

Trabajo preparado para la Asociación Argentina de Economía Política

Progresos en Economía del Sector Público

El Impacto Distributivo de las Políticas Sociales *

Sebastián Galiani **

Leonardo Gasparini ***

* Este trabajo fue preparado para el volumen de Progresos en Economía del Sector Público de la Asociación Argentina de Economía Política. Agradecemos los comentarios y el estímulo de Alberto Porto y Fernando Navajas. Parte del trabajo se nutre del capítulo 9 de Gasparini, Cicowiez y Sosa Escudero (2010).

** Washington University in Saint Louis. Investigador asociado de CEDLAS, GRADE y JPAL. galiani@wustl.edu

*** Centro de Estudios Distributivos, Laborales y Sociales (CEDLAS), Facultad de Ciencias Económicas, Universidad Nacional de La Plata. leonardo@depeco.econo.unlp.edu.ar

1. Introducción

La evaluación rigurosa de programas públicos constituye un área de enorme relevancia práctica dentro de la Economía. Contar con información cuantitativa sobre los probables efectos de una intervención es valioso para el diseño y la modificación de las políticas públicas. La evaluación global de un programa es incompleta sin alguna estimación de la distribución de sus beneficios y de su impacto redistributivo. ¿Quiénes se benefician y perjudican ante la implementación de un programa? ¿Cómo modifica el programa la distribución del bienestar? Estas preguntas han atraído desde hace mucho tiempo la atención de los economistas, quienes han ido desarrollando un instrumental cada vez más amplio y sofisticado para contribuir con respuestas cuantitativas más precisas.

El objetivo de este trabajo es reseñar brevemente los métodos tradicionales de evaluación del impacto distributivo de las políticas públicas y discutir algunos de los avances más relevantes en los últimos veinte años. Por razones de espacio el capítulo se concentra en la evaluación de programas sociales, dejando de lado otras intervenciones públicas y su financiamiento. Por las mismas razones sólo se resumen los progresos en el análisis del impacto sobre la distribución personal del ingreso, ignorando los efectos sobre la distribución regional o funcional.

El trabajo resume los progresos a nivel internacional con algunas referencias a la experiencia argentina. A menudo se subrayan las deficiencias del sector público argentino en actuar eficazmente contra la pobreza, la desigualdad y otros problemas sociales. Su intervención suele ser considerada escasa, poco focalizada y en ocasiones incluso regresiva. En este contexto las estimaciones del impacto distributivo de las intervenciones de política social son particularmente relevantes.

El resto del trabajo está ordenado de la siguiente forma. La sección 2 discute conceptualmente el problema empírico de la evaluación del impacto distributivo de un programa público. El enfoque tradicional y de uso más extendido (*benefit-incidence analysis*) es presentado e ilustrado en la sección 3. Mientras que la sección 4 discute alternativas para caracterizar cambios en la estructura de beneficios de un programa, la sección 5 resume la nueva literatura sobre incidencia distributiva marginal. A menudo las demandas de política económica requieren la evaluación *ex-ante* de programas alternativos con diseños, características y magnitudes diferentes. La sección 6 presenta algunos instrumentos para afrontar estos desafíos. La sección 7 presenta un conjunto de estrategias empíricas modernas para la construcción del contrafactual de la existencia de un programa, necesario para realizar interpretaciones causales de los resultados. El trabajo se cierra en la sección 8 con breves comentarios finales.

2. El problema de la evaluación del impacto distributivo

El objetivo central de todo estudio de incidencia distributiva de programas públicos es comparar dos distribuciones del ingreso (u otra variable que aproxime el bienestar): (i)

la correspondiente al caso en que el programa existe, y (ii) aquella resultante si el programa no existiera. La diferencia entre ambas distribuciones puede ser interpretada como el impacto redistributivo del programa.

Supongamos que hay un programa en funcionamiento que queremos evaluar y que provee transferencias. Llamemos $\{Y_i^c\}$ a la distribución del ingreso vigente, y $\{Y_i^s\}$ a la distribución en la situación contrafactual en la que el programa no existe. Dado que el programa está vigente se trata de un análisis de incidencia *ex-post*. Para cada persona i el beneficio del programa está dado por

$$(2.1) \quad b_i = Y_i^c - Y_i^s$$

donde Y_i^c representa el ingreso vigente y Y_i^s el ingreso contrafactual en la situación de inexistencia del programa. Un típico estudio de incidencia provee dos resultados principales contruidos a partir de las estimaciones de la ecuación (2.1): (i) una evaluación del grado de focalización de la política pública, en términos de la relación entre la distribución de los beneficios b_i y la distribución del ingreso Y_i^s ; y (ii) una evaluación del impacto redistributivo de la política, lo cual requiere comparar las distribuciones real $\{Y_i^c\}$ y contrafactual $\{Y_i^s\}$.

Supongamos, por simplicidad, una población de personas que viven solas, perciben un ingreso por sus actividades de mercado Y_i^{cm} , y reciben por parte del Estado transferencias monetarias t_i^m y transferencias en especie valoradas en t_i^e , asociadas al programa bajo estudio. Por simplicidad, asumamos que éste es el único programa vigente y que se financia con fondos externos (ej. donaciones internacionales), de manera de obviar los temas impositivos. El ingreso Y_i^c es entonces

$$(2.2) \quad Y_i^c = Y_i^{cm} + t_i^m + t_i^e$$

En ausencia del programa, el ingreso de la persona i es simplemente su ingreso de mercado Y_i^{sm}

$$(2.3) \quad Y_i^s = Y_i^{sm}$$

Existen múltiples razones por las cuales el ingreso de mercado después de las transferencias Y_i^{cm} puede ser diferente del ingreso antes de la intervención Y_i^{sm} . Supóngase que el gobierno transfiere \$300 por mes a una persona pobre, que lo usa de colateral para acceder a un préstamo informal que le permite comprar una motocicleta con la cual incrementa en \$50 sus ganancias mensuales como vendedor callejero (neto de los costos del préstamo). En este caso el ingreso de mercado post-intervención Y_i^{cm} es \$50 superior al ingreso antes de la intervención Y_i^{sm} . Supóngase, alternativamente, que sabiendo que el gobierno transfiere ahora \$300 por mes a una persona pobre, una ONG deja de otorgarle un subsidio mensual en alimentos por \$50. En este ejemplo, el ingreso Y_i^{cm} resulta \$50 inferior al ingreso Y_i^{sm} .

Combinando las ecuaciones (2.1) a (2.3)

$$(2.4) \quad b_i = t_i^m + t_i^e + (Y_i^{cm} - Y_i^{sm})$$

De la ecuación (2.4) se desprende que la estimación de los beneficios b_i del programa público requiere tres pasos fundamentales: (i) obtener información sobre las transferencias monetarias t_i^m recibidas por cada persona, (ii) obtener información y valorizar las transferencias en especie t_i^e , y (iii) estimar los cambios en el ingreso de mercado ($Y_i^{cm} - Y_i^{sm}$) que pudieran haber sido generados por la presencia de la política. El primer punto no ofrece dificultades significativas si contamos con encuestas que releven información sobre ingresos provenientes de subsidios monetarios estatales. El segundo punto resulta más complicado, dado que, por un lado muchas encuestas no contienen información detallada sobre transferencias en bienes y servicios, y por otro lado el ejercicio de valorizarlas es conceptualmente complicado. Supóngase que un niño recibe una vacuna gratuita en un hospital público. La estimación y traducción en términos monetarios del valor de la vacuna para el niño y su familia es un tema plagado de problemas conceptuales y empíricos.

La ecuación (2.4) exige un tercer paso para la estimación de b_i : la consideración del cambio en los ingresos de mercado debido a la existencia de los programas de transferencias. Este paso implica un desafío metodológico formidable, ya que Y_i^{sm} es un valor contrafactual, obviamente no observable. La sección 7 examina con detalle este punto.

3. Enfoques tradicionales: *benefit-incidence*

Un estudio básico de incidencia del gasto público (*benefit-incidence analysis*) realiza algunos supuestos simplificadores que permiten estimar (2.4) de manera sencilla. El primero es que son sólo los usuarios o participantes los que se benefician de un programa social. Este supuesto implica ignorar los potenciales beneficios generados en aquellas personas que no usan directamente el servicio provisto públicamente (externalidades) y en los factores usados para producir el servicio. Para el caso de educación primaria pública, por ejemplo, este supuesto implica considerar como beneficiarios a los alumnos de las escuelas primarias públicas y sus familias, quienes no deben pagar por la educación del niño, e ignorar como beneficiarios al resto de la sociedad y a los maestros, quienes podrían verse perjudicados (incluso en el largo plazo) si el gobierno decidiera no proveer más educación pública. Naturalmente, el supuesto de restringir el conjunto de beneficiarios a los participantes del programa implica ignorar las repercusiones y efectos de equilibrio general que pueda generar el gasto en el programa.¹

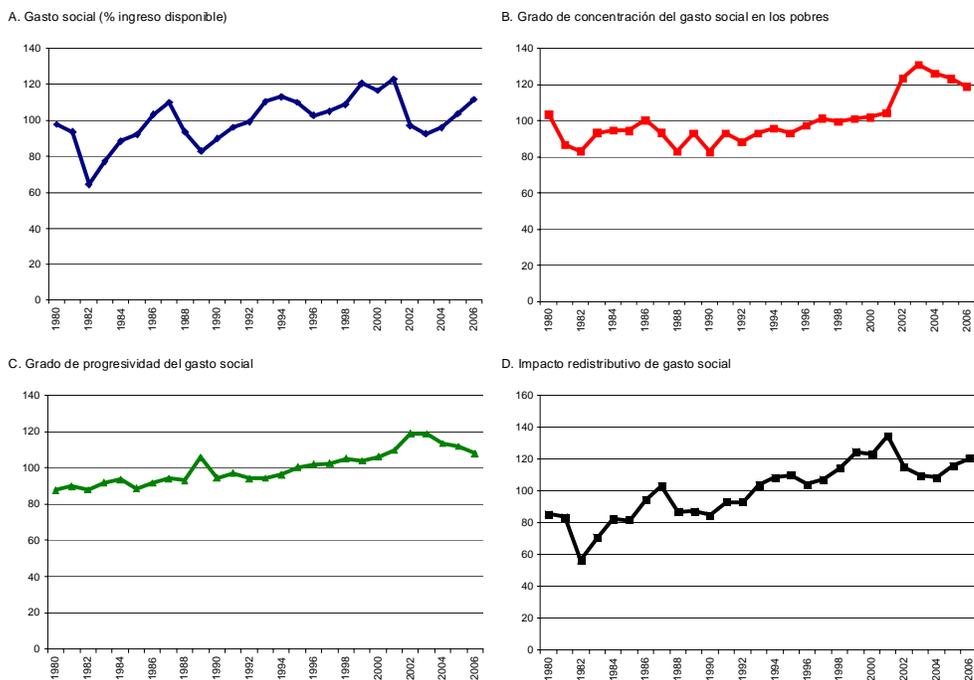
¹ Por ejemplo, el mayor gasto público podría implicar un déficit imposible de financiar que desemboque en un proceso inflacionario que afecte a toda la población. O, alternativamente, el mayor gasto público puede aliviar el efecto de una recesión y favorecer a toda la población.

