

# Estimadores de regresión/calibración compuestos

## Aplicación Encuesta Continua de Hogares de Uruguay

Juan Pablo Ferreira  
[jferreir@ine.gub.uy](mailto:jferreir@ine.gub.uy)

Instituto Nacional de Estadística

Seminario Regional sobre Innovaciones y Desafíos en Encuestas  
de Hogares

# introducción

- ▶ inicio = 1968.
- ▶ encuesta multipropósito que releva información de los hogares y personas
- ▶ indicadores oficiales de:
  - ▶ mercado laboral <ML> (e.g. actividad, empleo y desempleo)
  - ▶ ingresos de hogares y personas
  - ▶ pobreza de hogares y personas
  - ▶ condiciones de vida (e.g. educación, salud, etc.)
- ▶ **periodicidad:** ML e ingresos mensuales; resto anual (por el INE)

## metodología hasta 2019

- ▶ **condición de elegibilidad** = hogares particulares situados en viviendas particulares en todo el país (Inicio =2006)
- ▶ **cross-section** (i.e. muestras mensuales independientes)
- ▶ **diseño muestral:** aleatorio, estratificado, por conglomerados y en dos etapas de selección.
- ▶ 3400 hogares mensuales (elegibles respondentes <ER>)
- ▶ 41000 hogares en el año
- ▶ relevamiento 100% presencial (CAPI)
- ▶ cuestionario único (condiciones de vida + ML + ingresos)

## método de estimación (hasta 2019)

Distintos indicadores/parámetros  $\theta$  eran estimados utilizando **estimadores directos** teniendo en cuenta únicamente a los *ER* y en base a un sistema de ponderadores **único**  $w_i \forall i \in \text{ER}$  que eran computados de forma mensual, trimestral y anual.

- ▶ por ejemplo, la estimación del total en la población ( $U$ ) de una variable cualquiera  $y$  es:

$$Y = \sum_{i \in U} y_i$$

y es estimado como:

$$\hat{Y} = \sum_{i \in \text{ER}} w_i y_i$$

## método de estimación (hasta 2019)

- ▶ estimadores **calibrados/regresión** para la producción de las estimaciones de los distintos indicadores  $\theta$
- ▶ Vector/set para calibrar/modelar  $\mathbf{x}_i = (x_{1i}, \dots, x_{Ji})^T$  son variables de pertenencia (indicadoras) a distintos grupos demográficos (e.g. tramos de edad, sexo y region <departamento>)

### enfoque de regresión

$$E_m(y_i) = \mathbf{x}_i^T \boldsymbol{\beta} = \mu + \text{edad}_j + \text{sexo}_k + \text{dpto}_l$$

### enfoque de calibración

$$\sum_{i \in ER} w_i \mathbf{x}_i = \sum_{i \in U} \mathbf{x}_i$$

## método de estimación (hasta 2019)

el ponderador de la persona  $i$  queda definido como:

$$w_i = d_i \times \hat{\phi}_i^{-1} \times g_i$$

donde:



$$d_i = (\text{Prob}[i \in \text{muestra}])^{-1} = f_h^{-1} = \frac{N_h}{n_h}$$

- ▶  $\hat{\phi}_i$  es la propensión de estimada del hogar/persona  $i$  de responder. Se **asume MAR** y un modelo de igualdad de medias a nivel de estrato.
- ▶  $g_i$  es el ajuste proveniente de la calibración:

$$g_i = 1 + \left( \sum_{i \in U} \mathbf{x}_i - \sum_{i \in ER} w_i^{nr} \mathbf{x}_i \right)^T \left( \sum_{i \in ER} w_i^{nr} \mathbf{x}_i \mathbf{x}_i^T \right)^{-1} \mathbf{x}_i,$$

## método de estimación (hasta 2019)

la estimación de un total (u otro parámetro  $\theta$ ) puede verse bajo dos enfoques:

- ▶ **enfoque de regresión**

$$\hat{Y}_{RE} = \sum_{i \in U} \hat{y}_i + \sum_{i \in ER} w_i^{nr} (y_i - \hat{y}_i)$$

donde  $\hat{y}_i = \mathbf{x}_i^T \hat{\mathbf{B}}$  y los parámetros del modelo son estimado con los datos de la propia muestra

- ▶ **enfoque de calibración**

$$\hat{Y} = \sum_{i \in ER} w_i y_i$$

donde  $w_i$  son los ponderadores calibrados (i.e. cumplen las ecuaciones de calibración)

## construcción matriz para la calibración

hogar	persona	sexo	edad	dpto
1	1	H	45	MVD
1	2	M	40	MVD
2	1	H	24	MVD
2	2	H	21	MVD
2	3	M	24	MVD
3	1	H	53	MVD
3	2	M	55	CAN
3	3	M	27	CAN
3	4	M	15	CAN
4	1	H	41	CAN

hogar	persona	X1	X2	X3	X4	X5	X6
1	1	0	1	0	0	1	0
1	2	0	0	0	1	1	0
2	1	1	0	0	0	1	0
2	2	1	0	0	0	1	0
2	3	0	0	1	0	1	0
3	1	0	1	0	0	1	0
3	2	0	0	0	1	0	1
3	3	0	0	0	1	0	1
3	4	0	0	1	0	0	1
4	1	0	1	0	0	0	1

variables indicadoras representando grupos de sexo/edad y de  
región: X1 hombres (0-24), X2 hombres (25+), X3 mujeres (0-24)  
X4 mujeres (25+), X5 Mvd, X6 Can

## método de integración

- ▶ variables de calibración  $x$  se encuentran definidas a nivel de persona
- ▶ ECH produce estimaciones a nivel de hogares y personas
- ▶ necesidad de consistencia (sistema de ponderación único **uniweight**)
- ▶ para producir ponderadores  $w_i$  iguales para cada individuo del hogar se utiliza el método de integración.
- ▶ las variables  $X$  previo a la calibración son sustituidas por el promedio de las mismas a nivel de hogar.

## precisiones ECH 2019 (una mirada)

ECH tiene un tamaño de muestra suficientemente grande para estimar ciertos indicadores (con periodicidad baja <e.g. pobreza>) y pequeña para indicadores claves con periodicidad alta (e.g. ML)

- ▶ diseño y tamaño muestral no es suficiente para brindar estimaciones confiables de ML de forma mensual
  - ▶ moe de 1% para las estimaciones mensuales del nivel de las tasas ML
  - ▶ capaz de detectar cambios significativos (al 95%) de un mes a otro si son mayores a 1.3%

## metodología ECH (nueva)

- ▶ encuesta de panel rotativo
- ▶ la muestra de un mes está compuesta por seis paneles (grupos de rotación)
- ▶ relevamiento mixto:
  - ▶ **CAPI:** implantación que releva variables habituales de la ECH por única vez
  - ▶ **CATI:** seguimiento solo ML durante 5 meses +

## objetivos

- ▶ mejorar las estimaciones de ML
  1. reducir los moe para las estimaciones mensuales tanto de nivel como el cambio neto respecto a la ECH 2019
  2. producir indicadores confiables para una amplia gama de áreas de estimación de forma mensual (e.g. educación, género, departamentos, etc)
- ▶ mantener la calidad de las estimaciones para el resto de los indicadores que brinda la ECH

## nueva metodología 2021

- ▶ la nueva ECH pasa a ser una encuesta de panel rotativo con periodicidad mensual, en donde, la muestra de un mes, está compuesta por seis paneles (grupos de rotación).
- ▶ la ECH 2021 se basa en la **Labour Force Survey (LFS) de StatCan**

