

# Desafíos de medición de las desigualdades

Datos, problemas y soluciones

---

Ignacio Flores<sup>1</sup>

Seminario de Alto Nivel - Estadísticas Económicas

CEPAL Santiago,

18 Noviembre, 2019

<sup>1</sup> Coordinador LAC en World Inequality Lab -  
Paris School of Economics -  
INSEAD



## Introducción General

---

# Preguntas de investigación

- ¿Qué desafíos de medición para capturar a la parte más alta de la distribución? ¿Qué datos existen y cómo podemos reconciliarlos?  
¿Cómo mejorar las fuentes?

# ¿Qué datos?

## Encuestas a Hogares

- Micro-datos, buena cobertura geográfica, covariables y representatividad
- Sólo años recientes. Incluye sesgos (e.g., sampling and non-sampling)

## Impuestos - Administrativos

- Cubre mejor el top. Disponible más tiempo.
- Mayoritariamente tabulados sin covariables (a veces micro-datos).  
Inconsistencias en unidades y conceptos , calidad variable

## Cuentas Nacionales

- Buena referencia para totales
- No incluye información distributiva (por ahora). Puede ser una caja negra

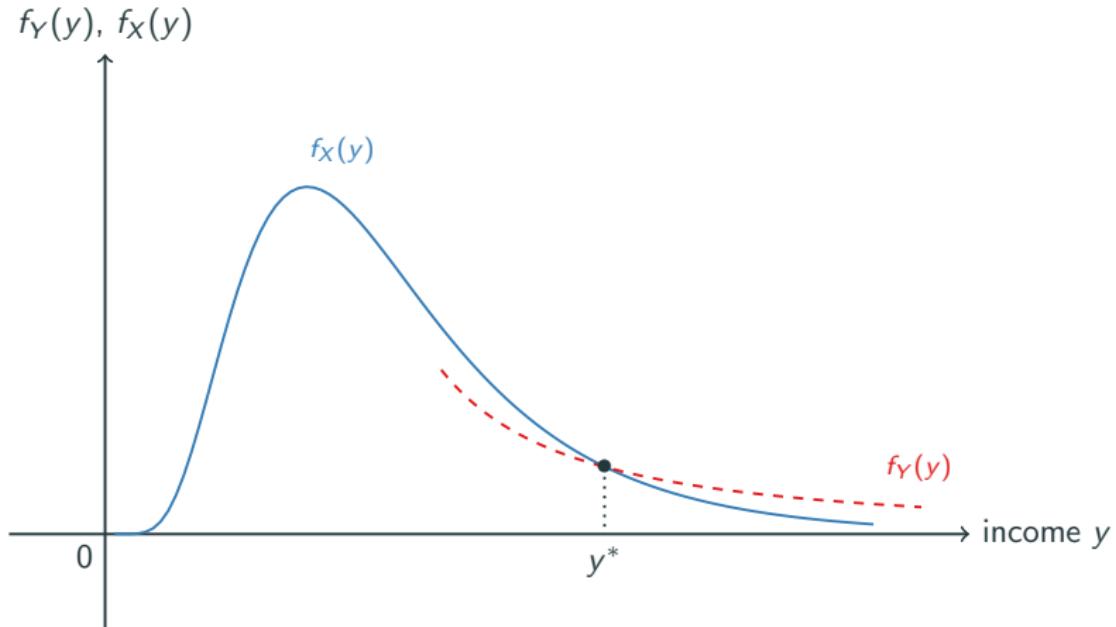
## Otros

- Rankings de riqueza (e.g., Forbes)
- Fugas de datos o 'Leaks' (e.g., LuxLeaks, Panama Papers)

## ¿Se pueden combinar consistentemente?

- Si. Algunos ejemplos para países desarrollados: Garbinti, Goupille-Lebret and Piketty, 2016 (FR); Piketty, Saez and Zucman, 2018 (US) o OECD EG-DNA
- Pero los métodos (Alvaredo et al., 2017) no son fácilmente adaptables a países en desarrollo: Cobertura, confianza en datos fiscales (informalidad, peso de independientes)

## Escena típica (LatAm): Encuestas vs. Tax



## Sampling

- Small sample bias (Taleb and Douady, 2015)

## Non-Sampling

- Misreporting (Bound and Krueger, 1991; Bollinger, 1998; Angel et al., 2017; Paulus, 2015)
- Heterogeneous response rates across the income distribution (Korinek, Mistiaen and Ravallion, 2006; Johansson and Klevmarken, 2007; Bollinger et al., 2015; Chenevert et al., 2016)

# Interpretar la diferencia: Perspectiva formal

## Non-Response

- $f_Z(y) = f_Y(y)\theta(y) \Rightarrow \theta(y) = f_Z(y)/f_Y(y)$

## Misreporting

- $f_Z(y) = f_Y(y)(1 - p(y)) + f_M(y)\bar{p}$

## Non-Response & Misreporting

- $f_Z(y)/f_Y(y) = \theta(y)(1 - p(y)) + f_M(y)/f_Y(y)\theta(y)\bar{p}$

## Conclusiones

- Si ambos existen, se confunden *ex-post*.
- Misreporting sólo se puede resolver con *matching* individual

# Metodología

⇒ Blanchet, Flores and Morgan, 2019 (BFM)

# **The Weight of the Rich: Improving Surveys with Tax Data**

---

## ¿Un problema antiguo?

- Eliminar las inconsistencias entre las encuestas y otras fuentes de datos más confiables (e.g., censos) no es nada nuevo
  - Las encuestas son corregidas rutinariamente para asegurar representatividad en términos de edad, sexo, etc . . .
- ⇒ ¿Deberíamos entonces hacerlas también más representativas en términos de **ingresos**?

# Calibración de encuestas

- Metodologías bien establecidas (e.g. Deville and Särndal, 1992)
- Variable en encuesta  $x_1, \dots, x_n$ , con *design weights*  $d_1, \dots, d_n$
- Encontrar nuevos weights  $w_1, \dots, w_n$  que entreguen los totales observados en otra fuente:

$$\sum_{k=i}^n w_i x_k = T$$

- Condición: que minimize la distancia entre weights originales y corregidos:

$$\min_{w_1, \dots, w_n} \sum_{i=1}^n \frac{(w_i - d_i)^2}{d_i}$$

⇒ Solución se interpreta cómo un modelo de *non-response*.

## Comandos de Stata bfmcorr (incl. postbfm)

- Flexibilidad en forma de datos, conceptos de ingreso, unidades estadísticas
- Selección automática de 'merging point' & funciones de extrapolación si necesario (datos limitados)
- Incluye varias herramientas de diagnóstico para realizar y analizar correcciones

# Literatura sobre corrección de encuestas

- **Reweighting**

⇒ Korinek, Mistiaen, and Ravallion (2006); Hlasny and Verme (2017; 2018); Alvaredo (2011, for Argentina)...

- **Replacing**

⇒ Burkhauser et al. (2016); Piketty, Yang, and Zucman (2017); Chancel and Piketty (2017); Czajka (2017); DWP (2015); Alvaredo (2011, for U.S.); Burkhauser et al. (2018); Jenkins (2017)...