Una vez identificados los beneficiarios, debe estimarse el valor del beneficio que el programa genera en cada uno. La práctica usual de un estudio de incidencia en esta etapa es (i) ignorar ajustes en el comportamiento, es decir $Y_i^{sm} = Y_i^{cm}$, (ii) estimar el beneficio de una transferencia monetaria por su valor nominal t_i^m , y (iii) estimar el beneficio de un subsidio en especie (bienes o servicios) en función del costo de provisión para el Estado c_i . Lo usual, de hecho, es asumir que ese costo no varía entre beneficiarios, o lo hace sólo en función de algunas variables (ej. por área geográfica). Por ejemplo, es usual que el beneficio de la educación pública primaria gratuita en una determinada área se asuma idéntico para todos los participantes, e igual al gasto público total en ese servicio sobre el número de asistentes en esa área.

Para implementar un estudio de incidencia es necesario contar con información del gasto público en cada programa, y una encuesta que releve algún indicador de bienestar individual y la participación de las personas en los programas públicos vigentes. Dados estos requerimientos, si bien la literatura sobre incidencia distributiva del gasto social se desarrolló en los 1970s (Aaron y McGuire, 1970; Meerman, 1979; Selowsky, 1979), recién en las últimas dos décadas proliferó alentada por la multiplicación de encuestas de hogares, la creciente capacidad de procesamiento gracias al desarrollo de las computadoras, y la mayor facilidad de acceso a la cuentas públicas (Van de Walle y Nead, 1995; Bourguignon y da Silva, 2003; Demery, 2003).

Petrei (1988), en un trabajo pionero, estudia el impacto distributivo de los gastos públicos en educación, salud, seguridad social, vivienda, agua potable y alcantarillado para cinco países de Latinoamérica. En un estudio minucioso concentrado en Argentina Dieguez, Llach y Petrecolla (1991) estiman el subsidio neto asociado a la política social. La Dirección de Gastos Sociales Consolidados ha realizado una importante contribución con varios trabajos que evalúan la totalidad del gasto en sectores sociales entre los cuales se encuentran los estudios de Flood *et al.* (1994), Gasparini, Bonari y Fassio (1998), DNPGS (1999), DGSC (2002) y Bertranou y Bonari (2003), quienes han utilizado información de la Encuesta Permanente de Hogares (EPH), la Encuesta Nacional de Gastos de Hogares (ENGH) y la Encuesta de Condiciones de Vida (ECV). La reciente dificultad en acceder a datos de estas encuestas sumada a la falta de una ECV desde 2001 han implicado un virtual estancamiento de los estudios de incidencia global del gasto en la década del 2000. En contraste, han florecido estudios que analizan el impacto de programas de asistencia social específicos como el Trabajar y el Programa Jefes de Hogar a partir de microdatos de la EPH. Al limitarse a evaluar programas específicos la mayoría de estos estudios utiliza enfoques cuasi experimentales que exceden la metodología de *benefit-incidence*.

Figura 3.1
Incidencia del gasto social en Argentina



Fuente: Elaboración propia en base a Gasparini y Cruces (2009).

Nota: A: gasto social como porcentaje del ingreso disponible, B: índice de concentración (multiplicado por -1), C: índice de progresividad de Kakwani, D: índice de Reynolds-Smolenski (ver Lambert, 2001). En todos los casos series estandarizadas con promedio 1980-2006=100.

La figura 3.1 resume los resultados de Gasparini y Cruces (2009) al evaluar la incidencia del gasto público social (GPS) en Argentina. La evolución del GPS como porcentaje del ingreso disponible ha sido errática: creció durante los noventa, tendencia que fue abruptamente interrumpida por la crisis económica del 2001-2002. El gasto social creció más rápido en el período 2003-2006 (y muy posiblemente en lo que siguió de esa década). La estructura del GPS también varió durante el período bajo análisis. El principal cambio es el aumento de 15 a 25 por ciento en la participación de las transferencias monetarias en programas sociales y laborales. Este cambio se debe a la aparición de nuevos programas de empleo de emergencia a mediados de los noventa y a la implementación de amplios programas de transferencias de dinero luego de la crisis del 2001-2002, principalmente el Programa Jefes de Hogar.

La focalización del GPS (panel B) se incrementó a lo largo del tiempo, particularmente desde la implementación del Jefes en el año 2002. La progresividad del GPS (panel C) aumentó durante el período bajo análisis en gran parte impulsada por la creciente desigualdad de ingresos: una estructura de gasto dada es más progresiva si la distribución del ingreso subyacente de referencia se vuelve más desigual. El impacto distributivo del gasto social (panel D) varió durante los ochenta como resultado de la introducción de cambios en el alcance del presupuesto y de reasignaciones entre

programas.² Durante los noventa el impacto del GPS creció moderadamente, debido a incrementos presupuestarios y en el grado de progresividad (en parte explicado por el deterioro distributivo). Luego de una caída en el impacto igualador por la crisis del 2001-2002, la serie retoma su comportamiento creciente en la recuperación económica. Como en estudios previos Gasparini y Cruces (2009) encuentran que si bien la política fiscal (gasto social más su financiamiento) reduce el nivel de desigualdad, no ha tenido un efecto significativo sobre su evolución en las últimas décadas. Los cambios en el impacto redistributivo de la política fiscal fueron relativamente menores en relación a las grandes variaciones en la desigualdad de mercado inducidas por otros factores.

4. Caracterización de los cambios en incidencia

Es relevante explorar las razones inmediatas detrás de la estructura de incidencia de un programa. Supongamos que estamos interesados en caracterizar la estructura de incidencia del programa de escuelas primarias públicas. La participación del grupo j (típicamente un percentil) en los beneficios de ese programa puede escribirse como

$$(4.1) \quad s_j = m_j \cdot \frac{a_j}{a} \cdot \frac{p_j}{p} \cdot \frac{c_j}{c}$$

donde m_j es la participación del grupo j en la población objetivo (niños en edad escolar), a_j es la tasa de asistencia a la escuela primaria, p_j la proporción de asistentes que eligen la provisión pública y c_j los costos medios de provisión del grupo j . Existen cuatro razones por las cuales s_j puede diferir entre grupos: (i) que la distribución de personas en la población objetivo no sea uniforme, (ii) que la tasa de asistencia difiera entre grupos, (iii) que la proporción de los que eligen provisión pública no sea idéntica, y (iv) que los costos medios de provisión difieran entre grupos. El cuadro 4.1 reporta los valores de m_j , a_j , y p_j por quintiles para el caso de la educación primaria y secundaria en Argentina 2009, asumiendo costos de provisión iguales ($c_j=c$). Nótese que la mayor incidencia del subsidio público a la educación primaria en el quintil 1 es producto de una mayor proporción de niños en ese estrato y de una tasa de asistencia a establecimientos públicos muy superior al promedio. El grado de focalización del gasto en educación media es inferior dada una algo menor concentración de jóvenes en edad de asistir al secundario en los estratos inferiores de ingreso (comparado al nivel primario) y tasas de asistencia significativamente menores en relación al resto de la población.

Cuadro 4.1
Descomposición de la estructura de incidencia
Educación primaria y secundaria pública en Argentina

² El impacto redistributivo del gasto puede medirse como el gasto público como proporción del ingreso disponible multiplicado por la progresividad de los programas públicos.

Primaria							
		1	2	3	4	5	Total
Niños [7-12] (% del total)	mj	34.8	24.4	18.3	14.2	8.3	100.0
Tasa de asistencia primario	aj	97.7	98.8	98.3	98.4	99.4	98.3
Tasa de asistencia pública	pj	89.9	73.4	61.6	44.1	27.0	68.9
Incidencia estimada		45.1	26.1	16.3	9.1	3.3	100.0

Media							
		1	2	3	4	5	Total
Jóvenes [13-17] (% del total)	mj	31.9	23.9	20.0	14.5	9.7	100.0
Tasa de asistencia secundario	aj	67.7	76.0	83.7	91.5	90.9	78.6
Tasa de asistencia pública	pj	91.9	78.7	67.0	55.2	37.1	71.2
Incidencia estimada		35.5	25.5	20.0	13.1	5.9	100.0

Fuente: elaboración propia sobre la base de microdatos de la EPH.

