Implementation on R

Methodologies and Data Science for Statistical Production

INE Chile

December 2022

Implementación en R

Implementation in R

Demostración (Demonstration)

Antes de comenzar...

Para seguir la demostración en tu computador, es necesario contar con un nivel básico de R

Si no sabes nada de R y quieres tener una idea general de la herramienta, no tendrás ningún problema

Es necesario tener un dominio muy básico de programación

Before starting...

If you want to follow the demonstration on your machine, a basic knowledge of R is required

If you don't have any idea about R and you just want to get an overview, it is totally fine.

Very basic programming skill is required

Demostración (Demonstration)

Lo primero, es descargar el paquete desde CRAN

The first step is to download the package from CRAN

```
install.packages("calidad")
```

... o versión en desarrollo desde github

... or developing version from github

```
devtools::install_github("inesscc/calidad")
```

Cargamos el paquete en la sesión y otras dependencias que usaremos

We load the package with other dependencies we will be using

```
library(calidad)
library(survey)
library(dplyr)
```

Demostración (Demonstration)

Trabajaremos con los datos de la Encuesta de Caracterización Socioeconómica (CASEN) 2020 (cargados en el paquete)

We will work with the National Socioeconomic Survey (CASEN) 2020 (already loaded into the package)

Construyamos algunas variables necesarias para calcular indicadores relevantes del mercado laboral

Let's create some relevant variables for the labor market

```
casen_edit <- casen %>%
  mutate(fdt = if_else(activ %in% c(1, 2), 1, 0, missing = 0), # fuerza de trabajo
         ocupado = if_else(activ == 1, 1, 0, missing = 0), # persona ocupada
         desocupado = if_else(activ == 2, 1, 0, missing = 0), # persona desocupada
         metro = if_else(region == 13, 1, 0))
```

Variables dummy

- fuerza de trabajo
- ocupado
- desocupado
- metro (pertenece a la región metropolitana)

Dummy variables

- labour force
- employed
- unemployed
- metropolitan area

Panorama general (Overview)

Declaramos el diseño complejo con la función `svydesign` de `survey`

We declare the complex design with the `svydesign` function from `survey`

```
dc <- svydesign(weights = ~expr, ids = ~cod_upm, strata = ~estrato, data = casen_edit )
options(survey.lonely.psu = "certainty")
```

Debemos decirle a `R` qué hacer con la varianza cuando encuentra estratos con una sola UPM

We must tell `R` what to do with the variance when it finds strata with only one PSU

Panorama general (overview)

El paquete `calidad` tiene 2 tipos de funciones:

- *create_*: **crean** los insumos para el estándar
- *assess*: **evaluación** del estándar

`calidad` has 2 types of functions

- *create_*: **to create** the quality indicators
- *assess*: **to assess** the quality according to some standard

Podemos hacer los siguientes cálculos

- media (create_mean)
- proporción o razón (create_prop)
- suma de variables continuas (create_total)
- conteo de unidades (create_size)

The following estimations can be obtained

- mean (create_mean)
- porportion or ratio (create_prop)
- totals (create_total)
- size (create_size)

Creando los insumos (getting the values)

Queremos calcular la edad media para mujeres y hombres

We want to get the mean age for women and men

```
create_mean(var = "edad", domains = "sexo", design = dc)
```

```
##   sexo     stat        se    df     n          cv
## 1    1 35.81776 0.1320879 10701 86096 0.003687776
## 2    2 38.88116 0.2030783 10818 99341 0.005223053
```

- `var`: variable a estimar
- `domains`: desagregaciones
- `design`: diseño muestral creado con `svydesign`

La función retorna:

- estimación (stat)
- error estándar (se)
- coeficiente de variación (CV)
- grados de libertad (df)
- tamaño muestral (n)

The function returns:

- estimation (stat)
- standard error (se)
- Coefficient of variation (CV)
- Degrees of freedom (df)
- Sample size (n)

Creando los insumos (getting the values)

¿Y si queremos calcular la tasa de desempleo?

Para ello, contamos con la función `create_prop`

```
create_prop(var = "desocupado", domains = "sexo", design = dc)
```

El problema es que el desempleo debe calcularse sobre una subpoblación específica (fuerza de trabajo)

Para ello, utilizamos el argumento `subpop`

```
create_prop(var = "desocupado", domains = "sexo", subpop = "fdt", design = dc)
```

No olvidar que **subpop debe ser dummy**

Con subpop evitamos error en el cálculo de la

And if we would like to get the unemployment rate?