- **Hybrids**

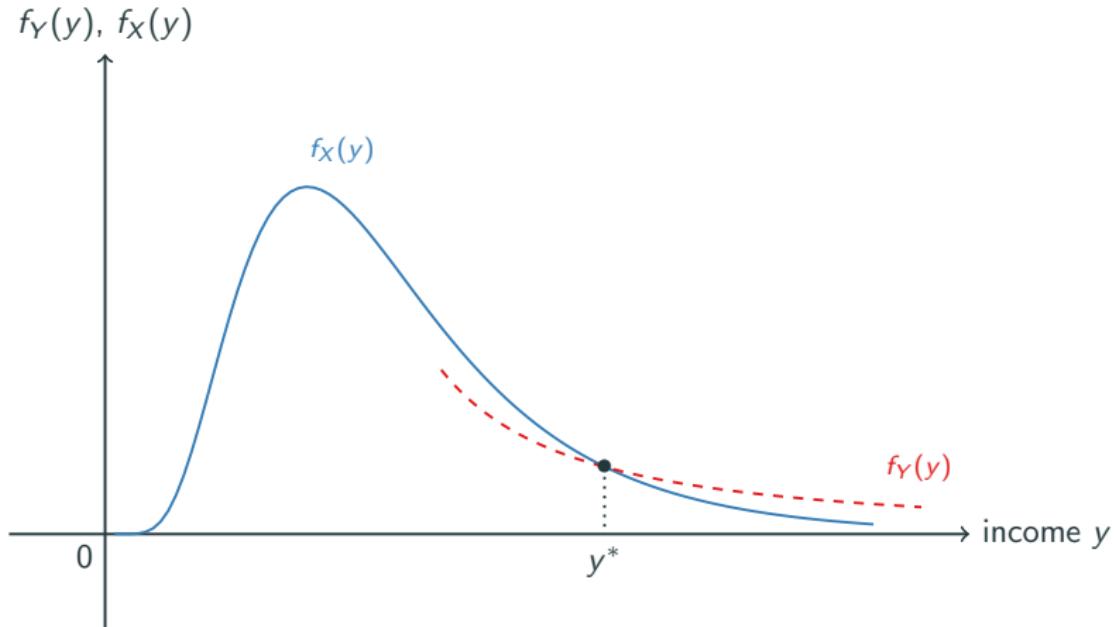
⇒ Bourguignon (2018); Medeiros et al. (2018); *nuestro método*

Nuestro método híbrido usa datos fiscales, encuentra un ‘merging point’ no-arbitrario y preserva la estructura de micro-datos, incluyendo totales de población (entre otros)

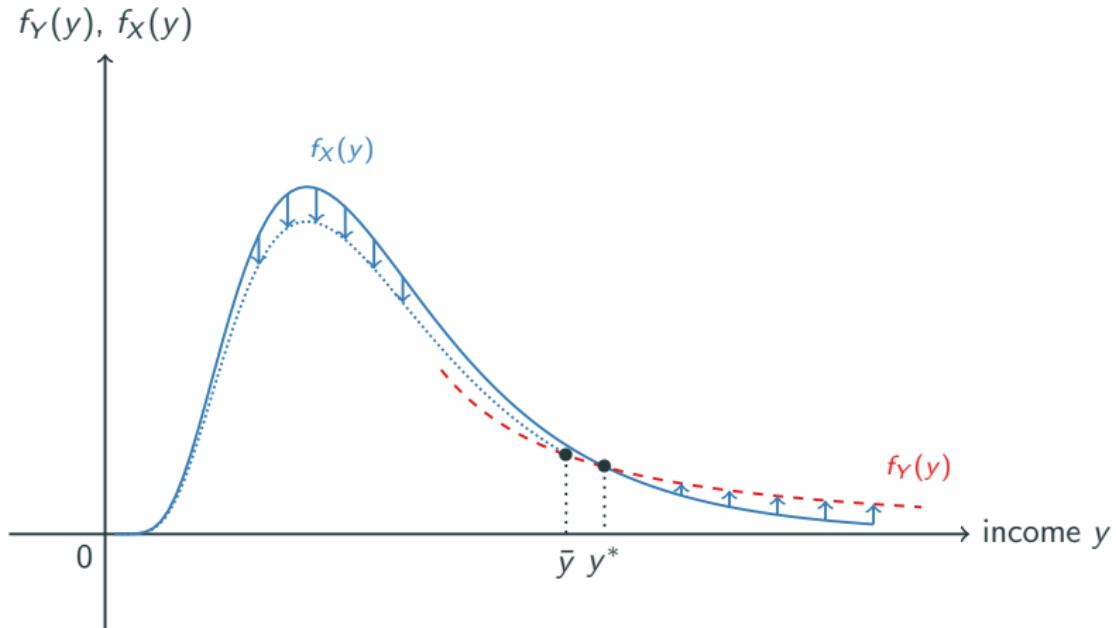
Dos hipótesis fundamentales:

1. Declaraciones fiscales son un *lower bound* para las frecuencias en parte alta de la distribución
2. No cuestionamos las respuestas aportadas por individuos encuestados

# Merging point



# Merging point



# Merging point

- Probabilidad relativa de respuesta

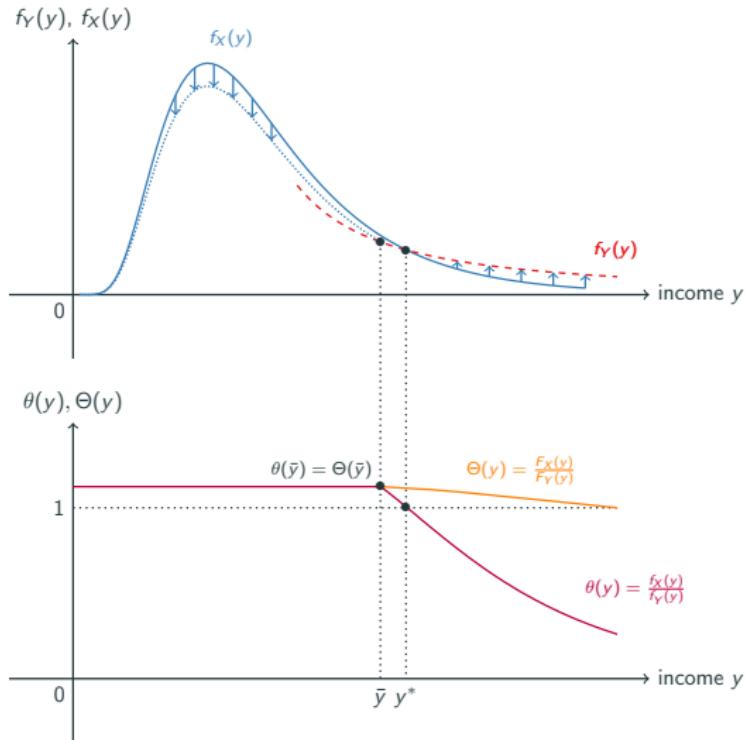
$$\theta(y) = \frac{f_X(y)}{f_Y(y)}$$

- Probabilidad relativa de respuesta cumulada

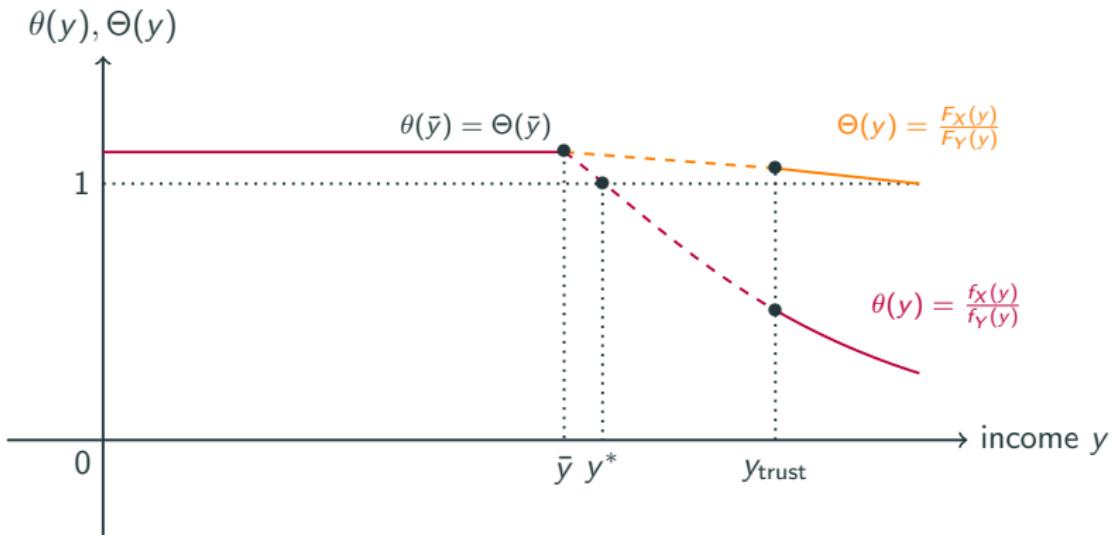
$$\Theta(y) = \frac{F_X(y)}{F_Y(y)}$$

- Ambas se estiman empíricamente

# Cesgo implícito y merging point



# Datos fiscales limitados



## Con datos fiscales limitados, merging point

Para extraer, asumimos la siguiente relación en el top:

