Dia 1. Introducción al R básico

¿Qué es R?

Principios de la investigación reproducible.

Tipos y estructuras de datos en R.

Universidad de Guadalajara, CUCSH–CUCBA
Viacheslav Shalisko 16–24.07.2019

Lenguaje R

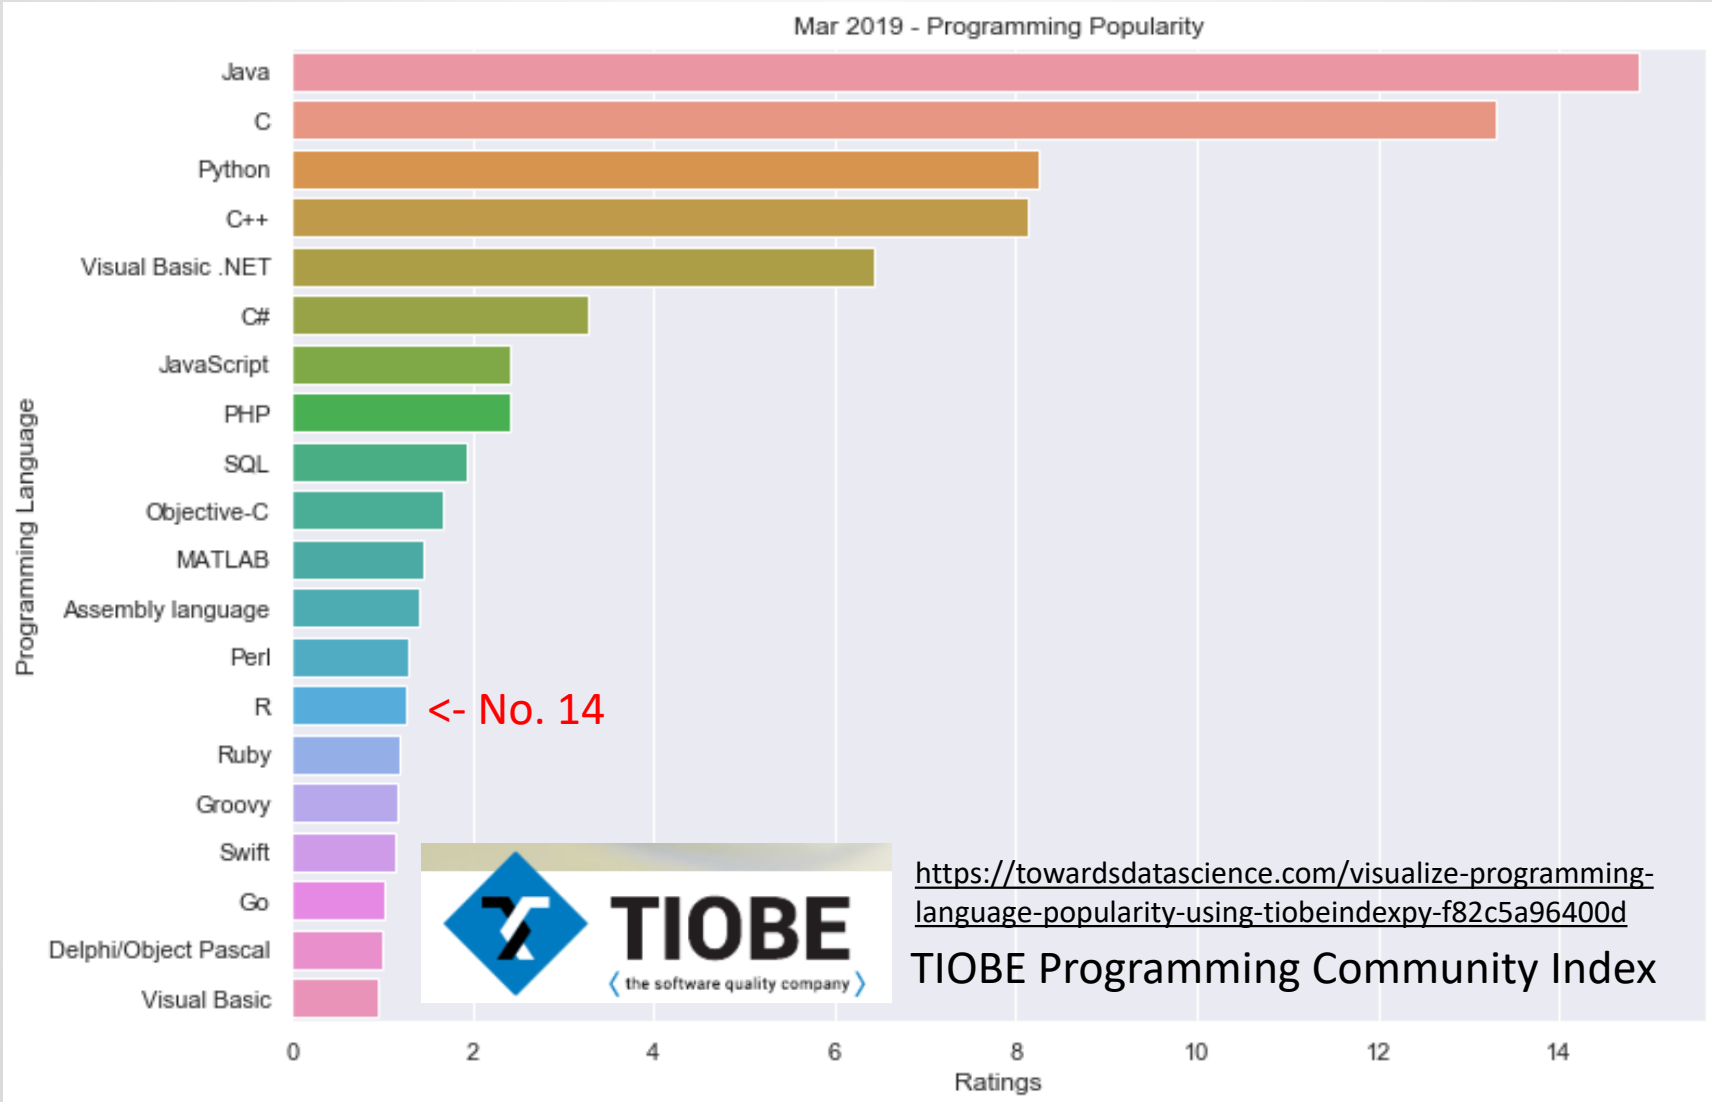

https://towardsdatascience.com/visualize-programming-language-popularity-using-tiobeindexpy-f82c5a96400d

