

# Estimação de Variância com a PNADC

## Método dos Conglomerados Primários e Estimador de Calibração

Guilherme Jacob

Doutorando na Escola Nacional de Ciências Estatísticas (ENCE/IBGE)

25/07/2022

# Roteiro

1. Estimando Totais na PNADC
  - ▶ Estimador de Horvitz-Thompson
  - ▶ Variância do Estimador de Horvitz-Thompson
  - ▶ Método dos Conglomerados Primários
2. Calibração na PNADC
  - ▶ Pós-Estratificação
  - ▶ *Raking*
3. Implementação no R

Estimando Totais na PNADC

# Estimando Totais com Amostras Probabilísticas

- ▶ *Amostragem probabilística*: métodos para selecionar amostras e fazer inferência de acordo com o plano amostral;
- ▶ População *finita*  $\mathcal{U}$ , composta por  $N$  unidades;
- ▶ Amostra  $s \subset \mathcal{U}$ , composta por  $n$  unidades;
- ▶ Plano amostral  $p(s)$ : distribuição de probabilidade que associa todas as amostras possíveis  $s$  de  $\mathcal{U}$  a uma probabilidade;
  - ▶ A aleatoriedade da amostra é determinada pelo plano amostral!

# Estimando Totais com Amostras Probabilísticas

Quanto à seleção de amostras, isso significa selecionar amostras que atendam as probabilidades de inclusão de 1ª e 2ª ordem,  $\pi_i$  e  $\pi_{ij}$ :

- ▶  $\pi_i = \Pr(i \in s)$ : probabilidade da unidade  $i$  ser incluída em uma amostra aleatória  $s$ ;
- ▶  $\pi_{ij} = \Pr(i, j \in s)$ : probabilidade das unidades  $i$  e  $j$  serem incluídas conjuntamente em uma amostra aleatória  $s$ ;

# Estimando Totais com Amostras Probabilísticas

Em relação à estimação, partimos do estimador de Horvitz-Thompson. O estimador de totais de Horvitz-Thompson é definido por:

$$\hat{Y}_{HT} = \sum_{i \in s} \frac{y_i}{\pi_i} = \sum_{i \in s} d_i y_i$$

onde  $d_i$  é o *peso amostral básico*.

# Estimando Totais com Amostras Probabilísticas

A variância de  $\widehat{Y}_{HT}$  é dada por

$$\text{Var}[\widehat{Y}_{HT}] = \sum_{i \in \mathcal{U}} \sum_{j \in \mathcal{U}} \frac{y_i}{\pi_i} \frac{y_j}{\pi_j} \Delta_{ij},$$

onde  $\Delta_{ij} = \pi_{ij} - \pi_i \pi_j$  é a covariância dos indicadores de inclusão na amostra das unidades  $i$  e  $j$ .

Esta variância pode ser estimada usando

$$\widehat{\text{Var}}[\widehat{Y}_{HT}] = \sum_{i \in \mathbf{s}} \sum_{j \in \mathbf{s}} \frac{y_i}{\pi_i} \frac{y_j}{\pi_j} \frac{\Delta_{ij}}{\pi_{ij}}.$$

# Amostragem na PNADC

## Plano Amostral da PNADC:

- ▶ Amostragem em Dois Estágios com Estratificação das Unidades Primárias de Amostragem (UPA):
  - ▶ Em cada estrato, seleciona uma amostra  $s_I$  de  $m$  UPAs com probabilidade proporcional ao tamanho (PPT de Pareto);
  - ▶ Na UPA selecionada  $i$ , seleciona uma amostra  $s_i$  de  $\bar{n}$  domicílios com Amostragem Aleatória Simples (sem reposição).

## Observações:

- ▶ Tamanho da amostra:  $n = m \times \bar{n}$ ;
- ▶ A princípio, dentro de cada estrato, esse plano gera amostras *autoponderadas*.



# Amostragem na PNADC

Observações sobre a estratificação:

- ▶ Estratos são partições da população. Por isso, o total da população é a soma dos totais dos estratos;
- ▶ Podemos estimar o total populacional pela soma das estimativas dos totais dos estratos;
- ▶ Como o sorteio dentro de cada estrato é independente, a variância do estimador do total pode ser estimada pela soma das variâncias estimadas dos totais dos estratos.