We have the `create_prop` function

We have one issue here: the unemployment must be obtained from a specific subpopulation (labor force)

we can use the `subpop` parameter

Do not forget that **subpop must be a dummy variable**

The use of subpop avoids errors in variance

Creando los insumos (getting the values)

¿Qué pasa si queremos desagregar por más variables?

Se debe agregar otra variable utilizando un signo +

And what if we want to add more variables in domains?

That can be done using the "+" character

```
create_prop(var = "desocupado", domains = "sexo+metro", subpop = "fdt", design = dc)
```

```
##   sexo metro      stat          se   df     n         cv
## 1    1     0 0.1171641 0.002540917 7977 34097 0.02168682
## 2    2     0 0.1417696 0.003012865 7750 27786 0.02125184
## 3    1     1 0.1097366 0.004349727 2019  9901 0.03963790
## 4    2     1 0.1364608 0.008565356 1972  9055 0.06276788
```

Creando los insumos (getting the values)

Queremos calcular el número de ocupad**os** respecto al número de ocupad**as**

$$\frac{SumaOcupadosHombre}{SumaOcupadasMujer}$$

We want to get the ratio between men employed and women employed

$$\frac{TotalEmployedMen}{TotalEmployedWomen}$$

Lo primero que debemos hacer es crear variables auxiliares

The first step is to create some new variables

```
casen_edit <- casen_edit %>%
  mutate(ocupado_hombre = if_else(sexo == 1, ocupado, 0),
         ocupada_mujer  = if_else(sexo == 2, ocupado, 0))
```

Volvemos a declarar el diseño para incluir las variables recién creadas

We have to declare the design again in order to include the new variables.

```
dc <- svydesign(weights = ~expr, ids = ~cod_upm, strata = ~estrato, data = casen_edit )
```

Creando los insumos (getting the values)

La función `create_prop` permite incluir el argumento `denominator`

`create_prop` includes the parameter `denominator`

```
create_prop(var = "ocupado_hombre", denominator = "ocupada_mujer",
            subpop = "fdt", design = dc)
```

```
##       stat           se    df     n         cv
## 1 1.186844 0.0001418034 10590 80839 0.01003344
```

Podemos incluir el parámetro `domains`, si queremos desagregar

We can include `domains`, if we need it.

```
create_prop(var = "ocupado_hombre", denominator = "ocupada_mujer",
            domains = "metro" , subpop = "fdt", design = dc)
```

```
##   metro     stat         se   df     n         cv
## 1     0 1.238095 0.01312396 8510 61883 0.01060013
## 2     1 1.127986 0.02073977 2080 18956 0.01838654
```

Argumentos adicionales (other parameters)

Solo hemos revisado `create_prop` y `create_mean`

Todas las funciones del paquete operan de manera similar

Existen más argumentos

- ci
- deff
- rel_error
- ...

We took a look at `create_prop` and `create_mean`

All the functions works in a similar way

There are more parameters

- ci
- deff
- rel_error
- ...

Evaluación calidad (quality assessment)

Hasta el momento solo hemos visto la generacion de insumos

¿Cómo podemos evaluar la calidad estadística?

So far we have only learned how to create the inputs

How can we assess the statistical quality?

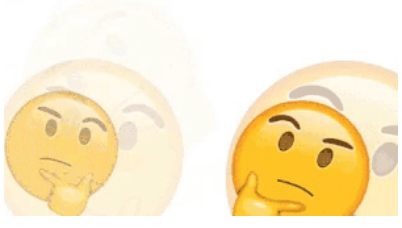

Evaluación de la calidad (quality assessment)

Evaluemos la calidad de la edad media, según sexo

Let's assess the quality for mean age by sex

```
est <- create_mean(var = "edad", domains = "sexo", design =  dc)
assess(est)
```

```
##   sexo     stat        se    df     n          cv                 eval_n       eval_df    eval_cv
## 1    1 35.81776 0.1320879 10701 86096 0.003687776 sufficient sample size sufficient df cv <= 0.15 re
## 2    2 38.88116 0.2030783 10818 99341 0.005223053 sufficient sample size sufficient df cv <= 0.15 re
```