TIOBE Programming Community Index

Lenguaje R

Número de posiciones laborales de “Data Science” en mayo del 2019

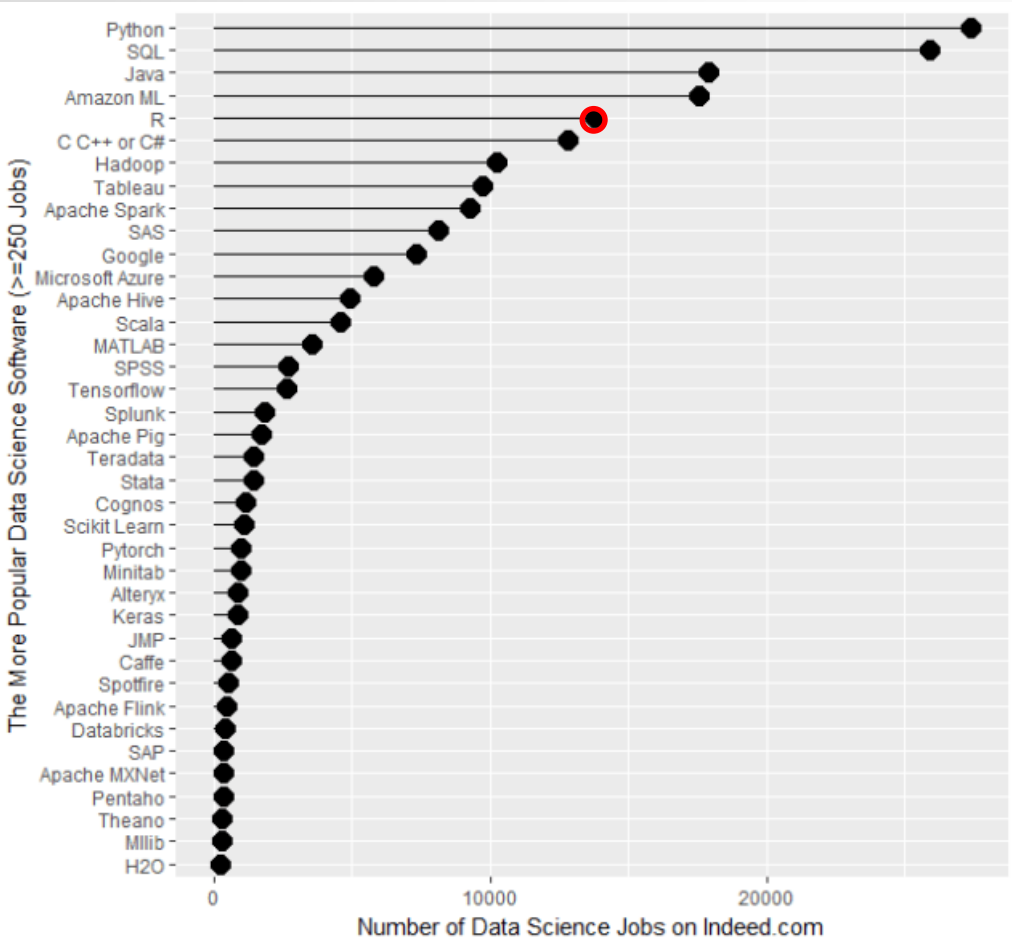

Número de citas en artículos en 2018 (Google Scholar)