## Amostragem na PNADC

Portanto, considerando os  $h = 1, \dots, H$  estratos da PNADC, podemos fazer:

$$\widehat{Y}_{\text{PNADC}} = \sum_{h=1}^H \widehat{Y}_{\text{PNADC},h} \implies \text{Var}[\widehat{Y}_{\text{PNADC}}] = \sum_{h=1}^H \text{Var}[\widehat{Y}_{\text{PNADC},h}]$$
$$\therefore \widehat{\text{Var}}[\widehat{Y}_{\text{PNADC}}] = \sum_{h=1}^H \widehat{\text{Var}}[\widehat{Y}_{\text{PNADC},h}]$$

## Amostragem na PNADC

Assim, considerando um estrato  $h$  da PNADC, temos:

$$\text{Var}[\widehat{Y}_{\text{PNADC},h}] = \sum_{i \in \mathcal{U}_I} \sum_{j \in \mathcal{U}_I} \frac{Y_i}{\pi_{Ii}} \frac{Y_j}{\pi_{Ij}} \Delta_{Iij} + \sum_{i \in \mathcal{U}_I} \frac{\text{Var}_{\text{AAS}}[\widehat{Y}_i]}{\pi_{Ii}}$$

$$\therefore \text{Var}[\widehat{Y}_{\text{PNADC},h}] = \sum_{i \in \mathcal{U}_I} \sum_{j \in \mathcal{U}_I} \frac{Y_i}{\pi_{Ii}} \frac{Y_j}{\pi_{Ij}} \Delta_{Iij} + \sum_{i \in \mathcal{U}_I} \frac{N_i^2}{\pi_{Ii}} \left(1 - \frac{\bar{n}}{N_i}\right) S_i^2,$$

onde:

- ▶  $\pi_{Ii}$  é a probabilidade de inclusão de 1ª ordem da UPA  $i$ ;
- ▶  $Y_i$  e  $\widehat{Y}_i$  são o valor e a estimativa do total de  $y$  na UPA  $i$ , respectivamente;
- ▶  $N_i$  é o número de domicílios na UPA  $i$ ;
- ▶  $S_i^2$  é a variância populacional da característica  $y$  na UPA  $i$ .

## Amostragem na PNADC

O estimador não-viesado desta variância é:

$$\widehat{\text{Var}}[\widehat{Y}_{\text{PNADC},h}] = \sum_{i \in S_I} \sum_{j \in S_I} \frac{\widehat{Y}_i}{\pi_{Ii}} \frac{\widehat{Y}_j}{\pi_{Ij}} \frac{\Delta_{Iij}}{\pi_{Iij}} + \sum_{i \in S_I} \frac{N_i^2}{\pi_{Ii}} \left(1 - \frac{\bar{n}}{N_i}\right) s_i^2,$$

onde:

- ▶  $\pi_{Iij}$  é a probabilidade de inclusão de 2ª ordem das UPAs  $i$  e  $j$  na amostra do primeiro estágio  $S_I$ ;
- ▶  $s_i^2$  é a variância da característica  $y$  na amostra  $s_i$  de domicílios da UPA  $i$ .

O problema é que essa fórmula exigiria conhecer uma matriz quadrada  $\pi_{Iij}$  de tamanho  $m \times m$ , o que não é trivial.

## Método dos Conglomerados Primários

Antes de adotar o método do *Bootstrap*, a variância do estimador  $\widehat{Y}$  se baseava no Método dos Conglomerados Primários (MCP):

$$\widehat{\text{Var}}_{\text{MCP}}[\widehat{Y}_{\text{PNADC},h}] = \frac{m}{m-1} \sum_{i \in \mathbf{s}_I} \left( \frac{\widehat{Y}_i}{\pi_{Ii}} - \frac{\widehat{Y}_{\text{PNADC},h}}{m} \right)^2$$

onde  $m$  é o número de UPAs selecionadas no estrato  $h$ .

Esta é uma das razões para **não excluir observações** de uma base de dados amostrais complexos.