$$\log \theta(y) = \beta_0 - \beta_1 \log y$$

Usando la *Ridge regression*:

$$\min_{\beta_0, \beta_1} \sum_{i=1}^m (\log \tilde{\theta}_k - \beta_0 - \beta_1 \log y_k)^2 + \lambda(\beta_1 - \beta_1^*)^2$$

Las estimaciones de  $\beta_1^*$  son calculadas a partir de datos reales

## Aplicación a datos de ingreso

- Discretizar la distribución en grupos (percentiles...)
- ¿Cuanta gente en la encuesta para cada fractil?

La flexibilidad de los métodos de calibración permiten:

- ajustar weights respetando la consistencia macro de las variables (e.g. edad, sexo)
- introducir otros datos administrativos (características, composición de ingresos, lidiar con distintas definiciones de ingreso)

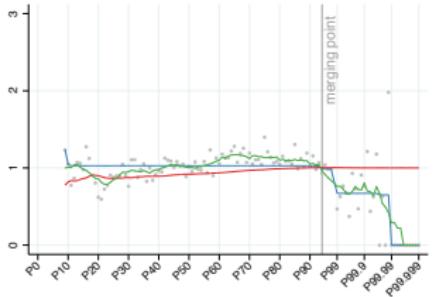
# Replacing and Matching

- We can gain more precision by replacing the survey distribution by the tax data distribution at the top.
- Addresses small-sample bias on top shares (Taleb and Douady, 2015).
- Duplicate observations and match them on their rank
  - ⇒ expand the support.
- Statistically:
  - Use the marginal distribution of income at the top provided by the survey data.
  - Keep the survey data for the marginal distribution of covariates.
  - Keep the survey data for the copulas (dependency) between income and the covariates.

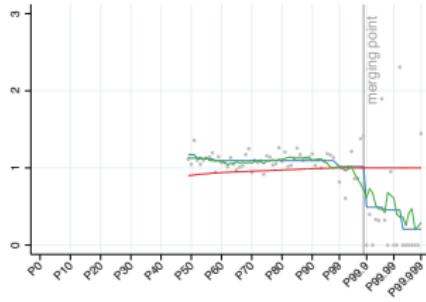
# Aplicaciones

- Paso preliminar, armonizar definiciones (ingreso y unidad)
- Fuente: Encuestas locales (Chile, Brasil) y EU-SILCS (Francia, Noruega, Reino Unido)
- Series de tax: <http://wid.world>

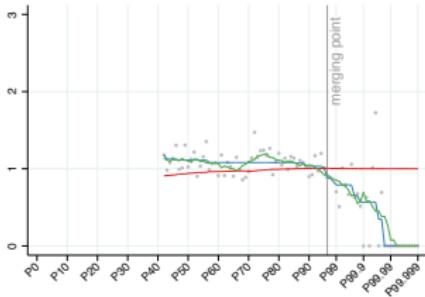
# La forma del cesgo: Paises desarrollados



(a) Norway 2014



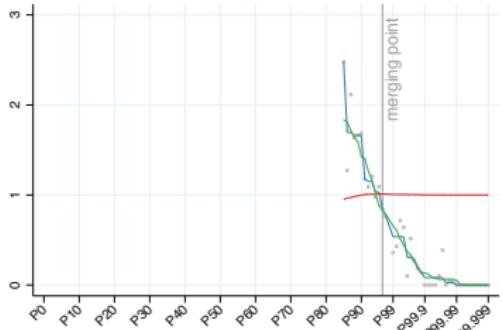
(b) France 2014



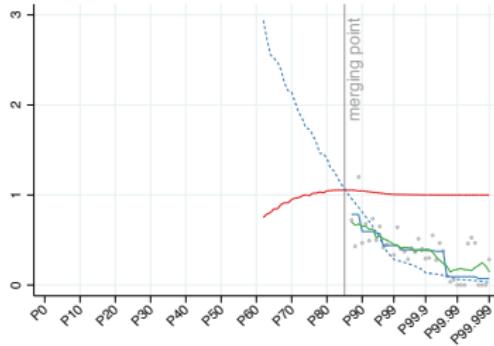
(c) UK 2014

$\circ$	$\theta(y)$	$\text{---}$ $\theta(y)$ (antitonic)
$\text{---}$	$\Theta(y)$	$\text{---}$ $\theta(y)$ (moving avg.)

# La forma del cesgo: países en desarrollo



(e) Brazil 2015



(f) Chile 2015

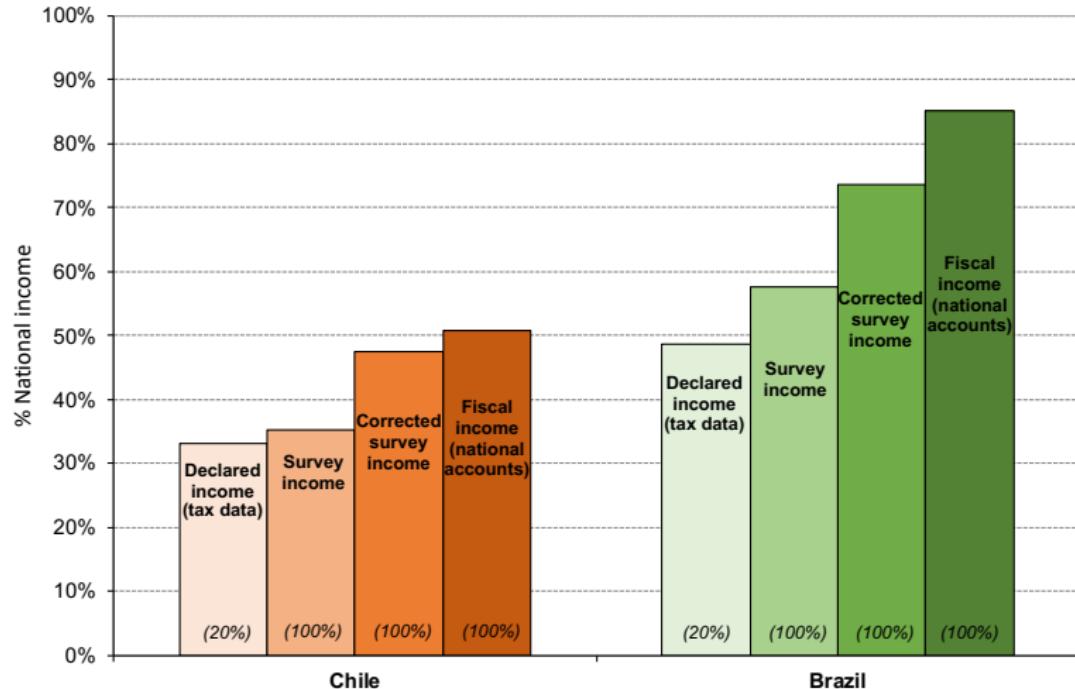
- |                                      |                                      |                        |
|--------------------------------------|--------------------------------------|------------------------|
| $\bullet$ $\theta(y)$                | $\text{---}$ $\theta(y)$ (antitonic) | $\text{—}$ $\Theta(y)$ |
| $\text{—}$ $\theta(y)$ (moving avg.) | $\cdots$ $\theta(y)$ (extrapolation) |                        |