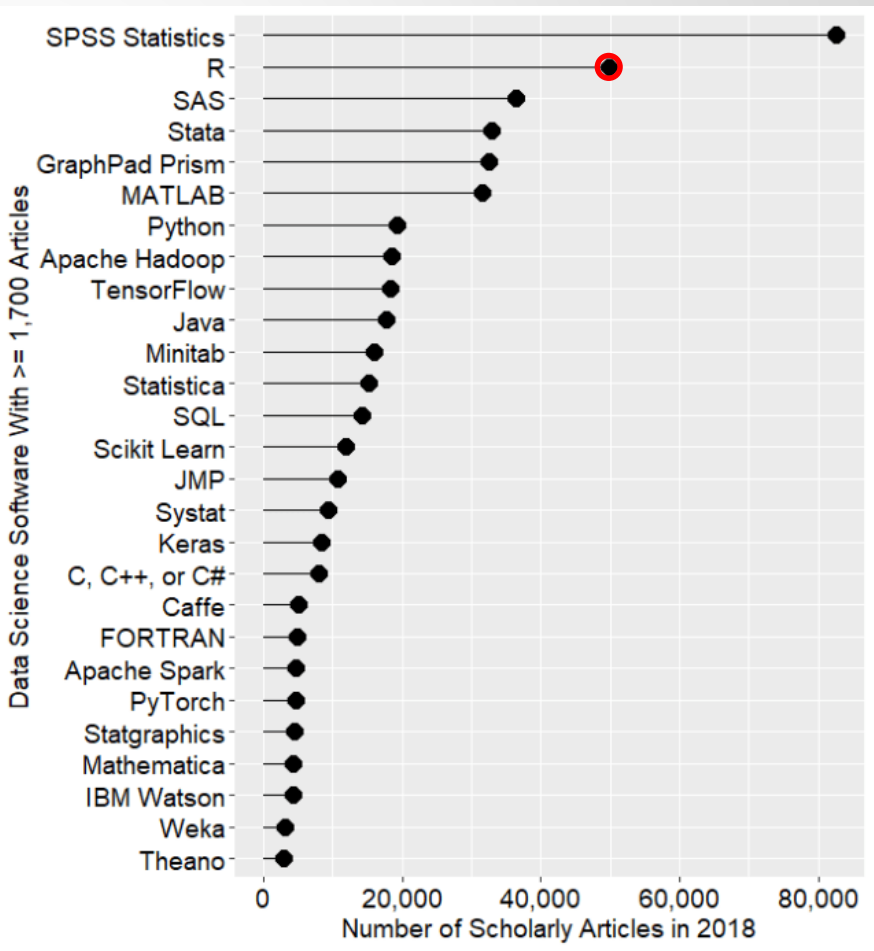

http://r4stats.com/articles/popularity/

Lenguaje R

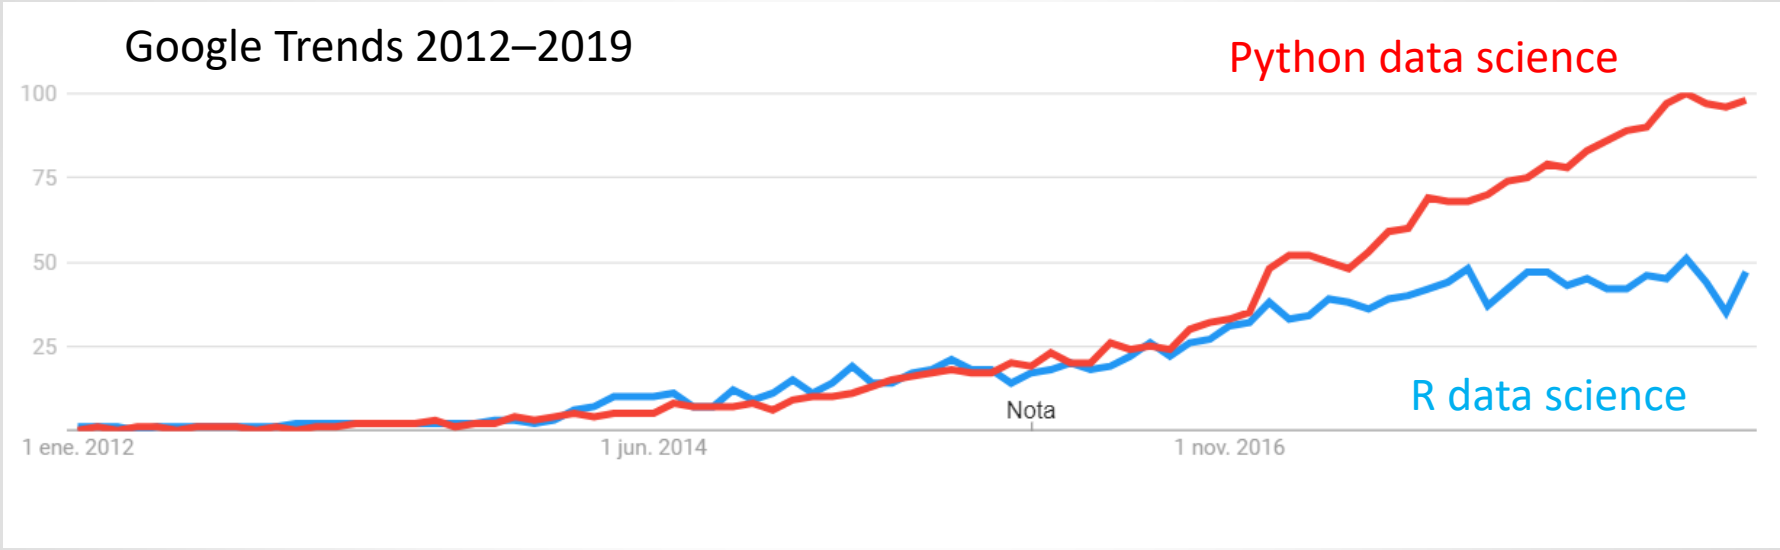
Google Trends 2012–2019
Python data science
R data science
100
75
50
25
Nota
1 ene. 2012
1 jun. 2014
1 nov. 2016