# sistema de rotación

Grupo de rotación (GR)	mes de la encuesta (estimación)											
	2021						2022					
	7	8	9	10	11	12	1	2	3	4	5	
1	1ra	2do	3ra	4ta	5ta	6ta						abandona la encuesta
2		1ra	2do	3ra	4ta	5ta	6ta					
3			1ra	2do	3ra	4ta	5ta	6ta				
4				1ra	2do	3ra	4ta	5ta	6ta			
5					1ra	2do	3ra	4ta	5ta	6ta		
6						1ra	2do	3ra	4ta	5ta	6ta	
1							1ra	2do	3ra	4ta	5ta	
2								1ra	2do	3ra	4ta	
3									1ra	2do	3ra	
4										1ra	2do	
5											1ra	
6												

- ▶ cada GR es implantado presencialmente y aplicando un formulario similar a la ECH 2019
- ▶ un GR está conformado por 2000 hogares ER aproximadamente

## método de estimación para ML

- ▶ el solapamiento entre las muestras de un mes a otro puede ser explotado también en la etapa de estimación.
- ▶ existen estimadores que utilizan las estimaciones del ML del mes anterior  $\hat{\theta}_{t-1}$  para mejorar las precisiones de los estimadores del mes  $t$ , ya sea, para el nivel  $\hat{\theta}_t$ , como para el cambio neto (i.e.  $\hat{\Delta} = \hat{\theta}_t - \hat{\theta}_{t-1}$ )

**dos estrategias distintas:**

- ▶ estimadores compuestos K o AK (CPS)
- ▶ estimadores de **calibración/regresión compuestos (CRE)**

## estimadores compuestos

Ambos métodos explotan el solapamiento y la información del GR que abandona la encuesta.

- ▶ CRE reduce los SE del nivel y cambio neto mientras siguen cumpliendo la expansión a conteos demográficos
- ▶ Fácil de instrumentar en R utilizando paquetes existentes (e.g. survey). Simplemente se aumentan las variables de calibración.
- ▶ Estimación de la varianza se vuelve compleja y no se encuentra implementada en ningún paquete.

## estimación del nivel (MR1)

- ▶ añade variables extras a la ecuación de calibración para reducir el moe de la **estimación del nivel (MR1)**
- ▶ las variables nuevas son construidas con variables indicadoras del mes anterior  $\mathbf{z}_{t-1}$  del status de la persona en ML (e.g. ocupado en  $t - 1$ )

$$\mathbf{z}_i^L = \begin{cases} \mathbf{z}_{i,t-1} & \text{si } i \in ER_t - ER_t^b \\ \hat{\mathbf{Z}}/N_{PET} & \text{si } i \in ER_t^b \end{cases} \quad (1)$$

- ▶ lo anterior implica que si estimamos el total de la variable  $\mathbf{z}_i^L$  coincide con la estimación del mes anterior, i.e,

$$\hat{\mathbf{Z}} = \sum_{i \in ER} w_i \mathbf{z}_i^L$$

Esta forma de imputar se realiza para que MR1 sea un estimador insesgado (HT) para estimar el total del mes anterior

## método de estimación para ML

- ▶ añade variables extras a la ecuación de calibración para reducir el moe de la **estimación del cambio (MR2)**

$$z_i^c = \begin{cases} z_{i,t-1} + (R^{-1} - 1)(z_{i,t-1} - z_{i,t}) & \text{si } i \in ER_t - ER_t^b \\ z_{i,t} & \text{si } i \in ER_t^b \end{cases} \quad (2)$$

donde  $R \approx 5/6$  es la tasa de solapamiento ponderada.

- ▶ al igual que con el estimador **MR1**, si se estima el total de la variable  $z_i^c$  coincide con la estimación del mes anterior
- ▶ esta forma de imputar se realiza para que MR2 (al igual que MR1) sea un estimador insesgado (HT) para estimar el total del mes anterior

## ampliación de la matriz de calibración

Para las personas incluidas en la **muestra de solapamiento**, las variables  $z^C$ , a modo de ejemplo, quedan definidas como:

persona	ocupado en t	ocupado en t-1	Z ocupado C
1	1	1	1
2	1	0	-0.2
3	0	1	1.2
4	0	0	0

## método de estimación para ML

Se deben generar tantas variables  $\mathbf{z}^L$  y  $\mathbf{z}^C$ , como parámetros a estimar (e.g. totales de empleo, desempleo y actividad) así como definirlas no solo a nivel de todo el país, sino también para distintas áreas de estimación (e.g. sexo, región, etc.)

