

Control 1, respuestas

Web Scraping y acceso a datos
desde la web

Cristián Ayala

Ponderación: 20% de la nota final del curso

1 Tareas:

1.1 Identificar selectores

- 1) Desde la página web <https://www.scrapethissite.com/pages/simple/> a capturar, identificar el nombre de la clase de css para:

La clase de cada uno de estos elementos son:

- Nombre de país: `country-name`
- Nombre de capital: `country-capital`
- Población: `country-population`
- Superficie: `country-area`

1.2 Captura de datos

- 2) Capturar la información de todos los países para pasarla a una data.frame.

```
url <- 'https://www.scrapethissite.com/pages/simple/'  
html <- read_html(url)  
  
# Listado con los 4 selectores de interés.  
l_css_selectors <- c('pais'      = '.country-name',  
                      'capital'    = '.country-capital',  
                      'poblacion'  = '.country-population',  
                      'superficie' = '.country-area')  
  
# Extraigo los datos correspondientes para cada selector.  
l_paises <- map(l_css_selectors,  
                  \css_sel {  
                    html_elements(html, css_sel) |>
```

```

        html_text() |>
        str_squish()
    })

df_paises <- as_tibble(l_paises) # Convierbo la lista a tibble.

# Corrijo el tipo de variable de las variables capturadas.
df_paises <- readr::type_convert(df_paises)

head(df_paises)

```

	pais	capital	poblacion	superficie
	<chr>	<chr>	<dbl>	<dbl>
1	Andorra	Andorra la Vella	84000	468
2	United Arab Emirates	Abu Dhabi	4975593	82880
3	Afghanistan	Kabul	29121286	647500
4	Antigua and Barbuda	St. John's	86754	443
5	Anguilla	The Valley	13254	102
6	Albania	Tirana	2986952	28748

1.3 Listado de países ordenados según población

- 3) Listar los nombres de países desde el con menor población al con mayor población.

```

# Usando dplyr
df_paises |>
  arrange(poblacion) |>
  pull(pais) |>
  head(10)

```

```

[1] "Antarctica"
[2] "Bouvet Island"
[3] "Heard Island and McDonald Islands"
[4] "U.S. Minor Outlying Islands"
[5] "South Georgia and the South Sandwich Islands"
[6] "Pitcairn Islands"
[7] "French Southern Territories"
[8] "Cocos [Keeling] Islands"
[9] "Vatican City"
[10] "Tokelau"

```

```

# Usando R base
df_paises[order(df_paises$poblacion), 'pais', drop = TRUE] |>
  head(10)

```

```
[1] "Antarctica"
[2] "Bouvet Island"
[3] "Heard Island and McDonald Islands"
[4] "U.S. Minor Outlying Islands"
[5] "South Georgia and the South Sandwich Islands"
[6] "Pitcairn Islands"
[7] "French Southern Territories"
[8] "Cocos [Keeling] Islands"
[9] "Vatican City"
[10] "Tokelau"
```

1.4 Agregar variable continente

- 4) Agregar a la base de datos el dato continente para cada país según la base de datos `countryName_continents.csv` disponible en el repositorio.

```
df_continente <- read_csv('c_1_files/countryName_continents.csv',
                           col_types = cols(col_character())) # Asigno las variables como chr
sum(is.na(df_continente$continent))
```

```
[1] 41
```

41 países no tienen continente asignado en la base de continentes `df_continente`.

```
df_paises <- left_join(df_paises,
                        df_continente,
                        by = c('pais' = 'countryName'))

table(df_paises$continent, useNA = 'ifany')
```

	AF	AN	AS	EU	OC	SA	<NA>
	53	3	49	51	26	14	54

54 países en la base de población y superficie quedaron sin un continente asignado. Les daré un valor explícito: *sin dato*.

```
df_paises$continent <- fct_na_value_to_level(df_paises$continent, 'sin dato')
```

1.5 Graficar relación entre superficie y población

Excluyo países de la lista sin población

```

df_paises_habitados <- df_paises |>
  filter(poblacion > 0)

(n_paises_habitados <- nrow(df_paises_habitados))

```

[1] 246

- 5) Graficar la relación entre superficie (eje x) y población (eje y) coloreando cada país según el continente al que pertenezca según la base de datos `continente`.

El gráfico se muestra en Figura 1.

```

ggplot(df_paises_habitados,
       aes(x = superficie,
            y = poblacion,
            colour = continente)) +
  ggforce::geom_mark_ellipse(aes(fill = continente),
                             alpha = 0.1,
                             linetype = 0,
                             show.legend = FALSE) +
  geom_point() +
  scale_x_log10('log Superficie (miles de km2)',
                labels = ~scales::number(., scale = 0.001)) +
  scale_y_log10('log Población (miles)',
                labels = ~scales::number(., scale = 0.001)) +
  labs(title = 'Relación entre superficie y población por país',
       subtitle = str_glue('El gráfico muestra {n_paises_habitados} países'),
       caption = 'Web scraping y acceso a datos desde la web',
       colour = 'Continentes') +
  theme_minimal() +
  theme(axis.title.x = ggtext::element_markdown())

```

Relacion entre superficie y población por país

El gráfico muestra 246 países




Figura 1: Relación entre superficie y población