Es posible profundizar la caracterización de los cambios en la estructura de incidencia aplicando una metodología de microdescomposiciones. La idea detrás de esta metodología consiste en simular la decisión contrafactual de consumir un servicio en el sector público en el momento t_1 si ciertos factores fueran aquellos del momento t_2 en lugar de los observados en t_1 . Sea b_{ijt} una variable binaria que identifica si la persona i consume el servicio j en el sector público en el momento t . Puede escribirse, $b_{ijt} = q_{ijt} \cdot a_{ijt} \cdot p_{ijt}$ donde q es igual a 1 si la persona califica para el servicio y 0 en otro caso, a es igual a 1 si la persona usa el servicio dado que es elegible, y p es igual a 1 si la persona elige la provisión pública gratuita, dado que consume el servicio. Es usual asumir q determinístico, dependiendo de un vector de características observables X_i y de un vector de parámetros α que determina la regla de acceso al servicio j . Las variables a y p , en cambio, son aleatorias y dependen de X_i , de parámetros y de factores inobservables u_{it}

$$(4.2) \quad a_{ijt} = A(X_{it}, u_{it}, \beta_{jt}), \quad p_{ijt} = P(X_{it}, u_{it}, \gamma_{jt})$$

Una medida de la incidencia distributiva del programa j es una combinación de la distribución de b y ciertas características Y del vector X , típicamente el ingreso familiar ajustado por factores demográficos (ej. ingreso per cápita)

$$(4.3) \quad I_{jt} = I(\{b_{ijt}\}, \{Y_{it}\})$$

Luego,

$$(4.4) \quad I_{jt} = F(\{X_{it}\}, \{u_{it}\}, \alpha_{jt}, \beta_{jt}, \gamma_{jt})$$

Es posible descomponer el cambio en I entre t_1 y t_2 en tres efectos. El efecto “participación” captura el cambio de la incidencia resultante de un cambio en los parámetros que gobiernan la decisión de consumir un servicio (β)

$$(4.5) \quad PA_j = F(\{X_{it2}\}, \{u_{it2}\}, \alpha_{jt2}, \beta_{jt2}, \gamma_{jt2}) - F(\{X_{it1}\}, \{u_{it1}\}, \alpha_{jt1}, \beta_{jt1}, \gamma_{jt1})$$

El efecto “provisión pública” mide el cambio de la incidencia como consecuencia de cambios en los parámetros que gobiernan la decisión público/privada (γ)

$$(4.6) \quad PP_j = F(\{X_{i2}\}, \{u_{i2}\}, \alpha_{j2}, \beta_{j1}, \gamma_{j2}) - F(\{X_{i2}\}, \{u_{i2}\}, \alpha_{j2}, \beta_{j1}, \gamma_{j1})$$

El efecto “características de la población” mide los cambios en la incidencia resultantes de cambios en la distribución de características observables e inobservables de la población.

$$(4.7) \quad PO_j = F(\{X_{i2}\}, \{u_{i2}\}, \alpha_{j2}, \beta_{j1}, \gamma_{j1}) - F(\{X_{i1}\}, \{u_{i1}\}, \alpha_{j2}, \beta_{j1}, \gamma_{j1})$$

Asumiendo que α no cambia, el cambio en I se expresa como ³

$$(4.8) \quad \Delta I_j = PA_j + PP_j + PO_j$$

En una implementación típica de esta metodología el analista observa Q , α y X , asume una forma funcional para A y P , propone un índice I y estima los parámetros β y γ , y el vector de inobservables u . Gasparini (2006) aplica esta metodología a varios servicios de salud en Argentina. El índice de concentración para el programa público de atención médica pre-natal, por ejemplo, cayó 4.8 puntos (en valor absoluto) entre 1997 y 2001, lo cual implica una caída sustancial en el grado de focalización. El efecto “características de la población” contribuye con 3.5 puntos a esa disminución. La fuerte caída de los ingresos en los estratos medios de la población en el período considerado que implicaron cambios en las decisiones público/privada a favor de hospitales públicos es el principal fenómeno detrás de la relevancia de este factor.

5. Incidencia marginal

Los resultados presentados hasta ahora caracterizan la estructura actual de beneficiarios de un programa, pero nada nos dicen acerca de quienes se beneficiarán de una próxima expansión, o se perjudicarán ante una contracción del programa. La información de incidencia *marginal* es muy valiosa, ya que los gobiernos típicamente toman decisiones sobre variaciones en un programa. Por ejemplo, se discute a menudo sobre si expandir o no el programa de hospitales públicos, pero más raramente se debate sobre su existencia.

En ocasiones la distribución de beneficios medios y marginales coinciden. Un ejemplo es un aumento proporcional en el monto del subsidio de un programa de transferencias monetarias. En cambio, en general los beneficios en el margen difieren de los beneficios promedio. La provisión pública de servicios de infraestructura (agua, saneamiento, electricidad, caminos) suelen ser casos extremos, dado que las expansiones justamente benefician a personas que no contaban con el servicio. La incidencia marginal del gasto

³ La metodología es *path-dependent* por lo que es conveniente explorar los resultados de distintas secuencias de la descomposición.

en infraestructura suele tener un sesgo pro-rico inferior al de los resultados de incidencia promedio.

Mientras que la identificación de los beneficiarios actuales de un programa público es sencilla, las posibilidades de identificar a quienes se han beneficiado de una expansión son limitadas, dada la información usualmente disponible en una encuesta. Naturalmente, las proyecciones de los potenciales beneficiarios de expansiones futuras – la información más valiosa para tomar decisiones de política - sólo pueden hacerse mediante estimaciones. Recientemente, se han propuesto varios métodos para estimar incidencia marginal.⁴ Lo ideal sería contar con encuestas de panel que reporten información periódica de las mismas personas y registren su uso de servicios provistos públicamente a medida que los programas se expanden o contraen. Lamentablemente, la disponibilidad de estas encuestas es escasa, en particular en América Latina.⁵

El método más sencillo para estimar incidencia marginal requiere al menos dos encuestas de corte transversal y consiste en calcular los cambios en la participación de cada grupo (ej. cuantiles) en los beneficios del gasto público (Hammer *et al.*, 1995; Lanjouw *et al.*, 2002) o alternativamente la participación de cada grupo en el cambio en los beneficios (Younger, 2002; Glick y Razakamanantsoa, 2001). Gasparini (2006), por ejemplo, reporta una reducción en el grado de focalización del programa de atención médica pre-natal en Argentina entre 1997 y 2001. La participación del quintil más pobre en el total de beneficiarios cayó de 46.5% a 43.3% en esos años. Esta caracterización de los cambios en la estructura de incidencia es ilustrativa, pero nos dice poco acerca de la posible estructura de beneficiarios de una futura expansión del sistema público de atención médica.

Un método alternativo consiste en explotar la variabilidad geográfica en tamaños de programa y tasas de acceso de distintos grupos en una encuesta de corte transversal. Supóngase que el país está dividido en provincias indexadas con j , las cuales a su vez están divididas en municipios indexados con i . Lanjouw y Ravallion (1999) proponen estimar la siguiente ecuación para cada cuantil q (típicamente quintiles)

$$(5.1) \quad b_{ijp} = \alpha_p + \beta_p b_j + \varepsilon_{ijp}$$

donde b_{ijp} es la tasa de participación en el programa del percentil p en el municipio i perteneciente a la provincia j . El parámetro β_p indica el efecto marginal de un incremento en el alcance del programa en la provincia sobre la tasa de participación de las personas en un determinado cuantil. Dado que b_{ijp} está incluido en b_j se instrumenta b_j excluyendo aquellas personas en el municipio i del cuantil p .⁶

La disponibilidad de más de una encuesta de corte transversal permite construir un panel de provincias, e incluir un efecto fijo por provincia para controlar por variables

⁴ Ver Younger (2003) y van de Walle (2003) para excelentes resúmenes.

⁵ Ver Ravallion, van de Walle and Gautam (1995) para una aplicación de este enfoque.

⁶ Crosta (2009) expande el análisis a modelos no lineales, obteniendo interesantes resultados para el caso de la educación secundaria en Argentina.

constantes en el tiempo. Ravallion (1999) sigue esta estrategia para el caso del plan Trabajar. En primer lugar, corre una regresión por MCO para cada provincia en cada momento del tiempo entre la asignación del programa social y el nivel de pobreza de cada municipio. El coeficiente obtenido es una proxy del grado de focalización del programa en cada provincia/año. El segundo paso de la estrategia consiste en regresar esos coeficientes contra el gasto en el programa social en cada provincia, incluyendo un efecto fijo por provincia que capte factores específicos de la provincia que puedan afectar el grado de focalización del programa. Utilizando este procedimiento Ravallion (1999) encuentra que una contracción del programa redujo su grado de focalización.

Un enfoque alternativo consiste en (i) proponer un modelo teórico de elección de participación en un programa público, (ii) estimar un modelo empírico (derivado del punto (i)) de la probabilidad de participar, y (iii) calcular la variación compensada aplicando los resultados de las estimaciones al modelo. La variación compensada VC de un programa que provee gratuitamente un bien en cantidad q_g (ej. educación pública) se define como

$$(5.3) \quad v(p, y, 0) = v(p, y - VC, q_g)$$

donde $v(p, y, q_g)$ es una función de utilidad cuasi-indirecta que depende del vector de precios p , el ingreso y , y la provisión pública del bien. Small y Rosen (1981), McFadden (1995) y Gertler y Glewwe (1990), entre otros, han contribuido a la literatura de estimación de variaciones compensadas y disponibilidad a pagar ante cambios de precios y otras variables de política. Este enfoque es el más rico, y el que permite contestar una variedad de preguntas más amplia, al poder simular el impacto de intervenciones de política alternativas sobre los beneficios recibidos por cada persona. Esta riqueza obviamente tiene sus costos: el enfoque requiere una gran cantidad de supuestos simplificadores, y enfrenta serios problemas de estimación. En principio, supone que la alternativa seguida por cada agente es la que provee la máxima utilidad dadas sus preferencias, ignorando racionamientos típicos en el acceso a muchos servicios sociales (ej. educación). Una alternativa a este método consiste en calcular sólo los cambios en las probabilidades de participación ante una intervención de política, sin calcular las variaciones compensadas, evitando alguno de estos inconvenientes (Glick y Sahn, 2000).