# Población corregida

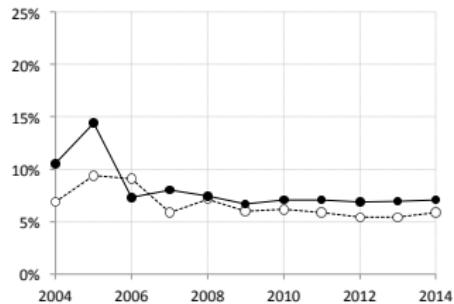
Table 1: Structure of Corrected Population: Latest Year

Country	Population over Merging Point (% total population)		Corrected population		
	Tax data	Survey	Total	Share inside survey support	Share outside survey support
	[2]	[3]	[4] = [2] – [3]	[5]	[6]
Chile	14.0%	9.2%	4.8%	99.99%	0.01%
Brazil	3.0%	1.9%	1.1%	98.2%	1.8%
UK	3.0%	2.5%	0.5%	93.6%	6.4%
Norway	5.0%	4.6%	0.4%	96.0%	4.0%
France	0.1%	0.05%	0.05%	99.0%	1.0%

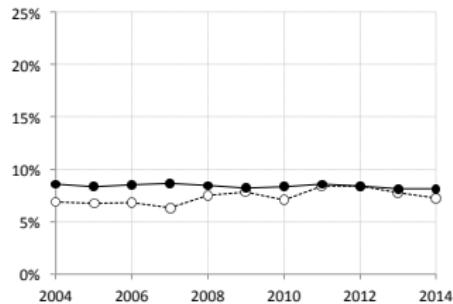
# Cobertura de Ingresos



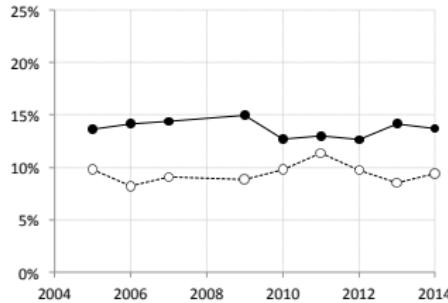
# Resultados: Top 1% (países desarrollados)



(h) Norway 2014



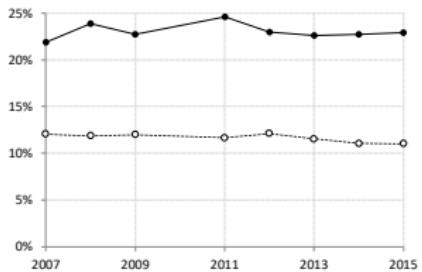
(i) France 2014



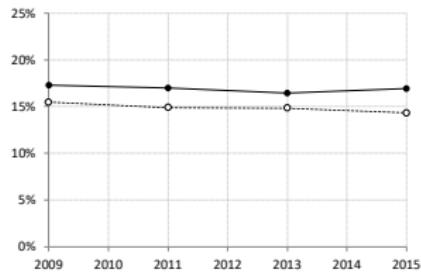
(j) UK 2014

-○-Raw Survey    -●-Corrected Survey

# Resultados: Top 1% (países en desarrollo)



(l) Brazil 2015



(m) Chile 2015

-○-Raw Survey      -●-Corrected Survey

## Puntos fuertes

1. Data-driven approach
2. Observaciones razonables al nivel de la observación
3. Minimiza distorsiones
4. Mantiene la representatividad en el uso de microdatos

# **Growing Unequal: The Distribution of Economic Prosperity in Latin America**

---

# Datos LatAm (1990-2015)

## Encuestas a hogares

- CEPAL aplicación con micro-datos
- Datos armonizados para 18 países = +95% de la población regional
- 14 con encuestas desde fin de 1980s/principios 1990s, 4 desde fines de 1990s/comienzos 2000s

## Tax

- Disponible: Argentina, Brazil, Chile, Colombia, Costa Rica, Mexico, Uruguay
- Pendiente: Ecuador, Peru, Bolivia
- Obstáculos: definiciones de ingreso

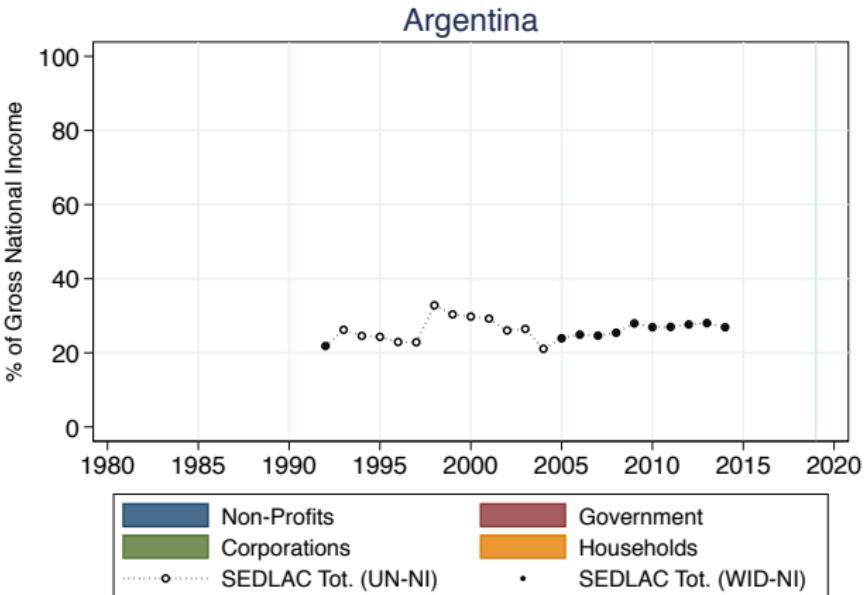
## Cuentas nacionales

- Descomposición sectoral desde mediados de 1990s
- Nivel de detalle y cobertura temporal variable

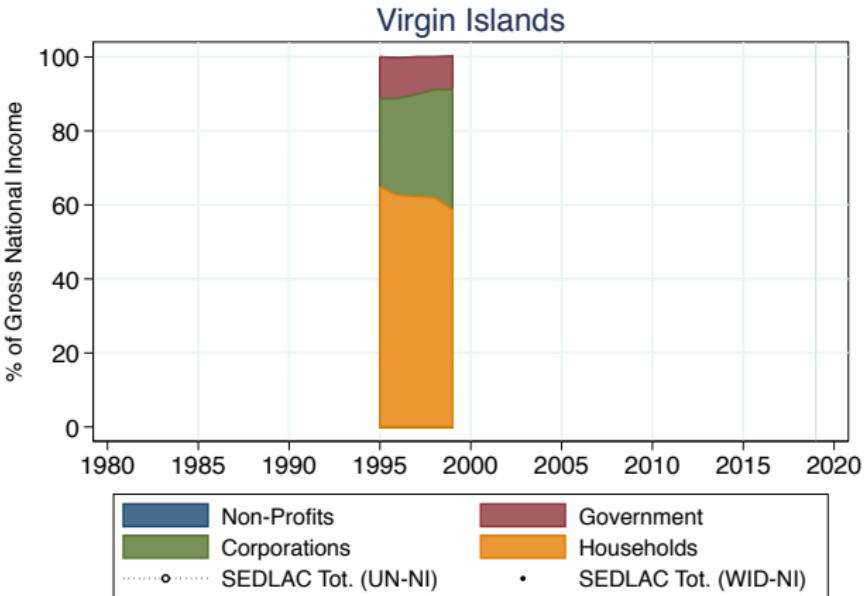
# Data coverage

[LINK]