## Calibração na PNADC

# Calibração

Seja  $\mathbf{X} = \sum_{i \in \mathcal{U}} \mathbf{x}_i$  um vetor de  $J$  totais conhecidos na população. Métodos de *calibração* buscam criar um sistema de pesos  $w_i$  que, independente de qual amostra foi selecionada, satisfaça a restrição de calibração:

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

# Calibração

## Resultados da Calibração:

- ▶ Estimativas baseadas em variáveis correlacionadas com as variáveis usadas na calibração se tornam mais precisas;
- ▶ *Pode* reduzir viés de não-resposta e cobertura;
- ▶ Faz as estimativas serem “consistentes” com totais conhecidos da população.



## Pós-estratificação

A técnica mais simples para ajustar pesos é a *pós-estratificação*:

- ▶ Suponha que possamos dividir a população em  $K$  grupos;
- ▶ Se os tamanhos  $N_k$  dos  $K$  grupos forem conhecidos e amostra não for estratificada, os totais estimados  $\hat{N}_k$  não coincidem com os valores populacionais;
- ▶ Mas podemos usar esta informação para corrigir os pesos.

## Pós-estratificação

Ou seja: podemos fazer realizar ajustes  $g_i = N_k / \hat{N}_k$  de modo que

$$\begin{aligned}\sum_{i \in \mathbf{s}_k} \frac{g_i}{\pi_i} &= \sum_{i \in \mathbf{s}_k} \frac{1}{\pi_i} \frac{N_k}{\hat{N}_k} \\ &= \frac{N_k}{\hat{N}_k} \sum_{i \in \mathbf{s}_k} \frac{1}{\pi_i} = \frac{N_k}{\hat{N}_k} \hat{N}_k = N_k\end{aligned}$$

Isso significa substituir os pesos básicos  $d_i = 1/\pi_i$  pelos pesos de pós-estratificação  $w_i = g_i/\pi_i = N_k/(\hat{N}_k\pi_i)$ .

## Pós-estratificação

Seja  $\mu_k$  a média populacional de uma variável  $y_i$  no grupo  $k$  e  $\mu_{k(i)}$  a média populacional do grupo que contem a observação  $i$ . Assim, fazendo  $y_i = (y_i - \mu_{k(i)}) + \mu_{k(i)}$ , temos:

$$\hat{Y} = \sum_{i \in \mathbf{s}} \frac{g_i}{\pi_i} [(y_i - \mu_{k(i)}) + \mu_{k(i)}] = \sum_{i \in \mathbf{s}} \frac{g_i}{\pi_i} (y_i - \mu_{k(i)}) + \sum_{i \in \mathbf{s}} \frac{N_{k(i)} \mu_{k(i)}}{\hat{N}_{k(i)} \pi_i}$$

$$\hat{Y} = \sum_{i \in \mathbf{s}} \frac{g_i}{\pi_i} (y_i - \mu_{k(i)}) + \sum_{k=1}^K \frac{N_k}{\hat{N}_k} \hat{N}_k \mu_k$$

$$\hat{Y} = \sum_{i \in \mathbf{s}} \frac{g_i}{\pi_i} (y_i - \mu_{k(i)}) + \sum_{k=1}^K N_k \mu_k, \quad \sum_{k=1}^K N_k \mu_k \text{ const.}$$

$$\therefore \hat{Y} = \sum_{i \in \mathbf{s}} \frac{g_i}{\pi_i} e_i + \sum_{k=1}^K N_k \mu_k, \quad e_i = y_i - \mu_{k(i)}$$

## Pós-estratificação

Como o segundo termo é uma constante, sua variância é zero. Logo, podemos estimar a variância aproximada usando

$$\text{Var}[\widehat{Y}] \approx \text{Var}\left[\sum_{i \in \mathbf{s}} \frac{g_i e_i}{\pi_i}\right]$$
$$\therefore \widehat{\text{Var}}[\widehat{Y}] = \sum_{i \in \mathbf{s}} \sum_{j \in \mathbf{s}} \frac{g_i e_i}{\pi_i} \frac{g_j e_j}{\pi_j} \frac{\Delta_{ij}}{\pi_{ij}}$$

Ou seja: podemos estimar a variância do estimador de pós-estratificação usando o estimador da variância do total dos resíduos.

## Raking

- ▶ O estimador de pós-estratificação exige totais conhecidos e tamanhos de amostra suficientemente grandes em cada grupo;
- ▶ Para pós-estratificar por área e idade, precisamos dos totais de todas as combinações de área e faixa etária;
- ▶ Quanto maior o número de grupos, menor é o tamanho da amostra em cada grupo;
- ▶ *Raking* é um método de calibração que permite usar uma abordagem mais parcimoniosa, calibrando pelas “marginais”;
  - ▶ No exemplo, totais da população de cada área e totais de cada faixa etária na população geral.