Tenemos 4 columnas nuevas

- `eval_n`: indica si el tamaño muestral es sufciente
- `eval_df`: indica si los gl son suficientes
- `eval_cv`: indica el tramo en el que está el cv
- `label`: evaluación final de la estimación

We have 4 new columns

- `eval_n`: adequate sample size
- `eval_df`: adequate degrees of freedom
- `eval_cv`: adequate band for CV
- `label`: global assessment

Por defecto, las funciones de evaluación consideran el estándar ONE

- **Grados de libertad**: 9

By default the assessment function uses ONE Chile approach

- **Degrees of freedom**: 9

Evaluación de la calidad (quality assessment)

Veamos el caso de la tasa de desempleo

Let's move to the unemployment rate

```
est <-  create_prop(var = "desocupado", subpop = "fdt", domains = "sexo", design = dc)
assess(est)
```

```
##   sexo      stat          se   df     n         cv                 eval_n       eval_df prop_est eva
## 1    1 0.1138937 0.002402195 9996 43998 0.02109156 sufficient sample size sufficient df   <= 0.5   E
## 2    2 0.1393067 0.004271094 9722 36841 0.03065964 sufficient sample size sufficient df   <= 0.5   E
##    quadratic       eval_se eval_cv    label
## 1 0.02610701 admissible SE    <NA> reliable
## 2 0.02985879 admissible SE    <NA> reliable
```

La función agrega las siguientes columnas

The function adds the following columns

- `prop_est`
- `eval_type`
- `quadratic`
- `eval_se`
- `eval_cv`

Evaluación de la calidad (quality assessment)

El estándar establece que un tabulado puede ser publicado si el 50% de sus celdas es fiable

ONE Chile stands that a chart can be publish if 50% of its cells are reliable

Para saber si el tabulado debe ser publicado, usamos el argumento `publish`

To know if a chart can be published, we can use the `publish` parameter

```
est <-  create_size(var = "desocupado", subpop = "fdt", domains = "region+sexo", design = dc)
assess(est, publish = T) %>%
  select(region, sexo, stat, label, publication, pass) %>%
  slice(1:4)
```

```
##   region sexo  stat    label publication                    pass
## 1      1    1  9436 reliable     publish 100% reliable estimates
## 2      2    1 21139 reliable     publish 100% reliable estimates
## 3      3    1  8586 reliable     publish 100% reliable estimates
## 4      4    1 22801 reliable     publish 100% reliable estimates
```

Tenemos 2 nuevas columnas

- `publication`: evaluación general del tabulado
- `pass`: porcentaje de celdas con categoría fiable

We have 2 new columns

- `publication`: global assessment for a chart
- `pass`: percent cells with reliable label

Evaluación de la calidad (quality assessment)

Podemos generar una visualización sencilla mediante la función `create_html`

We can get a simple visualization using `create_html`

```
create_size(var = "desocupado", subpop = "fdt", domains = "region+sexo+pobreza", design = dc) %>%
  assess( publish = T) %>%
  slice(1:3) %>%
  create_html( )
```

region	sexo	pobreza	stat	se	df	n	cv	eval_n	eval_df	eval_cv	label	publication	pass
1	1	1	1.075	236,75	20	27	0,22	insufficient sample size	sufficient df	cv between 0.15 and 0.3	non-reliable	do not publish	38.54% reliable estimates
2	1	1	1.633	444,91	13	20	0,27	insufficient sample size	sufficient df	cv between 0.15 and 0.3	non-reliable	do not publish	38.54% reliable estimates
3	1	1	632	185,09	9	15	0,29	insufficient sample size	sufficient df	cv between 0.15 and 0.3	non-reliable	do not publish	38.54% reliable estimates

Estándar de calidad CEPAL

ECLAC criteria

Estándar de calidad CEPAL (CEPAL approach)