6. Incidencia ex ante: las microsimulaciones

Los típicos estudios de incidencia evalúan programas existentes, es decir tienen una naturaleza *ex post*. En la ecuación (2.1) de beneficios b_i el ingreso con programa Y_i^c es observable: el trabajo del analista es estimar el ingreso contrafactual sin programa Y_i^s . A menudo el interés recae en evaluar propuestas de nuevas políticas o cambios en las existentes. En este caso los ingresos conocidos son aquellos donde el programa propuesto no existe Y_i^s y debe simularse la distribución de ingresos futuros Y_i^c cuando el programa se implemente. A este tipo de ejercicio se lo conoce como *incidencia ex ante*.

El camino ideal para predecir el impacto de un cambio de política es realizar un experimento a menor escala con el cual proyectar los resultados a toda la población objetivo. La posibilidad de realizar experimentos, sin embargo, es muy acotada, ya sea por sus costos, el rechazo que pueda generar por razones normativas, o la urgencia por implementar el programa. Adicionalmente, ciertos efectos del programa sólo se manifiestan cuando éste se implementa a gran escala.⁷

En ese escenario es útil proveer algún tipo de estimación del impacto del nuevo programa. Como en el caso de incidencia *ex post* la posibilidad más sencilla es asumir ausencia de cambios de comportamiento ante la política por lo cual el ingreso simulado luego del programa resulta igual al ingreso observado antes del programa más el valor monetario de la transferencia. Aunque rudimentario este ejercicio resulta útil para tener idea del orden de magnitud del impacto social de alguna propuesta de política. El cuadro 6.1 tomado de Gasparini y Cruces (2010) muestra el potencial impacto de la implementación plena del programa de Asignaciones Universales por Hijo (AUH) a partir de simulaciones que asumen ausencia de cambios en el comportamiento.

Cuadro 6.1
Impacto directo sobre la pobreza y la desigualdad del programa de Asignaciones Universales por Hijo

	Asignación Universal por Hijo				
	Actual	(1)	(2)	(3)	(4)
Tasa de pobreza					
Tasa de pobreza total					
Pobreza extrema	6.9	3.2	2.8	2.8	3.6
Pobreza moderada	23.2	21.1	19.0	19.0	20.6
Tasa de pobreza en niños					
Pobreza extrema	12.0	4.4	3.7	3.7	5.2
Pobreza moderada	36.0	32.0	28.3	28.3	31.3
Brecha de pobreza					
Pobreza extrema	2.9	1.1	0.9	0.9	1.3
Pobreza moderada	9.3	6.6	5.7	5.7	6.7
Tasa de pobreza en niños					
Pobreza extrema	4.9	1.2	0.8	0.8	1.6
Pobreza moderada	15.2	9.6	8.2	8.2	10.1
Desigualdad de ingresos					
Ratio 10/1	23.7	17.2	16.5	16.5	18.0
Share decil 1	1.4	1.9	2.0	2.0	1.8
Gini	0.455	0.442	0.435	0.435	0.441
Atkinson (2)	0.569	0.485	0.473	0.472	0.495

Fuente: Gasparini y Cruces (2010).

Nota: en las diferentes alternativas las nuevas AUH cubren a (1) los informales con salario menor al mínimo que mandan a su hijos a escuelas públicas, (2) todos los informales, (3) informales con salario menor a \$6000, (4) informales que mandan a su hijos a escuelas públicas.

Si este enfoque mecánico parece muy inadecuado, es necesario postular algún modelo de comportamiento, y o bien estimarlo con datos de encuestas, o bien calibrarlo para que sus predicciones sean consistentes con los datos de la realidad. Bourguignon y Ferreira (2003) ilustran este procedimiento con un modelo simple de oferta laboral. El problema que enfrenta cada agente es

$$(6.1) \quad \text{Max}_{c,L} U(c, L; X; \beta) \quad \text{sujeto a} \quad c \leq I + w.L + T(wL, I; X; \gamma), \quad L \geq 0$$

⁷ Por ejemplo, el impacto de un programa de transferencias monetarias sobre los salarios de equilibrio.

donde $U(\cdot)$ es la utilidad de una persona con características X que depende del consumo de un bien numerario c y de las horas trabajadas L . I es el ingreso no laboral exógeno, w el salario horario y T las transferencias públicas recibidas.⁸ La función $T(\cdot)$ refleja la dependencia del monto del subsidio estatal del ingreso laboral y no laboral del individuo. Por ejemplo, muchos programas de transferencias son incompatibles con ciertos niveles de ingreso en el mercado laboral, o establecen escalas de subsidios decrecientes en el salario percibido.

El vector β incluye coeficientes que parametrizan las preferencias y el vector γ la función de transferencias. Nótese que mientras que γ es conocido, β debe estimarse. La solución es una función de demanda de bienes de consumo y una función de oferta de horas trabajadas

$$(6.2) \quad L = F(w, I; X; \beta; \gamma)$$

que puede estimarse con información para una muestra de personas. El valor de L para cada individuo i puede escribirse entonces como

$$(6.3) \quad L_i = F(w_i, I_i; X_i; \hat{\beta}; \gamma; \hat{\varepsilon}_i)$$

donde el $\hat{\cdot}$ indica valores estimados y ε_i es el típico término estocástico en el análisis de regresión.

El siguiente paso es simular una nueva estructura de transferencias caracterizada por γ^s y predecir la nueva oferta laboral en ese escenario

$$(6.4) \quad L_i^s = F(w_i, I_i; X_i; \hat{\beta}; \gamma^s; \hat{\varepsilon}_i)$$

Nótese que esta ecuación asume implícitamente que el cambio en la estructura del programa no modifica ningún argumento de la función $F(\cdot)$. En particular, el salario w_i que enfrenta cada persona permanece invariable, lo que presupone ausencia de efectos de equilibrio general. Bajo estos supuestos, el cambio en el ingreso como producto del cambio del programa γ al programa γ^s es entonces

$$(6.5) \quad b_i = w_i(L_i^s - L_i) + T(w_i L_i^s, I_i; X_i; \gamma^s) - T(w_i L_i, I_i; X_i; \gamma)$$

La implementación del enfoque requiere la estimación de funciones de oferta de trabajo, usualmente no lineales. La etapa de estimación no está exenta de problemas⁹ Bourguignon, Ferreira y Leite (2002) proponen un modelo de elección discreta entre trabajo y escuela para estudiar el impacto del programa *Bolsa Escola* en Brasil. El cuadro 6.2 reproduce los principales resultados en términos del impacto sobre la pobreza y el costo total bajo diferentes alternativas de implementación.

Cuadro 6.2

⁸ Por simplicidad, asumimos que el financiamiento de las transferencias no recae sobre las personas bajo análisis.

⁹ Ver Blundell y MaCurdy (1999).

Evaluación ex ante del programa Bolsa Escola y alternativas Indicadores de pobreza

	Actual	Bolsa Escola	Alternativas				
			1	2	3	4	5
FGT(0)	30.1	28.8	27.5	24.6	27.7	28.8	28.9
FGT(1)	13.2	11.9	10.8	8.8	10.9	11.9	12.0
FGT(2)	7.9	6.8	5.9	4.6	6.0	6.8	6.8
Costo anual		2076	4201	8487	3905	2549	2009

Fuente: Bourguignon, Ferreira y Leite (2002) basados en PNAD 1999.

Nota: Bolsa Escola: transferencia mensual por niño $t=R\$15$ hasta un máximo por hogar $t^M= R\$45$ focalizado en hogares con ingreso per cápita familiar inferior a $x_m= R\$90$. Alternativa 1: $t=R\$30$, $t^M= R\$90$, $x_m= R\$90$; alternativa 2: $t=R\$60$, $t^M= R\$180$, $x_m= R\$90$; alternativa 3: valores diferentes por edad, sin valor máximo t^M , $x_m= R\$90$; alternativa 4: $t=R\$15$, $t^M= R\$45$, $x_m= R\$120$; alternativa 5: sin condicionalidad.

7. Inferencia causal y la construcción del contrafactual

Si bien los ejercicios que asumen ausencia de comportamiento son útiles como primera aproximación al impacto de un programa (o del conjunto del gasto social), son claramente insuficientes para la inferencia causal. Las últimas décadas han visto florecer los esfuerzos por mejorar las estimaciones del contrafactual de la intervención estatal, para arribar a cálculos más precisos de su impacto sobre el bienestar y su distribución. Esta sección detalla el problema de la inferencia causal e ilustra sobre alternativas de estimación del contrafactual.

Identificar efectos causales de un programa implica estimar qué hubiera pasado de no haberse implementado dicha intervención. Para abordar este tema el enfoque usual en la literatura de evaluación de impacto es el de Rubin (1974), quien postula que cada individuo tiene dos ingresos potenciales: uno bajo la intervención y otro en ausencia de la misma. Idealmente, si supiéramos el ingreso de cada individuo en los dos estados posibles, entonces podríamos identificar el efecto causal del programa.