## Raking

- ▶ O *raking* é implementado como um processo iterativo, “pós-estratificando” sucessivamente em cada vetor de totais até que os totais estimados sejam (aproximadamente) iguais aos totais de calibração;
  - ▶ *Iterative Proportional Fitting* (IPF).
- ▶ Como na pós-estratificação, a variância do total pode ser aproximada pela variância do total dos resíduos  $e_i$ ;
- ▶ Por sua vez, os resíduos  $e_i$  são calculados pelo processo iterativo, subtraindo as médias dos pós-estratos de cada vetor.

## Raking Generalizado

O método de *Raking* pode ser ampliado para, por exemplo, incluir:

- ▶ Restrições sobre a distância em relação ao peso amostral original;
- ▶ Restrição de igualdade de pesos em determinado estágio de conglomeração.

Em geral, a variância do total pode ser estimada pelo estimador da variância do total dos resíduos, com a fórmula dos resíduos mudando de acordo com o método.

Usando o pacote survey



## Criando o objeto de plano amostral

Com a base de dados da amostra (completa!), declaramos o plano amostral fazendo:

```
# carregando a library
library( survey )

# ajusta formatos dos domínios de calibração
pnadc.df[ , c( "posest" , "posest_sxi" ) ] <-
  lapply( pnadc.df[ , c( "posest" , "posest_sxi" ) ] , factor )

# criando o objeto de plano amostral
pnadc.mcp <-
  svydesign( ids = ~upa+v1008 ,
            strata = ~estrato ,
            data = pnadc.df ,
            weights = ~v1027 )
```

# Aplica calibração

Para aplicar a calibração, é preciso fornecer os totais populacionais. Estes totais estão dispostos na própria base de dados da PNADC:

```
# coleta tabela com os totais das marginais na população
pop.posest <-
  pna dc.df[ !duplicated( pna dc.df$posest ) , c( "posest" , "v1029" ) ]
pop.posest_sxi <-
  pna dc.df[ !duplicated( pna dc.df$posest_sxi ) ,
            c( "posest_sxi" , "v1033" ) ]
pop.posest <-
  pop.posest[ order( pop.posest$posest ) , ]
pop.posest_sxi <-
  pop.posest_sxi[ order( pop.posest_sxi$posest_sxi ) , ]

# ajusta nome das colunas de frequências
colnames( pop.posest ) [2] <- "Freq"
colnames( pop.posest_sxi ) [2] <- "Freq"
```

## Aplica calibração

Dispondo das tabelas de totais, passamos esta informação para a função `calibrate`. A opção `calfun = "raking"` determina a função de pseudo-distância.

```
# aplica calibração via raking com limites e pesos fixos no domicílio
pnadc.mcp.calib <-
  calibrate( pnadc.mcp ,
            formula = list( ~posest , ~posest_sxi ) ,
            population = list( pop.posest, pop.posest_sxi ) ,
            bounds = c(.2,5) ,
            bounds.const = FALSE ,
            calfun = "raking" ,
            aggregate.stage = 2 )
```

## Criando o objeto de plano amostral com pesos de replicação

Para criar o objeto de plano amostral com os pesos de calibração e de replicação (calibrados!) fornecidos pelo IBGE, fazemos:

```
# criando o objeto de plano amostral  
# com pesos de replicação  
pnadc.boot <-  
  svrepdesign( data = pnadc.df ,  
              type = "bootstrap" ,  
              weights = ~v1028 ,  
              repweights = "^v1028[0-9]{3}" ,  
              mse = TRUE )
```

## Verificando os Totais “Calibrados”

Estimador de Horvitz-Thompson e Variância pelo MCP:

```
svyttotal( ~factor( v2007 ) , pnadc.mcp )
```

```
##                total    SE
## factor(v2007)1 81519302 445533
## factor(v2007)2 89931244 466546
```

Estimador de Calibração e Variância pelo MCP:

```
svyttotal( ~factor( v2007 ) , pnadc.mcp.calib )
```

```
##                total SE
## factor(v2007)1 104020393 0
## factor(v2007)2 108787836 0
```