- ▶ **problema:** añadir muchas variables a la ecuación de calibración puede provocar estimaciones inestables producto de la existencia ponderadores  $w_i$  extremos e incluso **negativos**
- ▶ **solución:** construir variables  $\mathbf{z}$  como una combinación lineal ponderada de  $\mathbf{z}^L$  y  $\mathbf{z}^C$

$$\mathbf{z}_i = (1 - \alpha)\mathbf{z}_i^L + \alpha\mathbf{z}_i^C$$

donde  $\alpha = 2/3$  se elige como un compromiso entre reducción de los errores estándares de los estimadores de nivel y cambio neto.

## estimador CRE

Los ponderadores  $w_i^{cre}$  son obtenidos minimizando la función de distancia lineal entre  $w^{nr}$  y los ponderadores  $w^{cre}$ , sujetos a la ecuación de calibración

$$\sum_{i \in ER} w_i^{cre} \begin{pmatrix} \mathbf{x}_i \\ \mathbf{z}_i \end{pmatrix} = \begin{pmatrix} \mathbf{X} \\ \hat{\mathbf{Z}} \end{pmatrix}$$

donde

$$w_i^{cre} = w_i^{nr} g_i^{cre},$$

y  $g_i^{cre}$  es el factor de ajuste proveniente de calibración:

$$g_i^{cre} = 1 + (\mathbf{x}_i^T, \mathbf{z}_i^T) \left( \sum_{i \in ER} w_i^{nr} (\mathbf{x}_i^T, \mathbf{z}_i^T)^T (\mathbf{x}_i^T, \mathbf{z}_i^T) \right)^{-1} \left( (\mathbf{X}^T, \hat{\mathbf{Z}}^T)^T - \sum_{i \in ER} w_i^{nr} (\mathbf{x}_i^T, \mathbf{z}_i^T) \right)$$

## estimador CRE

### **Importante:**

Dado que el estimador CRE es una función del estimador compuesto del mes anterior, por definición es un **estimador recursivo**, debido a que las variables auxiliares son ajustadas a conteos o totales que poseen un componente aleatorio (son estimaciones del mes anterior)

# información auxiliar demográfica

- ▶ 44 grupos de edad/sexo/región (Capital y Resto)
  - ▶ 14 a 17 años, 18 a 24 años, 25 a 29 años, 30 a 34 años, 35 a 39 años, 40 a 44 años, 45 a 50 años, 50 a 54 años, 55 a 64 años, 65 a 74 años, 75 o + años
- ▶ Departamento (14 o + años)
- ▶ Grupo de rotación (14 o + años)

## variables auxiliares compuestas

- ▶ Personas ocupadas de 14 o + años a nivel total país
- ▶ Personas desocupadas de 14 o + años a nivel total país
- ▶ Personas inactivas de 14 o + años a nivel total país
- ▶ Hombres ocupados de 14 o + años a nivel total país
- ▶ Hombres desocupados de 14 o + años a nivel total país
- ▶ Hombres inactivos de 14 o + años a nivel total país
- ▶ Mujeres ocupadas de 14 o + años a nivel total país
- ▶ Mujeres desocupadas de 14 o + años a nivel total país
- ▶ Mujeres inactivas de 14 o + años a nivel total país
- ▶ Personas ocupadas de 14 o + años por departamento
- ▶ Personas desocupadas de 14 o + años por departamento
- ▶ Personas inactivas de 14 o + años por departamento

