y X, quantile(0.9)`
- `rifreg Y X, gini`
- `rifreg Y X, variance`

# Bibliografía

- Ariza, J.F. and Montes-Rojas, G.V. (2018) "Decomposition Methods for Analyzing Inequality Changes in Latin America 2002-2014," forthcoming Empirical Economics.
- Bitler, M. P., Gelbach, J. B. and Hoynes, H. W. (2006) "What Mean Impacts Miss: Distributional Effects of Welfare Reform Experiments, American Economic Review, 96(4), 9881012.  
<https://gspp.berkeley.edu/assets/uploads/research/pdf/BGH-AER-2006.pdf>
- Essama-Nssah, B. and Lambert, P.J (2015) "Chapter 6. Influence Functions for Policy Impact Analysis, in Inequality, Mobility and Segregation: Essays in Honor of Jacques Silber Research on Economic Inequality, Volume 20, 135159. <http://www.ecineq.org/milano/WP/ECINEQ2011-236.pdf>
- Huber, P.J and Ronchetti, E.M. (2009) Robust Statistics (2nd ed.). Wiley.
- Firpo, S., Fortin, N.M. and Lemieux, T. (2009) "Unconditional Quantile Regressions, Econometrica, 77(3), 953-973. [https://economics.ubc.ca/files/2013/05/pdf\\_paper\\_thomas-lemieux-unconditional-quantile-regressions.pdf](https://economics.ubc.ca/files/2013/05/pdf_paper_thomas-lemieux-unconditional-quantile-regressions.pdf)
- Firpo, S., Fortin, N.M. and Lemieux, T. (2011) "Chapter 1. Decomposition Methods in Economics, in Orley Ashenfelter and David Card (eds.) Handbook of Labor Economics, Vol 4A, 2-102. <https://www.nber.org/papers/w16045.pdf>
- Rothe, C. (2010) "Nonparametric Estimation of Distributional Policy Effects," Journal of Econometrics, 155, 5670.
- [https://www.stata.com/meeting/germany16/slides/de16\\_vankerm.pdf](https://www.stata.com/meeting/germany16/slides/de16_vankerm.pdf)