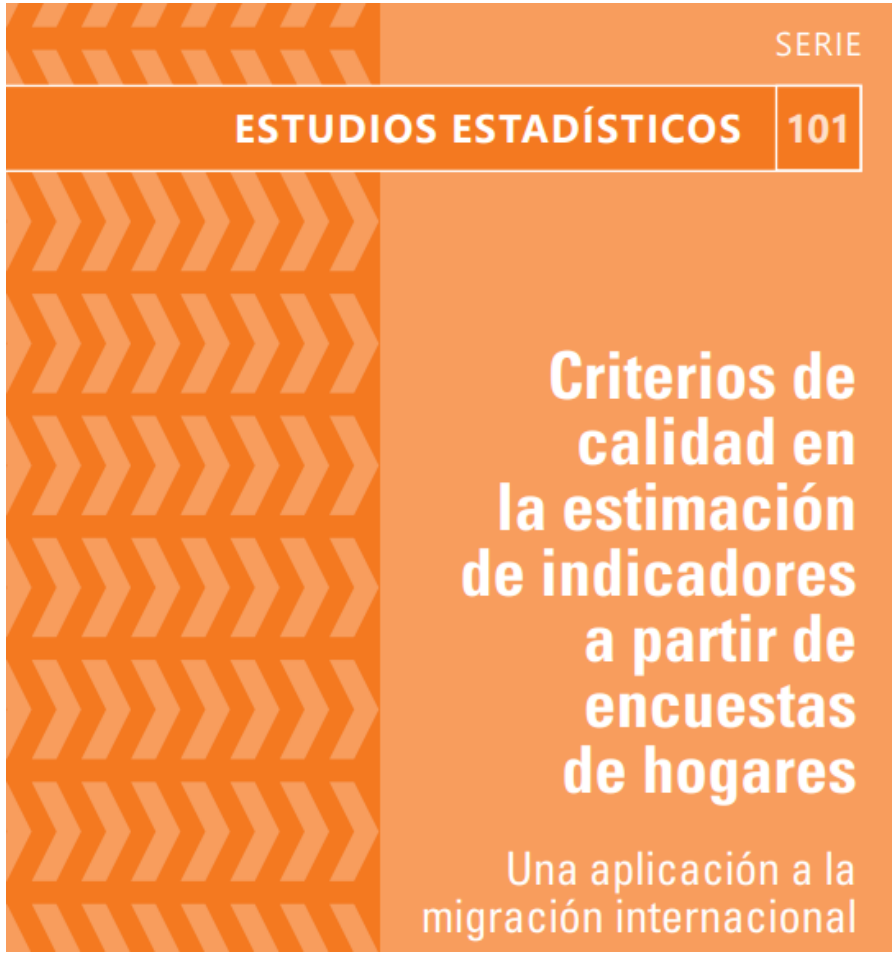

Estándar de calidad CEPAL (CEPAL approach)

- **El estándar CEPAL considera:**
  - coeficiente de variación
  - coeficiente de variación logarítmico
  - tamaño de muestra
  - tamaño de muestra efectivo
  - conteo de casos no ponderado
  - grados de libertad

¡Veamos un poco de código!

- **El estándar CEPAL considera:**
  - coefficient of variation
  - logarithmic coefficient of variation
  - sample size
  - effective sample size
  - non-weighted units
  - degrees of freedom

Let's see some code!

Estándar de calidad CEPAL (CEPAL approach)

Se deben incluir nuevos parámetros en las funciones `create_`

New parameters must be included in `create_`

```
est <- create_size(var = "desocupado", domains = "region+sexo", design = dc,
                   unweighted = T, deff = T, ess = T, df_type = "eclac")
```

Y agregar eclac en scheme

We have to add eclac in scheme

```
assess(est, scheme = "eclac") %>%
  select(region, sexo, stat, n, df, cv, unweighted, ess, label) %>%
  slice(1:6)
```

```
##   region sexo  stat    n   df         cv unweighted      ess   label
## 1      1    1  9436 3981  419 0.08412127        220 2545.121 publish
## 2      2    1 21139 3572  493 0.08197950        243 2130.673 publish
## 3      3    1  8586 3468  557 0.08745271        205 2076.391 publish
## 4      4    1 22801 3783  495 0.08145155        238 2402.469 publish
## 5      5    1 56607 8397 1119 0.06976443        511 2987.021 publish
## 6      6    1 24507 5830  611 0.07226518        327 3470.302 publish
```

Estándar de calidad CEPAL (CEPAL approach)

Contamos con un atajo para retornar los indicadores de CEPAL

We can take a shortcut for eclac indicators

```
est <- create_size(var = "desocupado", domains = "region+sexo",
                   design = dc, df_type = "eclac", eclac_input = TRUE)
```

Umbrales flexibles (flexible thresholds)

¿Y si necesito fijar mis propios umbrales?

What if I need to set my own thresholds?