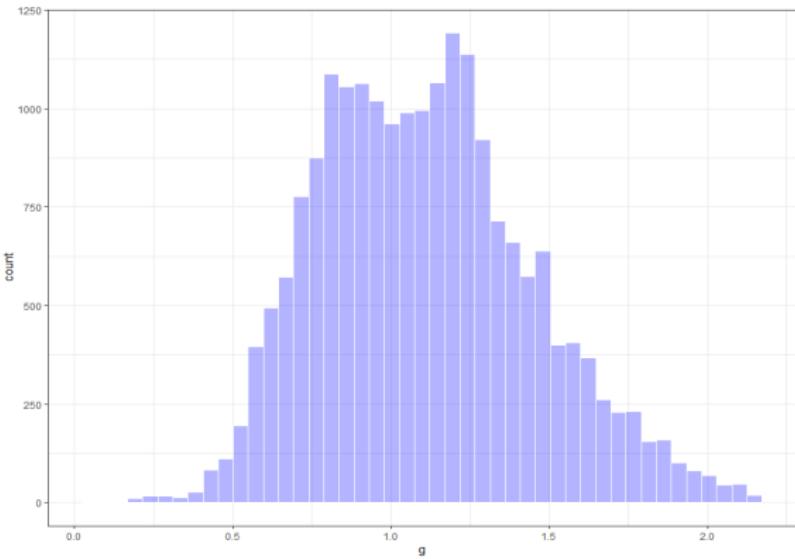
## imputación de datos faltantes

- ▶ para la creación de los vectores  $\mathbf{z}_i^L$  y  $\mathbf{z}_i^C$  se imputan los datos faltantes del grupo de rotación de nacimiento.
- ▶ pueden existir datos faltantes de las variables indicadoras de ML en  $t - 1$  para los nuevos miembros del hogar o integrantes que comienzan a formar parte de la PET.
- ▶ para los nuevos miembros se imputan los datos de  $t - 1$  utilizando donantes aleatorios.
- ▶ para los integrantes que comienzan a participar en la PET se les impulta cero.

## tratamiento de los ponderadores finales menores a uno

- ▶ la función de distancia lineal para la calibración puede permitir excepcionalmente que existan algunos ponderadores menores a uno e incluso negativos
- ▶ desde el punto de vista teórico, la existencia de ponderadores negativos no repercute en el sesgamiento del estimador
- ▶ por convención e incluso por "interpretación", los ponderadores de las unidades (hogares y personas) deben ser mayores o iguales a uno.
- ▶ una vez realizada la calibración compuesta a todas las unidades que tengan ponderadores menores a uno, se les asigna un ponderador final igual a 1.

# fatores de ajuste $g$



## RE vs CRE

- ▶ se simularon 5000 réplicas bajo un MAS c/rep
- ▶ para cada réplica se calcularon las estimaciones de nivel  $\hat{\theta}_t$  y cambio neto  $\hat{\Delta}_t = \hat{\theta}_t - \hat{\theta}_{t-1}$  de ML
- ▶ se computaron las eficiencias relativas, la cuales, se definen como el cociente entre varianzas

### cambio en el método de estimación en ML

- ▶ RCE vs RE nivel ocupados **90%**
- ▶ RCE vs RE nivel desocupados **91%**
- ▶ RCE vs RE cambio neto ocupados **54%**
- ▶ RCE vs RE cambio neto desocupado **85%**

## estimación de la varianza (simplificado)

se utilizan técnicas de remuestreo o réplicas (Bootstrap)

- ▶ se parte de los ER del mes y se generan 1000 sistemas de ponderadores bootstrap

$$w_{kjh}^b = \frac{n_h}{n_{h-1}} m_{hj}^b w_{kjh}^{nr}$$

- ▶ para cada uno de los sistemas de ponderadores Bootstrap se realiza la calibración compuesta. Si, los conteos o benchmarks  $\hat{Z}$  se consideran fijos, se subestima la varianza.