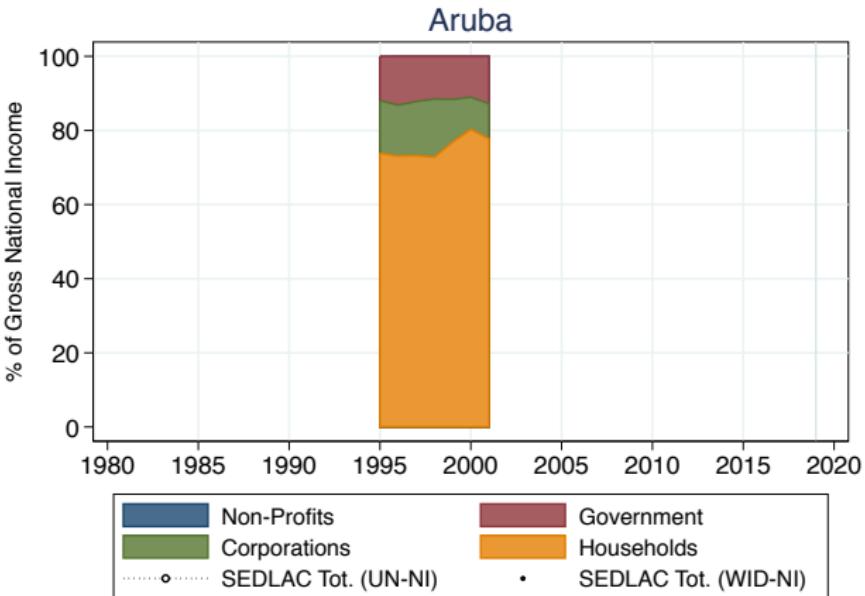
# Filling the national accounts gap



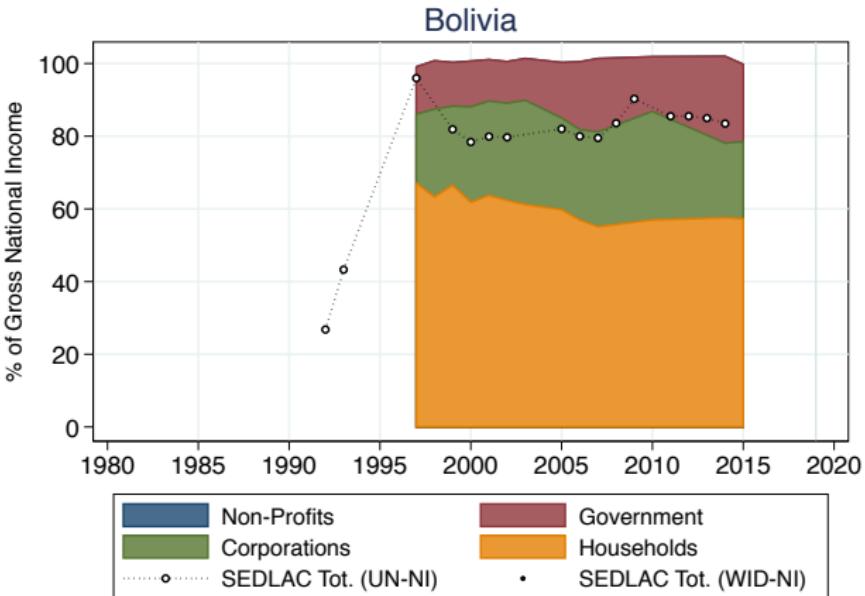
# Filling the national accounts gap



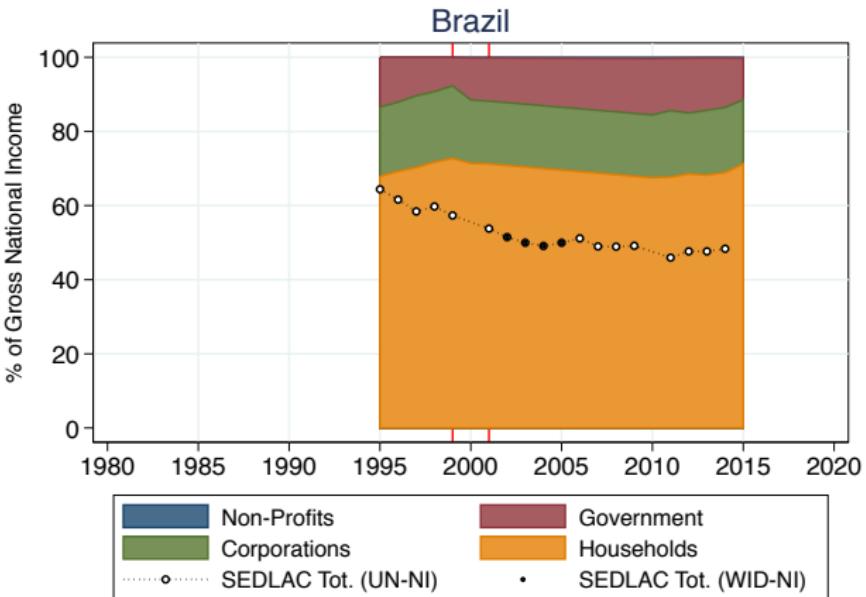
# Filling the national accounts gap



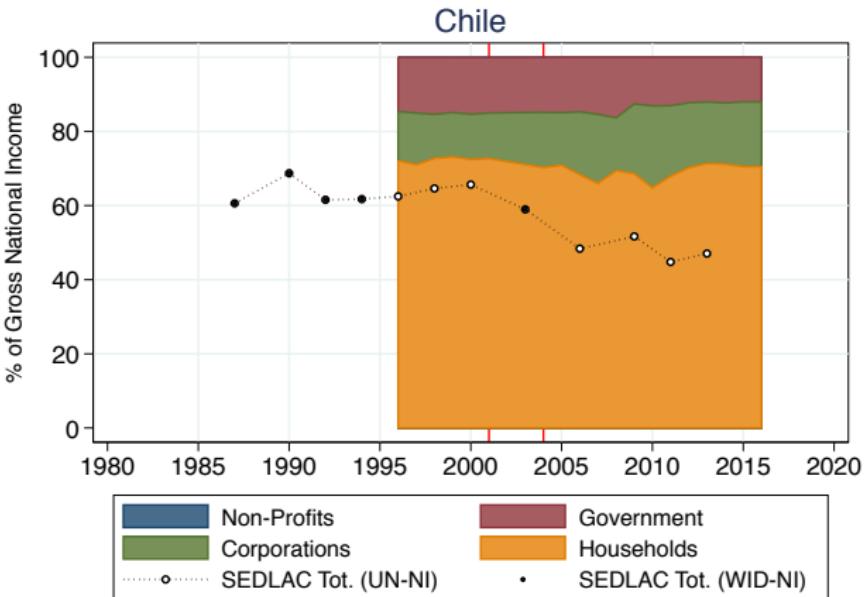
# Filling the national accounts gap



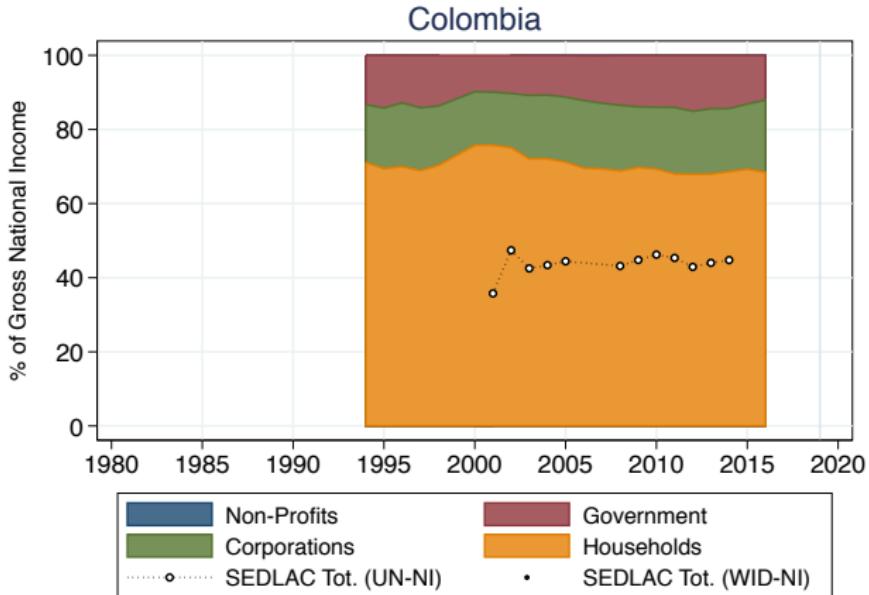