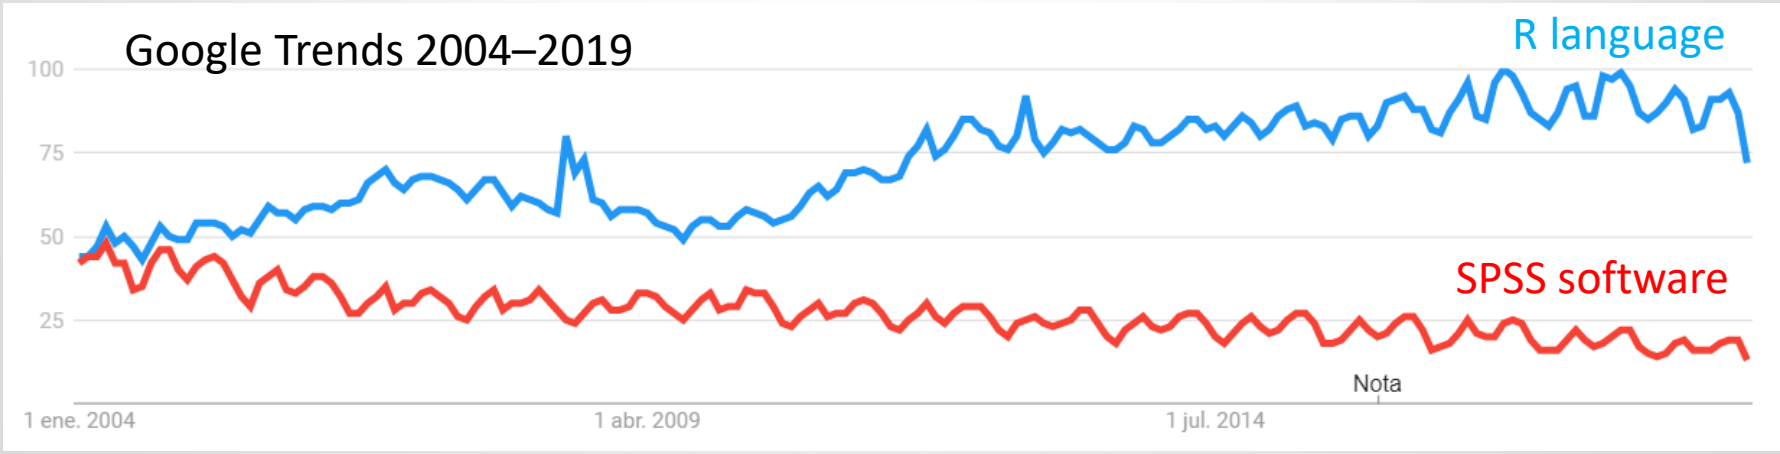
Google Trends 2004–2019
R language
SPSS software
100
75
50
25
Nota
1 ene. 2004
1 abr. 2009
1 jul. 2014

Lenguaje R

The R Project for Statistical Computing

https://www.r-project.org/

Algunas características del lenguaje de programación R

- **De código abierto** – licencia GNU General Public License (GPL), versión 2.
- **Interpretable** – programas no requieren compilación, pero requieren presencia del interpretador
- **Multiplataforma** – funciona en varias arquitecturas y OS, el interpretador pre-compilado existe para: Windows, MacOS, GNU/Linux/Unix (incl. Android)

- **Multiparadigma** – cuenta con soporte para programación con enfoque a proceduras, funciones y/o orientada a objetos

Lenguaje R

¿Cómo surgío R?