Formalmente, si denominamos T_u a la variable que indica si la unidad (típicamente un individuo o familia) recibe o no tratamiento (variable binaria igual a 1 para los tratados y 0 para los demás), Y_u a la variable de interés de la unidad u (por ejemplo el ingreso), ε al término de error no observable y β a una constante, hay dos resultados potenciales:

$$Y_{u1} = \beta + \delta_u + \varepsilon_u \quad \text{si } T_u=1$$

$$Y_{u0} = \beta + \varepsilon_u \quad \text{si } T_u=0$$

El efecto a nivel individual se define como la diferencia entre los ingresos potenciales:

$$\delta_u = Y_{u0} - Y_{u1}$$

El ingreso observable puede expresarse de esta forma

$$Y_u = (1 - T_u)Y_{u0} + T_u Y_{u1}$$

de modo tal que

$$Y_u = \beta + \delta_u T_u + \varepsilon_u$$

Cuando nos referimos al tratamiento en la unidad u , estamos asumiendo que la intervención sólo afecta a esa unidad y su efecto es independiente de si las otras unidades son o no tratadas. Este supuesto se suele llamar *Stable Unit Treatment Value Assumption* (SUTVA) (Rubin 1961), y es fundamental en toda la primera parte de esta sección. Violaciones de SUTVA implicarían efectos de equilibrio general o externalidades.

Cabe destacar que el análisis causal difiere del análisis estadístico en un punto fundamental. Si bien en ambos casos el punto de partida consiste en una muestra de determinada variable aleatoria obtenida de una población, el análisis causal tiene como objetivo inferir aspectos del proceso generador de datos. Consecuentemente, bajo un análisis causal podemos inferir no sólo la probabilidad de determinados eventos en condiciones estáticas, sino que también podremos entender la dinámica de los eventos ante condiciones cambiantes.

Es por ello que idealmente necesitaríamos saber el ingreso de los individuos en ambos estados. Sin embargo, llegado el momento de la intervención habrá individuos que serán afectados y otros que no, por lo cual para cada individuo uno de los dos estados será inobservable (contrafactual). Holland (1986) denomina a esta imposibilidad de conocer el “qué hubiera pasado si” y por ende de identificar el efecto causal de la intervención, como el *problema fundamental de la inferencia causal*. El autor propone dos soluciones al problema: la solución científica y la estadística.

La primera de ellas es la *solución científica*, típicamente utilizada en el contexto de un laboratorio, en donde el científico puede replicar el experimento manteniendo el resto de las condiciones inalteradas y postular que el cambio en la variable de interés se debe a la intervención introducida. Por supuesto, el resultado depende de cuán razonable y plausible es el supuesto de homogeneidad subyacente en el experimento. En las ciencias sociales no es aplicable esta solución, dado que no es posible aislar a los individuos y existen muchas variables correlacionadas que influyen en las variables de interés, y afectan tanto las causas como las consecuencias de los cambios que se observan. Estas variables suelen denominarse *confounders*.

Por su parte, la *solución estadística* consiste en reconocer que aunque el efecto individual es inobservable, analizar a toda la población (o a un determinado sub-grupo de interés) nos permite obtener alguna información sobre el efecto promedio de la intervención. A pesar de que en general no podemos conocer toda la distribución de efectos individuales, hay ciertas características de la distribución de la variable de interés que podemos obtener a partir de datos de toda la población. Los métodos que desarrollaremos en la primera parte de esta sección tienen como objetivo estimar la media de la distribución de δ_u , o el *Average Treatment Effect (ATE)*:

$$ATE = E[\delta_u]$$

Cabe destacar que el efecto promedio puede ser heterogéneo, en distintas sub-poblaciones. Otro parámetro de interés es el *Average Treatment Effect on the Treated*

(*ATOT*), que se refiere al efecto promedio en aquellas unidades beneficiadas por el programa. Este parámetro suele ser el más importante para evaluar políticas.

$$ATOT = E[\delta_u/T_u=1]$$

Es clave comprender que para realizar inferencia causal es necesario responder preguntas sobre “que hubiera pasado si...”, lo cual implica la construcción de un contrafactual. A lo largo de esta sección se relevarán brevemente las técnicas más usuales en la literatura reciente que nos permiten reconstruir las situaciones contrafactuales en base a la información disponible y los supuestos que estemos dispuestos a asumir.

Existen dos tipos de validez de la inferencia obtenida por las diferentes técnicas: interna y externa. La validez interna implica la identificación de la relación causal entre dos variables, es decir, bajo qué supuestos se puede aseverar que el cambio en la variable de resultado se debe al efecto de la intervención. Usualmente, los riesgos a la validez interna provienen de secuencias temporales ambiguas de la causa y consecuencia, cuando hay auto-selección de las unidades en el programa o intervención, desgaste o *attrition* (individuos que pertenecen a la muestra original y abandonan el estudio antes de que se midan los resultados), entre otros. En tanto, la validez externa hace referencia a la posibilidad de generalizar la inferencia obtenida de determinada muestra en cierto contexto y condiciones, a otras unidades y situaciones.

Respecto de las fuentes de datos para realizar inferencia causal, vamos a destacar tres clases. En primer lugar se destacan los experimentos sociales en los cuales el investigador asigna las unidades al grupo de tratamiento y al grupo control en forma aleatoria –*random*- (por ejemplo con una lotería, o tirando una moneda). Cuando la *randomización* se implementa correctamente se generan grupos de unidades que en promedio, en probabilidad, son iguales, difiriendo sólo por la asignación al tratamiento.

Otra fuente de inferencia causal es el de estudios observacionales no-experimentales, en los cuales la asignación al tratamiento no depende del investigador, quien enfrenta el desafío de diseñar una manera de identificar relaciones causales. Según Rosenbaum (2002) un estudio observacional es una investigación empírica de tratamientos, políticas y exposición, y los efectos que causan, pero difiere de los experimentos en el hecho de que el investigador no puede controlar la asignación de las unidades al tratamiento. En este contexto, la mayor dificultad reside en la presencia de *confounders* a la hora de separar causas y efectos, ya que hay muchas variables que interactúan. Sin embargo, a veces, los estudios observacionales pueden abordarse con un diseño *cuasi-experimental*, que permite bajo ciertos supuestos realizar inferencia causal, a pesar de que la exposición a la intervención es decidida por las mismas unidades, por leyes, o por políticas.

Por último, además de los experimentos sociales y fuentes no-experimentales, existen los experimentos naturales. Esta tercera categoría consiste en estudios observacionales en los cuales la asignación de las unidades al tratamiento es “como si” hubiera sido *randomizada* por la naturaleza. Es decir, si bien el investigador no puede manipular el

contexto para generar los grupos de tratamiento y control, sí puede basarse en ciertas premisas razonables para argumentar que la asignación es *como si* hubiera sido aleatoria, o por lo menos no correlacionada con otros factores que influyen en el efecto de la intervención. Un experimento natural puede generarse a través de causas naturales como terremotos o inundaciones, o también a través de cambios en políticas o leyes que constituyen una fuente de variabilidad exógena.

Para ilustrar cómo puede utilizarse un experimento natural para identificar efectos causales consideremos el impacto de los títulos de propiedad en variables socio-económicas de las familias. En la mayoría de los casos la posesión de títulos de propiedad es endógena (basada en la riqueza, las características de las familias, el esfuerzo, etc.), con lo cual no podríamos identificar a-priori efectos causales. Galiani y Schargrotsky (2010) explotan un experimento natural para evaluar el impacto de los derechos de propiedad, superando este problema de identificación. En 1981, alrededor de 1800 familias ocupaban tierras en los suburbios de la Provincia de Buenos Aires. Los ocupantes eran grupos de ciudadanos sin inmuebles, organizados por una capilla católica. Para evitar la creación de asentamientos precarios como villas miseria, dividieron la tierra en pequeñas parcelas. En 1984, el Congreso aprobó una ley de expropiación de las tierras de sus antiguos dueños para darles títulos de propiedad a estos ocupantes. Algunos de los dueños originales aceptaron las compensaciones establecidas por el gobierno, y otros siguieron en disputa judicial. Estas diferencias en las decisiones de los propietarios, generaron una fuente exógena de variabilidad en la asignación de derechos de propiedad a los ocupantes. Explotando este experimento natural, los autores encontraron que las familias a las que se les asignaron títulos de propiedad, aumentaron la inversión en los hogares, redujeron el tamaño de sus hogares y mejoraron la educación de sus hijos en comparación con aquellos vecinos que no obtuvieron títulos de propiedad (grupo control).

En síntesis, los experimentos aleatorios controlados (*randomized controlled trials*) constituyen el diseño que minimiza el problema de los *confounders*. Sin embargo, en las ciencias sociales es complicada su implementación, y la generalización de sus resultados (problema de validez externa). En los diseños cuasi-experimentales, el problema de la validez interna depende de los supuestos bajo los cuales se reconstruye el contrafactual.

Por último, otra rama de la evaluación de impacto de políticas es la de los modelos estructurales, que consisten en desarrollar un sistema de ecuaciones, dándole formas funcionales a todas las decisiones involucradas en el problema que se analiza. Estos modelos nos permiten identificar bajo ciertos supuestos todos los parámetros relevantes y la distribución de la heterogeneidad en los efectos de interés, así como realizar simulaciones sobre distintas intervenciones en distintos contextos dentro del marco del modelo. Es importante notar que la diferencia fundamental entre el enfoque de Rubin y los modelos estructurales es que en el primero identificamos y estimamos parámetros de la forma reducida correspondiente a un modelo estructural subyacente. Actualmente, el

uso de modelos estructurales combinados con experimentos es la principal fuente para realizar inferencia causal.

En el próximo apartado se reseñan brevemente los parámetros que se pueden identificar en los experimentos y los cuasi-experimentos, así como también los supuestos necesarios en cada diseño.