# Filling the national accounts gap



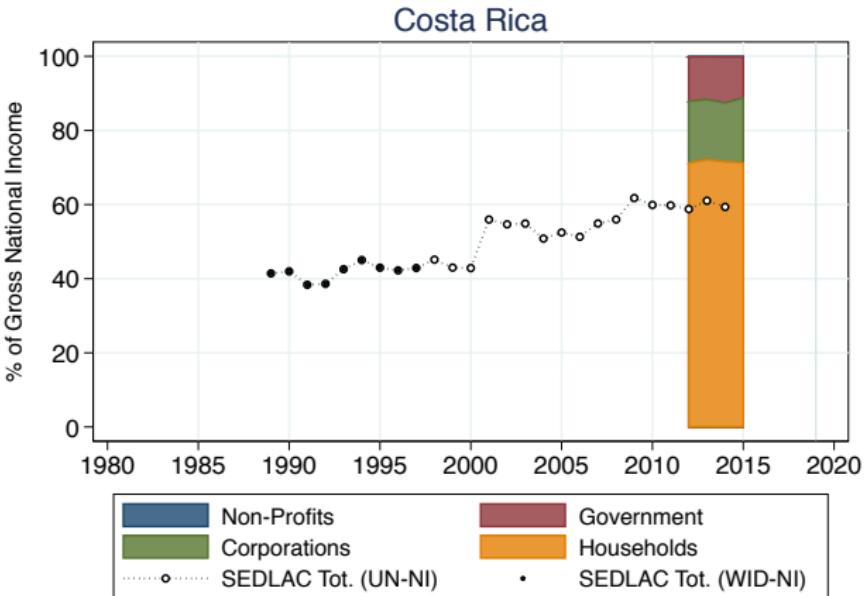
# Filling the national accounts gap



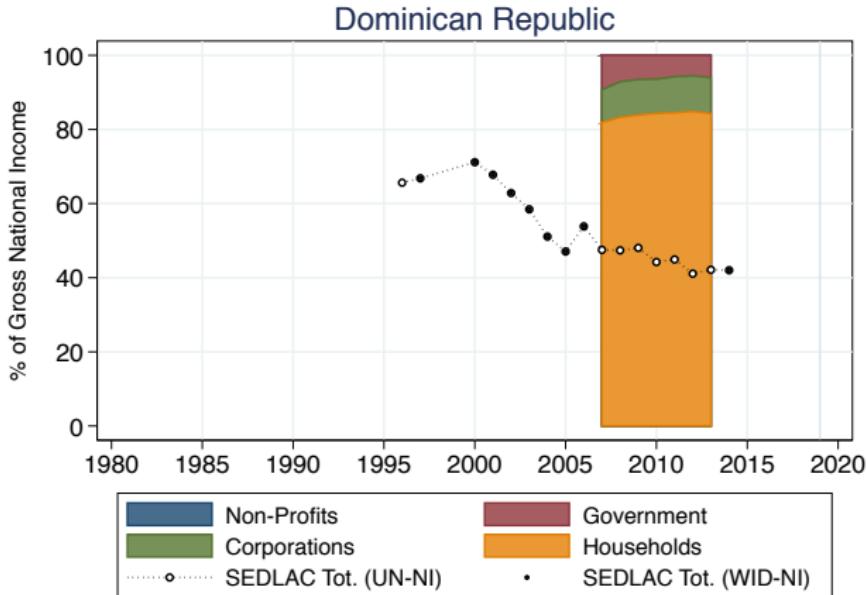
# Filling the national accounts gap



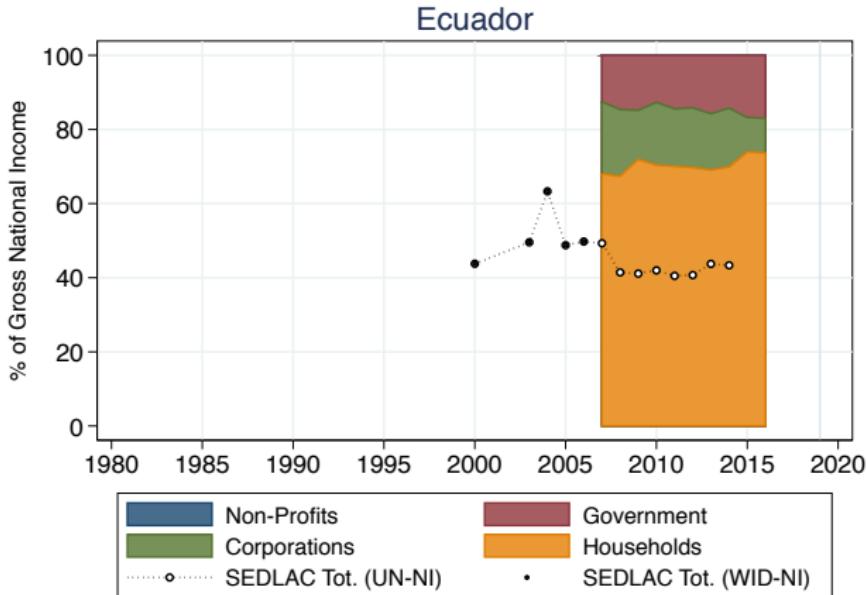
# Filling the national accounts gap



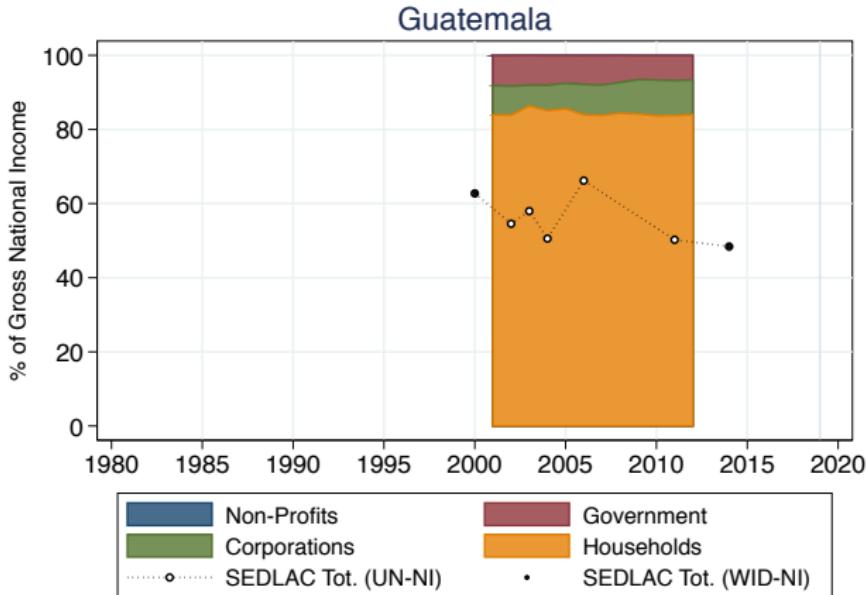
# Filling the national accounts gap



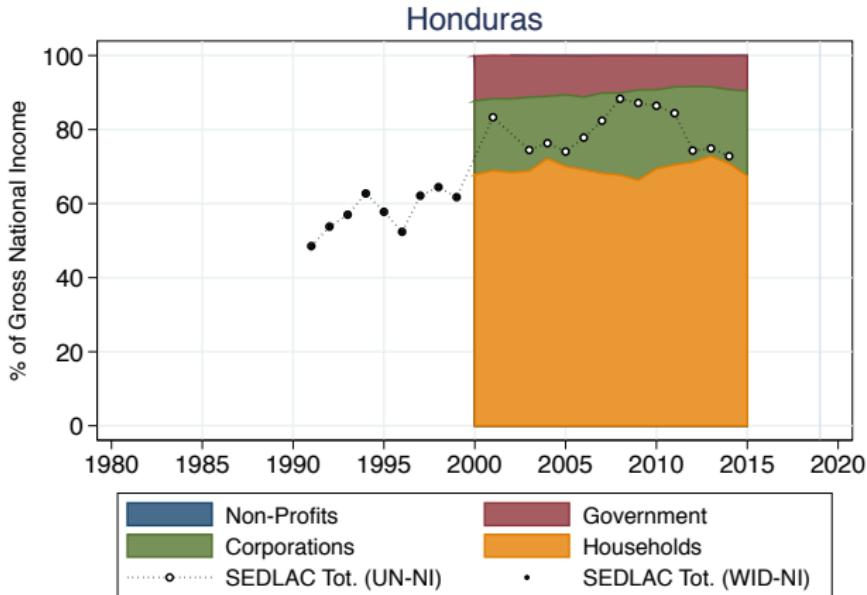