## Verificando os Totais “Calibrados”

Estimador de Calibração e Variância pelo MCP:

```
svyttotal( ~factor( v2007 ) , pnadc.mcp.calib )
```

```
##                total SE
## factor(v2007)1 104020393 0
## factor(v2007)2 108787836 0
```

Estimador de Calibração e Variância por *Bootstrap*:

```
svyttotal( ~factor( v2007 ) , pnadc.boot )
```

```
##                total    SE
## factor(v2007)1 104020393 0.1207
## factor(v2007)2 108787836 0.0998
```

# Estimando Médias

Estimador de Horvitz-Thompson e Variância pelo MCP:

```
svymean( ~v2009 , pnadc.mcp )
```

```
##           mean      SE  
## v2009  37.63  0.0778
```

Estimador de Calibração e Variância pelo MCP:

```
svymean( ~v2009 , pnadc.mcp.calib )
```

```
##           mean      SE  
## v2009  34.843  0.0035
```

# Estimando Médias

Estimador de Calibração e Variância pelo MCP:

```
svymean( ~v2009 , pnadc.mcp.calib )
```

```
##           mean      SE  
## v2009 34.843 0.0035
```

Estimador de Calibração e Variância por *Bootstrap*:

```
svymean( ~v2009 , pnadc.boot )
```

```
##           mean      SE  
## v2009 34.843 0.0035
```



## Estimando Totais

Estimador de Horvitz-Thompson e Variância pelo MCP:

```
svytotal( ~factor( vd4002 ) , poadc.mcp , na.rm = TRUE )
```

```
##                total      SE
## factor(vd4002)1 73881880 427835
## factor(vd4002)2 10657864 138799
```

Estimador de Calibração e Variância pelo MCP:

```
svytotal( ~factor( vd4002 ) , poadc.mcp.calib , na.rm = TRUE )
```

```
##                total      SE
## factor(vd4002)1 92976446 228121
## factor(vd4002)2 13453390 148898
```

## Estimando Totais

Estimador de Calibração e Variância pelo MCP:

```
svyttotal( ~factor( vd4002 ) , pncdc.mcp.calib , na.rm = TRUE )
```

```
##                total      SE  
## factor(vd4002)1 92976446 228121  
## factor(vd4002)2 13453390 148898
```

Estimador de Calibração e Variância por *Bootstrap*:

```
svyttotal( ~factor( vd4002 ) , pncdc.boot , na.rm = TRUE )
```

```
##                total      SE  
## factor(vd4002)1 92976446 218402  
## factor(vd4002)2 13453390 156700
```

## Impacto da Calibração na Estimação de Variância

Também é possível criar um novo objeto de plano amostral que ignora a calibração na estimação de variância.

Estimador de Calibração e Variância pelo MCP (sobre os resíduos):

```
svyttotal( ~factor( vd4002 ) , pnadc.mcp.calib , na.rm = TRUE )
```

```
##                total      SE
## factor(vd4002)1 92976446 228121
## factor(vd4002)2 13453390 148898
```

Estimador de Calibração e Variância pelo MCP (sobre a variável de interesse):

```
svyttotal( ~factor( vd4002 ) , pnadc.mcp.calib.nps , na.rm = TRUE )
```

```
##                total      SE
## factor(vd4002)1 92976446 551092
## factor(vd4002)2 13453390 180267
```

Conclusão

## Conclusão

- ▶ Ignorar os pesos calibrados pode introduzir viés nas estimativas;
- ▶ Em geral, ignorar a calibração gera perda de eficiência nas estimativas;
- ▶ Embora o método de *Bootstrap* simplifique a implementação em outros softwares, usar o estimador de calibração com MCP com o pacote `survey` é bastante simples;

# Conclusão

- ▶ *Bootstrap* é computacionalmente intensivo;
  - ▶ Seu uso combinado com Imputação Múltipla (IM) pode ser proibitivo, por exemplo.
  - ▶ Já MCP e IM é uma abordagem viável.
- ▶ A estratégia “MCP+IM” permitiu aumentar a precisão das estimativas trimestrais da taxa de pobreza nas UFs de 2012-2021.

# Conclusão

Estimativas das Taxas de Pobreza, por estimador – UFs selecionadas, 2012/1–2021/4

Linha de Pobreza: US\$ 3,20 PPC 2011.