Construcción del Contrafactual

A partir de la definición de ATE, observamos que para identificar el efecto causal es necesario asumir que la selección al tratamiento es independiente de los potenciales resultados en la variable de interés; es decir, que la asignación al tratamiento es *ignorable*.

$$ATE = E[\delta_u] = E[Y_{u1} - Y_{u0}] = E[Y_{u1}] - E[Y_{u0}] \text{ si } Y_{u1}, Y_{u0} \perp T_u$$

Bajo este supuesto, un estimador consistente de ATE es simplemente la diferencia de medias entre los grupos.

$$\hat{\delta}_{ATE} = \left[\hat{Y}_{u1} | T = 1 \right] - \left[\hat{Y}_{u0} | T = 0 \right]$$

Para entender las fuentes de posibles sesgos en la estimación de ATE, consideremos el siguiente modelo lineal:

$$Y_u = \beta + \delta_u T_u + \varepsilon_u$$

Este modelo difiere del tradicional modelo de regresión lineal ya que permitimos heterogeneidad en el efecto del tratamiento. De todos modos podemos escribir esta expresión en términos del efecto promedio, ATE:

$$Y_u = \beta + \delta^{ATE} T_u + \varepsilon_u + \delta_u T_u - \delta^{ATE} T_u = \beta + \delta^{ATE} T_u + [\varepsilon_u + \delta_u T_u - \delta^{ATE} T_u] =$$

$$Y_u = \beta + \delta^{ATE} T_u + v_u$$

donde v_u contiene todos los términos no observables. En este marco la estimación por mínimos cuadrados ordinarios (OLS) de δ^{ATE} será consistente sí y sólo sí la regla que determina asignación al tratamiento T_u no está correlacionada con la nueva expresión para el término de error. De lo contrario, habría un problema de endogeneidad.

Más formalmente, si derivamos la expresión para $\hat{\delta}^{OLS}$ y calculamos el *límite en probabilidad*, obtenemos que el estimador OLS va a identificar:

$$\delta^{OLS} = E[Y_{u1} | T_u = 1] - E[Y_{u0} | T_u = 0] =$$

$$\delta^{OLS} = \delta^{ATE} + E[\delta_u - \delta^{ATE} | T_u = 1] + E[\varepsilon_u | T_u = 1] - E[\varepsilon_u | T_u = 0]$$

Notar que el estimador OLS sólo recupera ATE si el resto de los términos son iguales a cero. Aquí observamos claramente que si estimamos ATE mediante la diferencia de medias por grupos, hay dos fuentes de sesgos: $E[\delta_u - \delta^{ATE} | T_u = 1]$ que representa la selección en base a *idiosyncratic gains* (si el efecto causal no es homogéneo), y $E[\varepsilon_u | T_u$

$= 1] - E[\varepsilon_u | T_u = 0]$ que expresa la selección en base a *non-treated outcomes* (*baseline differences*).

Si permitimos que el efecto sea heterogéneo, de no haber *baseline differences*, el estimador OLS recupera ATOT.

$$\begin{aligned}\delta^{OLS} &= \delta^{ATOT} + E[\varepsilon_u | T_u = 1] - E[\varepsilon_u | T_u = 0] = \\ \delta^{OLS} &= \delta^{ATOT} + E[Y_{u0} | T_u = 1] - E[Y_{u0} | T_u = 0]\end{aligned}$$

Si consideramos que la regla de asignación al tratamiento es parcialmente determinística (es decir, T_u está determinado por un conjunto de variables observables (z) y por un término de error (w)), entonces la asignación puede ser endógena por un problema de selección en base a observables (z) o no-observables (w). Dependiendo del supuesto que realicemos sobre el tipo de endogeneidad, deberá abordarse de distinta forma la identificación y estimación del efecto causal.

Usualmente se tiende a asumir que la selección ocurre en base a variables no observables. Si pudiéramos suponer que las unidades se seleccionan en función de variables observables, entonces podríamos aplicar la técnica de *Matching* que depende de suponer independencia condicional (*Conditional Independence Assumption* o CIA). Este supuesto asume que el tratamiento es ignorable, una vez que condicionamos el ingreso Y a una serie de variables X observables: $Y_{u1}, Y_{u0} \perp T_u / X_u$. Sin embargo, es poco factible que la selección sea solamente en base a variables observables, por lo que describiremos otras alternativas para identificar efectos causales.

Experimentos Aleatorios

Como mencionamos anteriormente, si podemos asignar las unidades aleatoriamente a los grupos, podemos asegurar que los grupos son en promedio similares, tanto en sus características observables como no observables, ya que la selección al tratamiento se realizó independientemente de ellas. Las implicancias que tiene la posibilidad de randomizar la asignación del tratamiento, son las siguientes:

$$\begin{aligned}E[Y_{u1} | T_u = 1] &= E[Y_{u1} | T_u = 0] = E[Y_{u1}] \\ E[Y_{u0} | T_u = 1] &= E[Y_{u0} | T_u = 0] = E[Y_{u0}]\end{aligned}$$

Es decir, que si randomizamos las unidades a los grupos, no debería haber diferencias en sus ingresos promedio iniciales (*baseline differences*), y tampoco debería haber diferencias en promedio a cómo reaccionarían al tratamiento. Con lo cual, ATE y ATOT son equivalentes, ya que por la definición de randomización, no esperamos heterogeneidad en el efecto del tratamiento entre grupos:

$$ATE = E[\delta_u] = E[Y_{u0} - Y_{u1}] = E[Y_{u0}] - E[Y_{u1}]$$

$$ATOT = E[\delta_u | T_u = 1] = E[Y_{u0} - Y_{u1} | T_u = 1] = E[Y_{u0} | T_u = 1] - E[Y_{u1} | T_u = 1] = E[Y_{u0}] - E[Y_{u1}]$$

lo cual, en el modelo lineal que estudiamos implica asumir:

$$E[\varepsilon_u | T_u = 1] = E[\varepsilon_u | T_u = 0] \quad \text{y} \quad E[\delta_u] = E[\delta]$$

Por lo que $\delta^{OLS} = \delta^{ATE} = \delta^{ATOT}$

Podemos estimar el parámetro causal por su análogo muestral:

$$\hat{\delta} = [\hat{Y}_{u1}|T_u = 1] - [\hat{Y}_{u0}|T_u = 0]$$

También se puede agregar a la regresión otros controles X , que reducirán la varianza del término de error, y el modelo lineal quedaría especificado de la siguiente forma:

$$Y_u = \beta_0 + \sum_{j=1}^k \beta_j X_{ju} + \delta T_u + v_u$$

También se suele estratificar la muestra para reducir la varianza del estimador. Por último, si el tratamiento se asigna aleatoriamente, pero a nivel de un grupo (empresa, escuela, barrio, hospital), es necesario extender el análisis a *Group Randomized Trials*, que tiene en cuenta la correlación de las variables dentro de cada grupo. En este caso el modelo a estimar sería el siguiente:

$$Y_{u:k:l} = \mu + \delta T_k + G_{k:l} + \varepsilon_{u:k:l}$$

donde $Y_{u:k:l}$ es el ingreso individual de la unidad u , que pertenece al grupo k , asignada a la condición l . μ es la media de la población, δ es el efecto del tratamiento y T_k es la variable binaria que indica si el grupo k fue asignado o no al tratamiento (todos los miembros de un grupo deben tener el mismo valor de T). Por su parte $G_{k:l}$ representa las características comunes al grupo G no observables y $\varepsilon_{i:k:l}$ es el término de error individual.

Los experimentos solucionan el problema de la validez interna, ya que si se implementan correctamente no tenemos dudas sobre la identificación del parámetro causal. Son embargo, para asegurarnos validez externa es necesario randomizar en dos etapas: de la población se elige aleatoriamente la muestra, y en la muestra se randomiza la asignación a los grupos de control y tratamiento.

Imperfect Compliance - Intention to Treat

En los experimentos con asignación aleatoria se randomiza la asignación a los grupos de tratamiento y control, por ejemplo se asigna aleatoriamente a trabajadores a participar en programas de capacitación laboral. Sin embargo, habrá trabajadores que no necesariamente cumplan con lo asignado: algunos no participarán del programa a pesar de haber sido elegidos, y otros probablemente participarán de otros programas de capacitación por no haber sido seleccionados para este programa. Por lo tanto, si comparamos el ingreso de los trabajadores de los grupos asignados y no asignados al programa, no estaríamos evaluando el efecto de la intervención en el ingreso. En este

caso, podemos pensar que la asignación sólo afecta la probabilidad de que el individuo reciba el tratamiento.

Para analizar los parámetros que podemos identificar bajo *imperfect compliance*, introducimos una variable binaria de asignación Z_u , mientras que la variable de tratamiento seguirá siendo T_u . Si calculamos la diferencia en ingresos entre aquellos asignados aleatoriamente al tratamiento ($Z=1$) y los asignados al grupo control ($Z=0$), estaríamos identificando el efecto total de la intervención en toda la muestra, que es un parámetro muy importante para la evaluación de políticas: el *Intention-to-Treat* (ITT). ITT representa el efecto causal de la asignación al tratamiento, pero no necesariamente del tratamiento recibido.

$$ITT = \delta^{ITT} = E[Y_u | Z_u = 1] - E[Y_u | Z_u = 0]$$

Expandiendo los términos, por la ley de esperanzas iteradas, podemos mostrar que bajo *perfect compliance*, ITT es igual a ATE.

$$\begin{aligned} \delta^{ITT} &= E[Y_u | Z_u = 1] - E[Y_u | Z_u = 0] \\ &= E[Y_u | Z_u = 1, T_u = 1] \Pr(T_u = 1 | Z_u = 1) + E[Y_u | Z_u = 1, T_u = 0] \Pr(T_u = 0 | Z_u = 1) - \\ &\quad - E[Y_u | Z_u = 0, T_u = 1] \Pr(T_u = 1 | Z_u = 0) + E[Y_u | Z_u = 0, T_u = 0] \Pr(T_u = 0 | Z_u = 0) \end{aligned}$$

Por *perfect compliance*, podemos reemplazar las probabilidades por 0 si $T_u \neq Z_u$, y por 1 si son iguales:

$$\delta^{ITT} = E[Y_u | Z_u = 1] - E[Y_u | Z_u = 0] = E[Y_u | T_u = 1] - E[Y_u | T_u = 0] = \delta^{ATE}$$

Si suponemos que el efecto del tratamiento es homogéneo, el hecho de que algunos del grupo de tratamiento no participen del programa y algunos de los no seleccionados sí participen en alguna intervención, hace que ITT sea menor que ATE, con lo cual se lo utiliza como una estimación conservadora de ATE. Sin embargo, en el marco de efectos heterogéneos, ITT es un estimador sesgado de ATE, sobre o sub estimando el verdadero parámetro.