## estimación de la varianza del cambio neto

- ▶ la matriz de pesos Bootstrap permite obtener estimaciones de la varianza para los estimadores cross-section (nivel); y pueden ser utilizados con cualquier software que estime varianza para diseños muestrales complejos.
- ▶ las estimaciones de las varianzas para los cambios netos son más complejas y no pueden ser llevadas a cabo con softwares tradicionales.
- ▶ se indica a los usuarios utilizar los pesos Bootstrap para la estimación de niveles y aplicar formulas que tengan en cuenta la correlación entre muestras y el porcentaje de solapamiento. Por ejemplo, la estimación del error estándar (SE) del cambio neto  $\hat{\Delta} = \hat{\theta}_t - \hat{\theta}_{t-1}$  es:

$$\widehat{SE}(\hat{\Delta}) = \sqrt{(1 - R\rho)} \sqrt{\widehat{SE}^2(\hat{\theta}_t) + \widehat{SE}^2(\hat{\theta}_{t-1})}$$

## estimación de la varianza (correcta)

### Bootstrap coordinado

- ▶ cuando las UPM son las mismas de un mes a otro, se les asigna los factores de multiplicidad del mes anterior.
- ▶ cuando solo algunas UPM se mantienen en los dos meses (5/6 aprox) se transfieren los factores de multiplicidad de las UPM en común. El resto (1/6) pertenecientes al GR de nacimiento, se les asigna un factor de multiplicidad de forma aleatoria correspondiente a las UPM que abandonan la encuesta.

## estimación de la varianza (correcta)

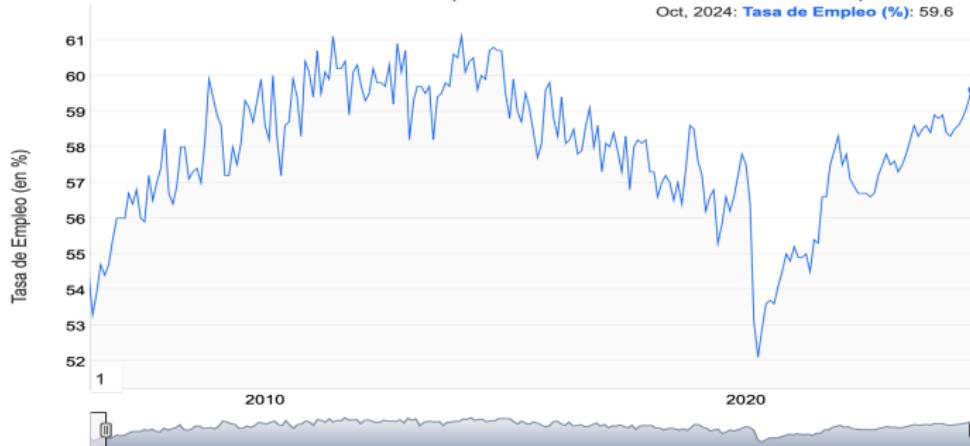
- ▶ A los ponderadores bootstrap se les aplica el factor de ajuste por no respuesta (único).
- ▶ Utilizando los ponderadores finales bootstrap del mes anterior se computan los totales  $\hat{Z}^{(b)}$  para cada una de las réplicas. Esto se hace para agregarle el componente estocástico a los conteos compuestos.
- ▶ Los ponderadores bootstrap generados en el paso 1 son calibrados a los conteos demográficos y a los conteos de las variables auxiliares compuestas para la réplica bootstrap correspondiente.

## resultados

Previo al cambio la serie era muy errática y para confirmar cambios era necesario esperar movimientos consecutivos en la misma dirección.

Ahora se tiene una serie mas suavizada (con menor ruido producto del error de muestreo).

Gráfico 2: Evolución mensual de la tasa de empleo. Período enero 2006 a último dato disponible. Total país  
Oct, 2024: Tasa de Empleo (%): 59.6



Fuente: INE - Encuesta Continua de Hogares

## resultados

Para ver más resultados y distintas aperturas, visita :

[https://www.gub.uy/instituto-nacional-estadistica/  
encuesta-continua-hogares](https://www.gub.uy/instituto-nacional-estadistica/encuesta-continua-hogares)