# Filling the national accounts gap



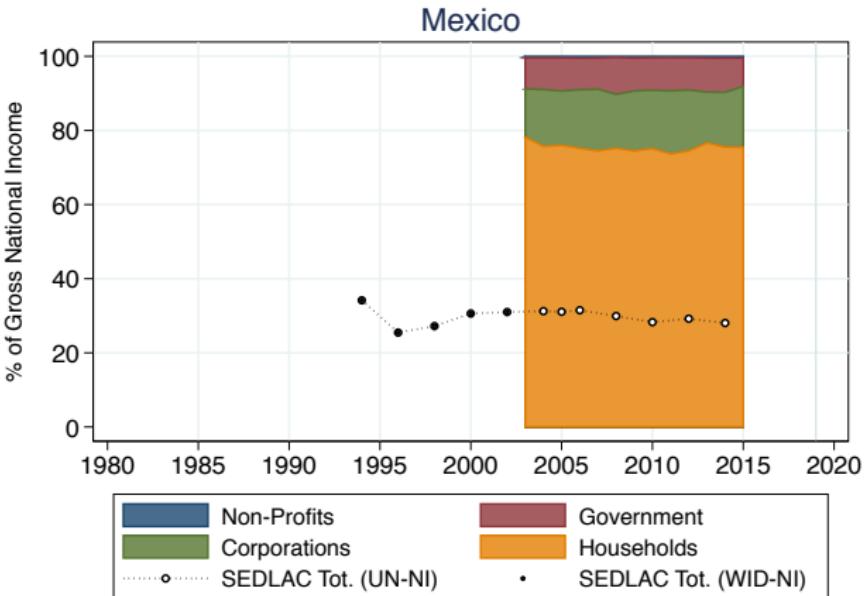
# Filling the national accounts gap



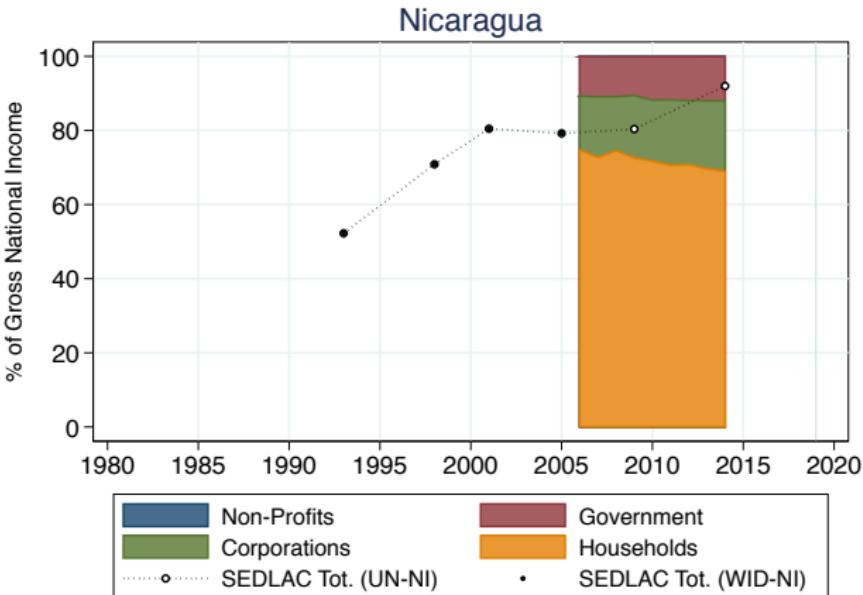
# Filling the national accounts gap



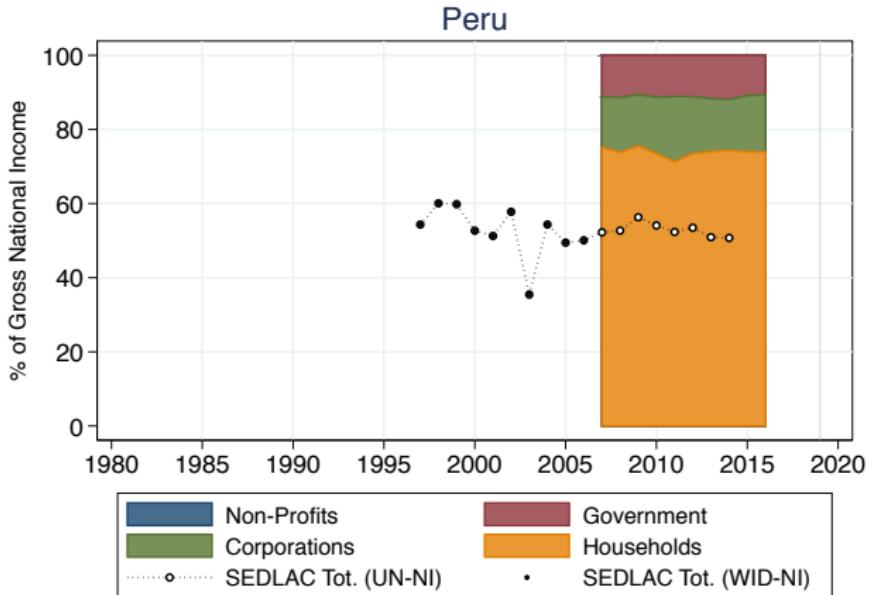
# Filling the national accounts gap



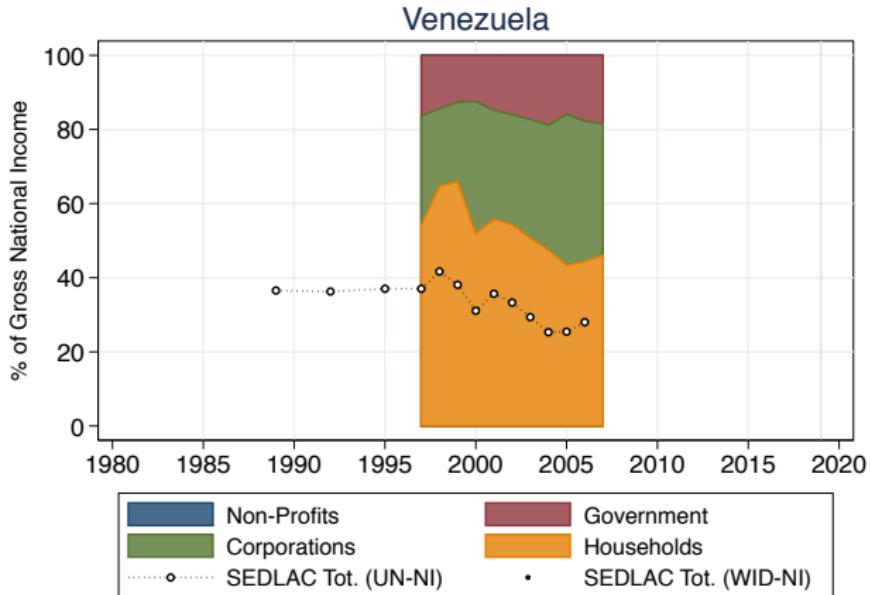
# Filling the national accounts gap



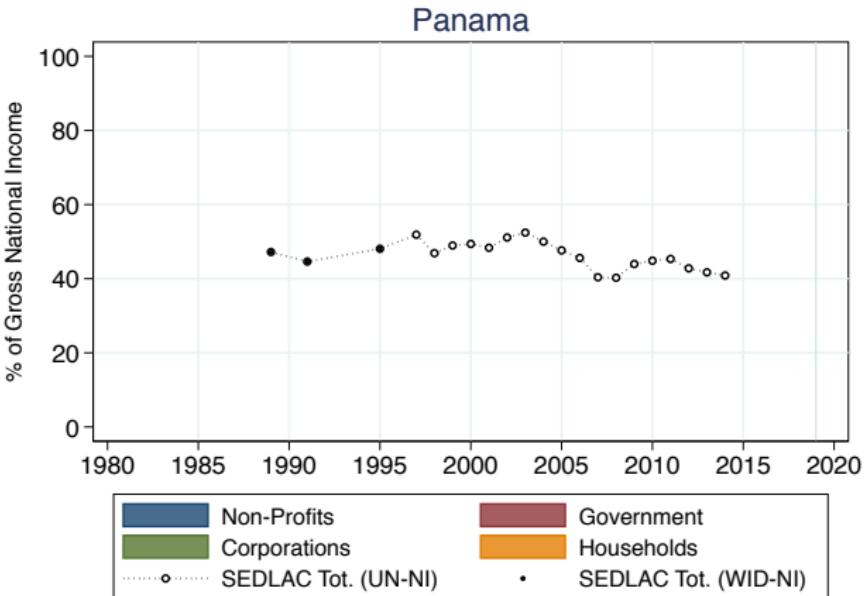