Variables Instrumentales

Si la selección en el tratamiento se realiza en base a variables no observables, estamos en el marco en donde podríamos utilizar variables instrumentales, si encontramos un instrumento apropiado. Recordemos que las condiciones para que un instrumento sea válido son: i) el instrumento debe estar correlacionado con la variable endógena (T en este caso), ii) el instrumento no debe estar correlacionado con el término de error, con lo cual sólo puede afectar la variable de interés a través de su efecto en la variable endógena T.

En el caso de un experimento con asignación aleatoria tenemos la variable que denota asignación Z , que constituye un instrumento perfecto, ya que la asignación al tratamiento se supone que incide en la probabilidad de participar, y además el carácter

aleatorio de Z hace que esta variable no esté correlacionada con otros factores que influyen en Y , con lo cual podemos instrumentar T con Z .

El estimador de variables instrumentales (IV) se define como:

$$\delta^{IV} = \frac{\text{cov}(Y_u, Z_u)}{\text{cov}(T_u, Z_u)}$$

En el caso de utilizar como instrumento una variable binaria, como en este caso, el estimador coincide con el estimador de Wald:

$$\delta^{IV} = \delta_{Wald} = \frac{E[Y_u | Z = 1] - E[Y_u | Z = 0]}{E[T_u | Z = 1] - E[T_u | Z = 0]}$$

Sin embargo, el estimador IV no recupera en general el parámetro causal ATE, ya que podemos reescribirlo como ATE más otro término:

$$\delta^{IV} = \delta + \frac{E[Z_u v_u | T_u = 1] \Pr(T_u = 1 | Z_u)}{\text{cov}(T_u, Z_u)}$$

Observamos que IV sólo identifica ATE bajo el supuesto poco probable de que la covarianza entre el retorno del tratamiento y el instrumento es cero entre las unidades tratadas. Por lo tanto, sin supuestos adicionales y bajo *imperfect compliance* δ^{IV} no tiene una interpretación causal.

El estimador IV también lo podemos relacionar con el parámetro ITT que definimos antes, ya que el numerador de IV es exactamente ITT.

$$\delta^{IV} = \frac{E[Y_u | Z = 1] - E[Y_u | Z = 0]}{E[T_u | Z = 1] - E[T_u | Z = 0]} = \frac{ITT}{E[T_u | Z = 1] - E[T_u | Z = 0]}$$

Sin embargo, δ^{IV} en general no tiene una interpretación causal. Para poder interpretarlo es preciso adicionar un supuesto clave a los supuestos anteriores (como la validez del instrumento): el supuesto de Monotonicidad (Angrist e Imbens, 1994), que postula que la regla de decisión sobre participar o no del programa es una función monótona no trivial de Z . Por ejemplo, podemos suponer que $T(Z)$ es creciente en Z : $T_u(1) \geq T_u(0)$. Aplicando monotonicidad obtenemos:

$$E[Y_u(1, T_u(1)) - Y_u(0, T_u(0))] = E[Y_u(1) - Y_u(0) | T_u(1) - T_u(0)] \cdot \Pr\{(T_u(1) - T_u(0))\}$$

El parámetro causal que denominamos LATE equivale a:

$$\delta^{LATE} = E[Y_u(1) - Y_u(0) | T_u(1) - T_u(0)] = \frac{E[Y_u(1, T_u(1)) - Y_u(0, T_u(0))]}{\Pr\{(T_u(1) - T_u(0))\}} = \frac{E[Y_u | Z = 1] - E[Y_u | Z = 0]}{E[T_u | Z = 1] - E[T_u | Z = 0]}$$

Este parámetro se conoce como Local Average Treatment Effect (LATE), y representa el efecto promedio del tratamiento para aquellos individuos que cambian su status frente al programa por un cambio en el valor del instrumento Z . En un marco de efectos heterogéneos, bajo los supuestos de que Z es un instrumento válido y monotonicidad, sólo podemos identificar LATE, que es un efecto causal local.

Diseños cuasi-Experimentales y Difference-in-Differences

Cuando no es posible encontrar un instrumento válido, ni hacer un experimento, otra alternativa es utilizar un diseño cuasi-experimental. En la mayoría de los diseños cuasi-experimentales se requiere una observación de cada unidad antes del programa y otra después, para construir un panel. En el siguiente modelo agregamos la dimensión temporal al modelo lineal que utilizamos anteriormente:

$$Y_{it} = \alpha + \chi t + \delta T_{it} + \mu_i + \varepsilon_{it}$$

donde α es la media en el periodo cero, χ capta el efecto del tiempo, δ es el efecto del tratamiento, y T es la variable binaria que tiene el valor de 1 si la unidad i es tratada en el período t y cero en los demás casos. μ y ε son los términos de error individual fijo e individual variable en el tiempo, respectivamente.

Consideremos a continuación cómo quedaría expresado el modelo para los individuos tratados:

$$\text{Para } t=1 \quad Y_{u1} = \alpha + \chi + \delta + \mu_1 + \varepsilon_{u1}$$

$$\text{Para } t=0 \quad Y_{u0} = \alpha + \mu_1 + \varepsilon_{u0}$$

con lo que la diferencia entre períodos sería:

$$E[\Delta Y_u | T_u = 1] = \chi + E[\delta | T_u = 1] + E[\Delta \varepsilon_i | T_u = 1]$$

Repitiendo lo mismo para el grupo control obtenemos:

$$E[\Delta Y_u | T_u = 0] = \chi + E[\Delta \varepsilon_u | T_u = 0]$$

Finalmente, si sustraemos la diferencia en el ingreso entre grupos, obtenemos:

$$E[\Delta Y_u | T_u = 1] - E[\Delta Y_u | T_u = 0] = E[\delta | T_u = 1] + E[\Delta \varepsilon_i | T_u = 1] - E[\Delta \varepsilon_u | T_u = 0]$$

por lo que si suponemos que no hay diferentes tendencias entre el grupo de tratamiento y el de control, identificamos ATOT mediante el estimador denominado Difference-in-Difference (DiD)

$$\delta^{DiD} = E[\Delta Y_u | T_u = 1] - E[\Delta Y_u | T_u = 0] = E[\delta | T_u = 1] = \delta^{ATOT}$$

Para poder asumir que el estimador DiD recupera el parámetro causal ATOT, debemos suponer que el término de error no está correlacionado con la asignación al tratamiento. Por ejemplo, la asignación no debe depender de outcomes pasados o futuros (debe ser exógena).

Regression Discontinuity Design

La última alternativa que analizamos en el marco de los modelos de forma reducida es *regression discontinuity design*. Se utiliza en los casos de que las unidades son asignadas a los grupos de tratamiento y control en base al *score* que las unidades tienen en determinada variable de asignación. Dicha variable debe ser medida antes de la intervención, y el investigador debe estipular un umbral para que todas las unidades con scores mayores a dicho umbral reciban tratamiento y si los scores son menores, no lo reciban (o vice versa).

El supuesto fundamental para identificar relaciones causales en el marco de RDD, es que cualquier discontinuidad en la relación entre el resultado de interés y la variable que determina tratamiento, se debe al tratamiento. Entonces, en las proximidades del umbral esta técnica recrea las condiciones análogas a un experimento. La comparación del resultado promedio a ambos lados del umbral identifica el efecto causal de la intervención, pero sólo en forma local, alrededor del umbral.

Hay dos tipos de RDD: *sharp* (descrito anteriormente) y *fuzzy* (cuando hay *imperfect compliance* con la regla de asignación en el umbral). Formalmente, en RDD necesitamos una variable observable de asignación, S . Esta variable tundra un umbral en el cual la probabilidad de ser asignado al programa pasa de 0 a 1 (o de 1 a 0), en el caso de Sharp RDD; y cambia en forma discontinua en el caso de Fuzzy RDD. La condición para identificar el efecto causal es que Y_0 condicional en S sea una función continua de S en \bar{s} (umbral). Si las observaciones marginalmente ubicadas a los lados del umbral las denominamos \bar{s}^- y \bar{s}^+ , \bar{s} es un umbral si:

$$\Pr(D=1|\bar{s}^+) \neq \Pr(D=1|\bar{s}^-)$$

Si arriba del umbral asignamos tratamiento: $\Pr(D=1|\bar{s}^+) - \Pr(D=1|\bar{s}^-) > 0$

En el caso especial de Sharp RDD: $\Pr(D=1|\bar{s}^+) - \Pr(D=1|\bar{s}^-) = 1$

Podemos re-expresar las diferencias promedio de la variable de interés a ambos lados del umbral:

$$\begin{aligned} E[Y|\bar{s}^+] - E[Y|\bar{s}^-] &= E[Y_0|\bar{s}^+] - E[Y_0|\bar{s}^-] + E[D(s)|\bar{s}^+] - E[D(s)|\bar{s}^-] \\ &= E[Y_0|\bar{s}^+] - E[Y_0|\bar{s}^-] + E[\delta|\bar{s}^+] \end{aligned}$$

Bajo las siguientes condiciones de identificación antes mencionadas

$$E[Y_0|\bar{s}^+] = E[Y_0|\bar{s}^-]$$

$$E[Y_1|\bar{s}^+] = E[Y_1|\bar{s}^-]$$

podemos identificar ATOT sólo en el entorno del umbral

$$E[\delta|\bar{s}] = E[Y|\bar{s}^+] - E[Y|\bar{s}^-]$$

Estimación de cambios en Distribuciones. Modelos no lineales y Modelos Estructurales

En todos los casos anteriores analizamos el efecto promedio de las intervenciones. Claramente, según a qué segmento de la población apunten los programas los efectos se van a ver reflejados también en la distribución de la variable de interés. Para analizar los efectos distributivos de las políticas necesitamos más información que el efecto medio, ya que precisamos estimar el efecto para distintos valores del soporte de la distribución.