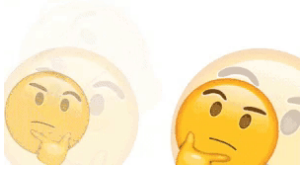

```
est <- create_size(var = "desocupado", domains = "region+sexo", design = dc,
                   unweighted = T, deff = T, ess = T, df_type = "ine")

assess(est, scheme = "eclac", unweighted = 220, ess = 200) %>%
  select(region, sexo, stat, n, df, cv, unweighted, ess, label) %>%
  slice(1:6)
```

```
##   region sexo  stat   n  df         cv unweighted      ess   label
## 1      1    1  9436 220 144 0.08412127        220 140.6497 supress
## 2      2    1 21139 243 167 0.08197950        243 144.9478 supress
## 3      3    1  8586 205 138 0.08745271        205 122.7394 supress
## 4      4    1 22801 238 146 0.08145155        238 151.1466 supress
## 5      5    1 56607 511 322 0.06976443        511 181.7754 supress
## 6      6    1 24507 327 175 0.07226518        327 194.6464 supress
```

Utilización de loops (loops)

Queremos calcular la media para varias variables

En este caso, queremos la media de `edad` y `ing_aut_hog`, según sexo

We want to get the mean for many variables

In this case, we want to get the mean for age and household_income by sex

```
insumos <- data.frame()
for (v in c("edad", "ing_aut_hog")) {
  insumo <- create_mean(var = v, domains = "sexo", design = dc, rm.na = T )
  insumos <- bind_rows(insumos, insumo)
}
```

Podemos hacer lo mismo, utilizando el paquete `purrr` (mucho más recomendado que un for)

We can do exactly the same using a functional approach from `purrr` package (much better option than for loop)

```
insumos <- map_df(c("edad", "ing_aut_hog"), ~create_mean(var = .x, domains = "sexo",
                                                         design = dc, rm.na = T ))
```

Funciones (functions)

El paquete `survey` funciona con evaluaciones no estándar

Esto es muy útil porque permite una sintaxis compacta, pero requiere que el usuario conozca un poco el funcionamiento de R

`survey` package works with Non Standard Evaluations (NSE)

This is very useful because it allows for a compact syntax, but requires the user to know about how R works

```
svyby(~edad, design = dc, by = ~sexo, FUN = svymean)
```

Veamos cómo crear una función con el paquete `calidad`

Let's see how to create a function using `calidad`

```
create_and_assess <- function(var, dom, dc) {
  create_mean(var, domains = dom, design = dc ) %>%
    assess() %>%
    select(dom, stat, n, df)
}
create_and_assess("edad", "sexo", dc)
```

```
##   sexo     stat     n    df
## 1    1 35.81776 86096 10701
## 2    2 38.88116 99341 10818
```

¿En qué estamos? (What are we doing now?)

- Mantenimiento constante
- Junto a CEPAL estamos preparando instancias de difusión:
  - RTC
  - UNSD (aquí estamos)
- Preparación de material de difusión
- Integración de `calidad` con `inedata`
- Comienzo de nuevos desarrollos

- Constant maintenance
- Together with ECLAC we are preparing dissemination instances:
  - PSTN
  - UNSD (here we are)
- Preparation of dissemination material
- Integration of `calidad` with `inedata`
- Start of new developments

Desarrollo open source

Open source development

El paquete `calidad` es un desarrollo completamente *open source*

En este repositorio de github pueden proponer nuevos desarrollos

Klaus Lehmann y Ricardo Pizarro son los mantenedores

Pueden generar *issues* o nuevas ramas de desarrollo

The `calidad` package is a completely *open source* development

In this github repository you can propose new developments

The maintainers are Klaus Lehmann y Ricardo Pizarro

You can create issues or new dev branches

Desarrollo open source

Open source development

Si tienen **propuestas de mejora, reportes de errores o nuevos desarrollos**, estaremos felices de revisarlo e incorporarlo al paquete

If you have **improvement proposals, bug reports or new developments**, we will be happy to review it and incorporate it into the package

😄 😄 😄 😄 😄

- Klaus Lehmann: kilehmannm@ine.gob.cl
- Ignacio Agloni: ifaglonij@ine.gob.cl
- Ricardo Pizarro: rapizarros@ine.gob.cl

https://github.com/inesscc/calidad

Implementation on R

Methodologies and Data Science for Statistical Production

INE Chile

December 2022