# Filling the national accounts gap



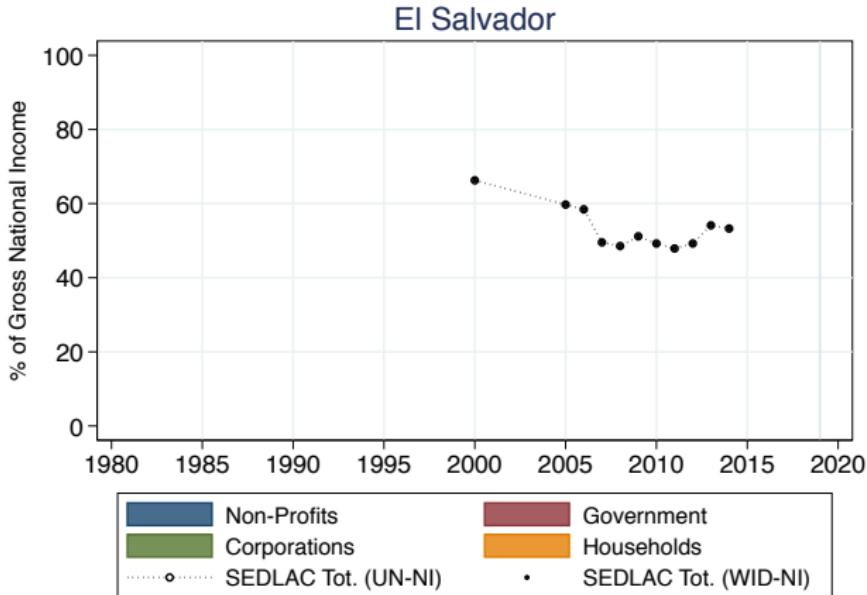
# Filling the national accounts gap



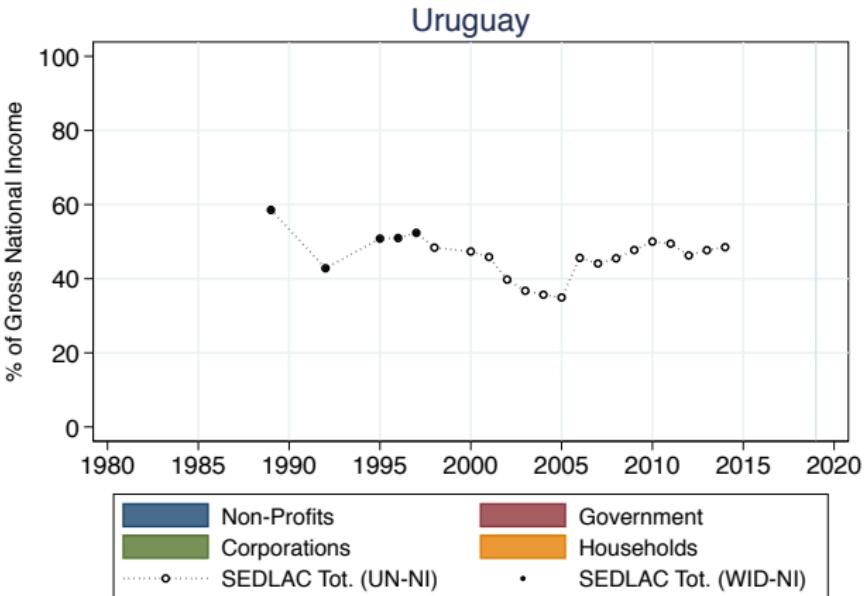
# Filling the national accounts gap



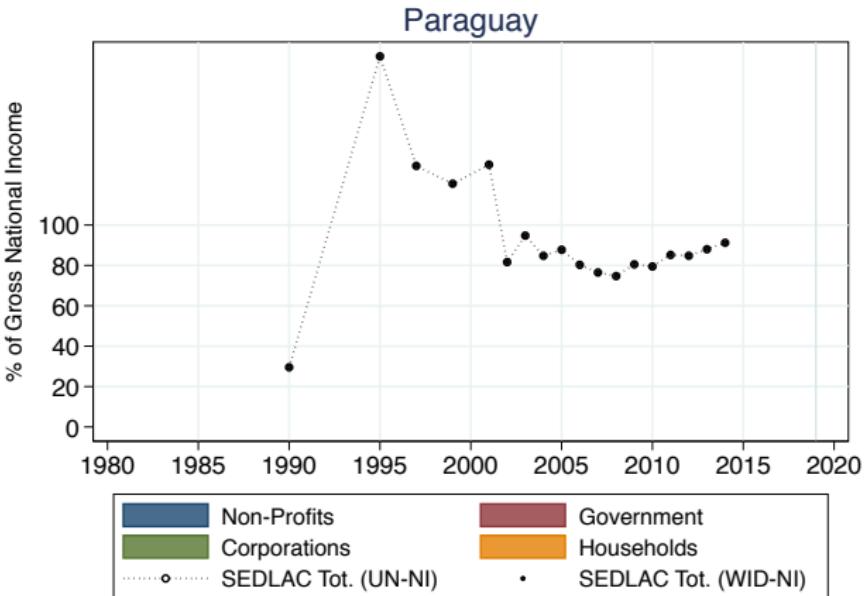
# Filling the national accounts gap



# Filling the national accounts gap



# Filling the national accounts gap



**Gracias!**