En la literatura reciente sobre evaluación de impacto una forma de evaluar cambios en las distribuciones es utilizando modelos no lineales. Desarrollaremos brevemente el marco de Athey e Imbens (2006). Supongamos que podemos expresar la variable de interés (ingreso) cuando el individuo no es beneficiario del programa:

$$Y_{g,t}^0 = h(u, t)$$

donde g denota el grupo, t el tiempo y h es una función desconocida, pero que cumple determinadas condiciones con el propósito de delimitar el tipo de modelos a los que se aplica este método. $h(u, t)$ es estrictamente creciente en u (o creciente solamente, cuando se trata de variables que representan resultados discretos). Además, condicional en g , la distribución de u no depende de t . Esto último significa que las características inobservables de la población en el grupo g permanecen inalteradas de un período a otro. El efecto del tiempo sólo proviene a través de t y no de algún cambio en la composición de inobservables. Bajo estas condiciones podemos identificar la distribución contrafactual de la variable de interés para el grupo de tratamiento en el período 1. Denominemos $F_{Y_{0,gt}}(y) = \Pr(Y_0 < y | g, t)$ a la distribución del ingreso en el estado no-tratado para el grupo g en el momento t . Si $q = F(y)$, entonces podemos invertir la distribución de probabilidad y expresar $y = F^{-1}(q)$. Athey e Imbens (2006) prueban que bajo los supuestos anteriores y algunos tecnicismos adicionales, la distribución en el estado no-tratado del ingreso de los beneficiarios del programa $F_{Y_{0,11}}(y)$ está identificada.

$$F_{Y_{0,11}}(y) = F_{Y_{,10}} [F^{-1}_{Y_{,00}} (F_{Y_{,01}}(y))]$$

Esta especificación del modelo implica que el efecto del tiempo es el mismo para los dos grupos, pero opera en forma distinta por el efecto del grupo. En el modelo lineal esta diferencia no es relevante porque el ajuste será igual en todos los grupos (por la linealidad); es sólo un corrimiento paralelo.

Cabe notar que si conocemos toda la distribución contrafactual, también es posible identificar los efectos promedio. Por ejemplo ATOT equivaldría a:

$$ATOT = E(Y_{1,11}) - E(F^{-1}_{Y_{01}}(F_{Y_{,00}}(Y_{10})))$$

Un ejemplo en la literatura de evaluación de impactos distributivos es el trabajo de Bitler *et al.* (2003), en el que analizan el efecto de programas de bienestar en Estados Unidos. Las autoras están interesadas en el análisis de la heterogeneidad de los efectos (en lugar del impacto promedio), y para ello utilizan datos de un programa con asignación aleatoria - *Connecticut's Jobs First waiver*- que capta elementos clave de los programas de asistencia social post-1996. Las autoras estiman *quantile treatment effects*

en la oferta de trabajo, y encuentran una sustancial heterogeneidad, tal como predice la teoría, con lo que comprueban que el estudio de efectos promedios omite un aspecto muy importante de los impactos.

8. Consideraciones finales

En este trabajo hemos presentado los problemas conceptuales que enfrentan las evaluaciones de impacto de políticas sociales y un conjunto de instrumentos para el análisis empírico. El listado no ha sido exhaustivo. Por ejemplo, ignoramos el impacto que una medida de política puede tener sobre el resto de la economía mediante externalidades y efectos de equilibrio general. La literatura económica ha ido avanzando lentamente en cubrir esta deficiencia. Un enfoque reciente es el *micro-macro*, que hace uso de modelos de equilibrio general computado.¹⁰

Mientras el instrumental económico de evaluación crece día a día, en Argentina aun no existe una conciencia sobre la importancia de la evaluación rigurosa de los efectos de las políticas. La evaluación del impacto de las políticas públicas constituye una de las áreas de mayor relevancia de la Economía, cuyos resultados deberían contribuir a un mejor diseño de políticas y en consecuencia a un mayor impacto de las intervenciones públicas. El escaso uso que aun estas evaluaciones tienen en el caso argentino no debería desalentar el estudio de las herramientas de análisis.

¹⁰ Ver algunos enfoques en Bourguignon y Pereira da Silva (2003).

Referencias

- Aaron, H. y McGuire, M. (1970). Public goods and income distribution. *Econometrica* 38(6).
- Bourguignon, F. y Pereira da Silva, L. (eds.) (2003). *The impact of economic policies on poverty and income distribution*. World Bank and Oxford University Press.
- Demery, L. (2003). Analyzing the incidence of public spending. En Bourguignon y Pereira da Silva (2003).
- Diéguez, H., Llach, J. and A. Petrecolli (1991). *El gasto público social*. PRONATASS-ITDT, Buenos Aires.
- Dirección de Gastos Sociales Consolidados (2002). *El impacto distributivo de la política social en la Argentina. Análisis basado en la Encuesta Nacional de Gastos de los Hogares*. Ministerio de Economía, Republica Argentina.
- Flood, C., Harriague, M., Gasparini, L. and Vélez, B. (1994). *El gasto público social y su impacto redistributivo*. Secretaría de Programación Económica. Ministerio de Economía. Buenos Aires.
- Galasso, E. and Ravallion, M. (2003). Social Protection in a Crisis: Argentina's Plan Jefes y Jefas. Mimeo The World Bank.
- Galiani, S. y Schargrotsky, E. (2010). Property Rights for the Poor: Effects of Land Titling. *Journal of Public Economics* 94 (9).
- Gasparini, L. (2006). "Assessing benefit-incidence results using decompositions. The case of health policy in Argentina" *Economics Bulletin*, Vol. 4, No. 40 pp. 1-10, 2006.
- Gasparini, L. Cicowiez, M. y Sosa Escudero, W. (2010). *Pobreza y desigualdad en América Latina. Conceptos, herramientas y aplicaciones*. Mimeo, CEDLAS.
- Gasparini, L. y Cruces, G. (2009) Desigualdad en Argentina. Una revisión de la evidencia empírica. *Desarrollo Económico* 193 (49).
- Gertler, P. y Glewwe, P. (1990). The willingness to pay for education in developing countries: evidence from rural Peru. *Journal of Public Economics* 42 (3).
- Glick, P. y Razakamanantsoa, M. (2001). The Distribution of Social Services in Madagascar, 1993-99, Working Paper No. 128, Cornell University Food and Nutrition Policy Program.
- Glick, P. y Sahn, D. (2000). The Demand for Primary Schooling in Rural Madagascar: Price, Quality, and the Choice Between Public and Private Providers. *Journal of Development Economics* 79(1).
- Hammer, J., Nabi, I. y Cercone, J. (1995). Distributional effects of Social Sector Expenditures in Malaysia, 1974 to 1989. En van de Valle y Nead (1995).
- Harriague, M. y Gasparini, L. (1999). El impacto redistributivo del gasto público en los sectores sociales. Anales de la XXXIV Reunión de la Asociación Argentina de Economía Política, Rosario.
- Holland, P. (1986) Statistics and Causal Inference, *Journal of the American Statistical Association* 81, pp. 945-70.

- Jalan, J. y Ravallion, M. (2003). Estimating the Benefit Incidence of an Anti-Poverty Program. *Journal of Business and Economic Statistics* 21 (1).
- Lambert, P. (2001). *The distribution and redistribution of income*. Manchester University Press.
- Lanjouw, P., Pradhan, M., Saadah, F., Sayed, S. y Sparrow, R. (2002). Pobreza, educación y salud en Indonesia: ¿Quién se beneficia del gasto público? en *Education and Health Expenditure, and Development: the Cases of Indonesia and Peru*. Christian Morrisson, ed., Paris: OECD.
- Lanjouw, P. y Ravallion, M. (1999). Benefit Incidence and the Timing of Program Capture. *World Bank Economic Review*, 13, 2.
- McFadden, D. (1995). Computing willingness to pay in random utility models. University of California at Berkeley.
- Meerman, J. (1979). *Public expenditure in Malaysia: who benefits and why?* Oxford University Press.
- Petrei, H. (1988). El gasto público social y sus efectos distributivos. Un examen comparativo de cinco países de América Latina. ECIEL, Río de Janeiro.
- Porto, A. y Gasparini, L. (1991). Impacto distributivo del gasto social. *Desarrollo Económico* 31 (124).
- Ravallion, M., van de Walle, D. y Gautam, M. (1995). Testing a Social Safety Net *Journal of Public Economics* 57.
- Ravallion, M. (2005). Evaluating anti-poverty programs. *World Bank Policy Research Working Paper* 3625, June.
- Rubin, D. (1974) Estimating causal effects of treatments in randomized and nonrandomized experiments, *Journal of Educational Psychology* 66.
- Selowsky, M. (1979). *Who benefits from government expenditures. A case study of Colombia*. Oxford University Press.
- Small, K. y Rosen, H. (1981). Applied welfare economics with discrete choice models. *Econometrica* 49 (1).
- van de Walle, D. y Nead, K. (1995). *Public Spending and the Poor. Theory and Evidence*. The World Bank and John Hopkins University Press.
- Van de walle, D. (2003). Behavioral incidence analysis of public spending and social programs. En Bourguignon, F. y Pereira da Silva, L. (2003).
- Younger, S. (2003). Benefits on the Margin: Evaluating Alternatives to Traditional Benefit Incidence Analysis. *World Bank Economic Review*, 17, 1.