- Versión inicial fue ofrecida en 1993 por Ross Ihaka y Robert Gentleman como modificación del lenguaje S (Department of Statistics of the University of Auckland in Auckland, New Zealand)
- A partir del 1997 desarrollo por comunidad *R Core Team*

Image credit: Significance (Wiley), August 2018

Lenguaje R

Una de las fortalezas de R es su comunidad y subcultura

https://stats.stackexchange.com/

https://stackoverflow.com/

https://github.com/

https://www.rfordatasci.com/

https://www.datacamp.com/

Lectura:

Thieme, N. (2018) R generation. *Significance*, *15*(4), 15–18. DOI: 10.1111/j.1740-9713.2018.01169.x

Lenguaje R

¿Donde descargar R?

Repositorio oficial https://cran.r-project.org/

Catalogo *base*

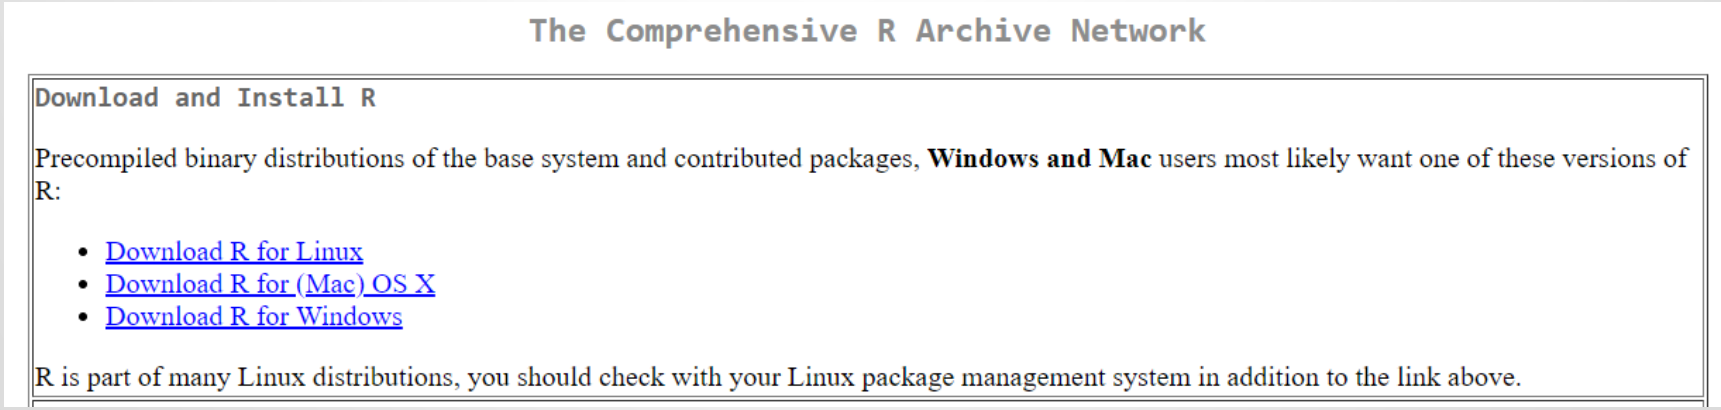

The Comprehensive R Archive Network

Download and Install R

Precompiled binary distributions of the base system and contributed packages, **Windows and Mac** users most likely want one of these versions of R:

- Download R for Linux
- Download R for (Mac) OS X
- Download R for Windows

R is part of many Linux distributions, you should check with your Linux package management system in addition to the link above.

Lenguaje R

¿Cómo actualizar la versión de R?

1. Descargar nueva versión de repositorio oficial https://cran.r-project.org/
2. Desinstalar la versión vieja de R
3. Instalar la nueva versión
4. Copiar las bibliotecas del usuario de la versión anterior a nueva (~\R\win64-library\x.y)
5. Actualizar las bibliotecas de usuario por medio de
   `update.packages(checkBuilt=TRUE, ask=FALSE)`

Nota: Se puede tener varias versiones de R instalados al mismo tiempo

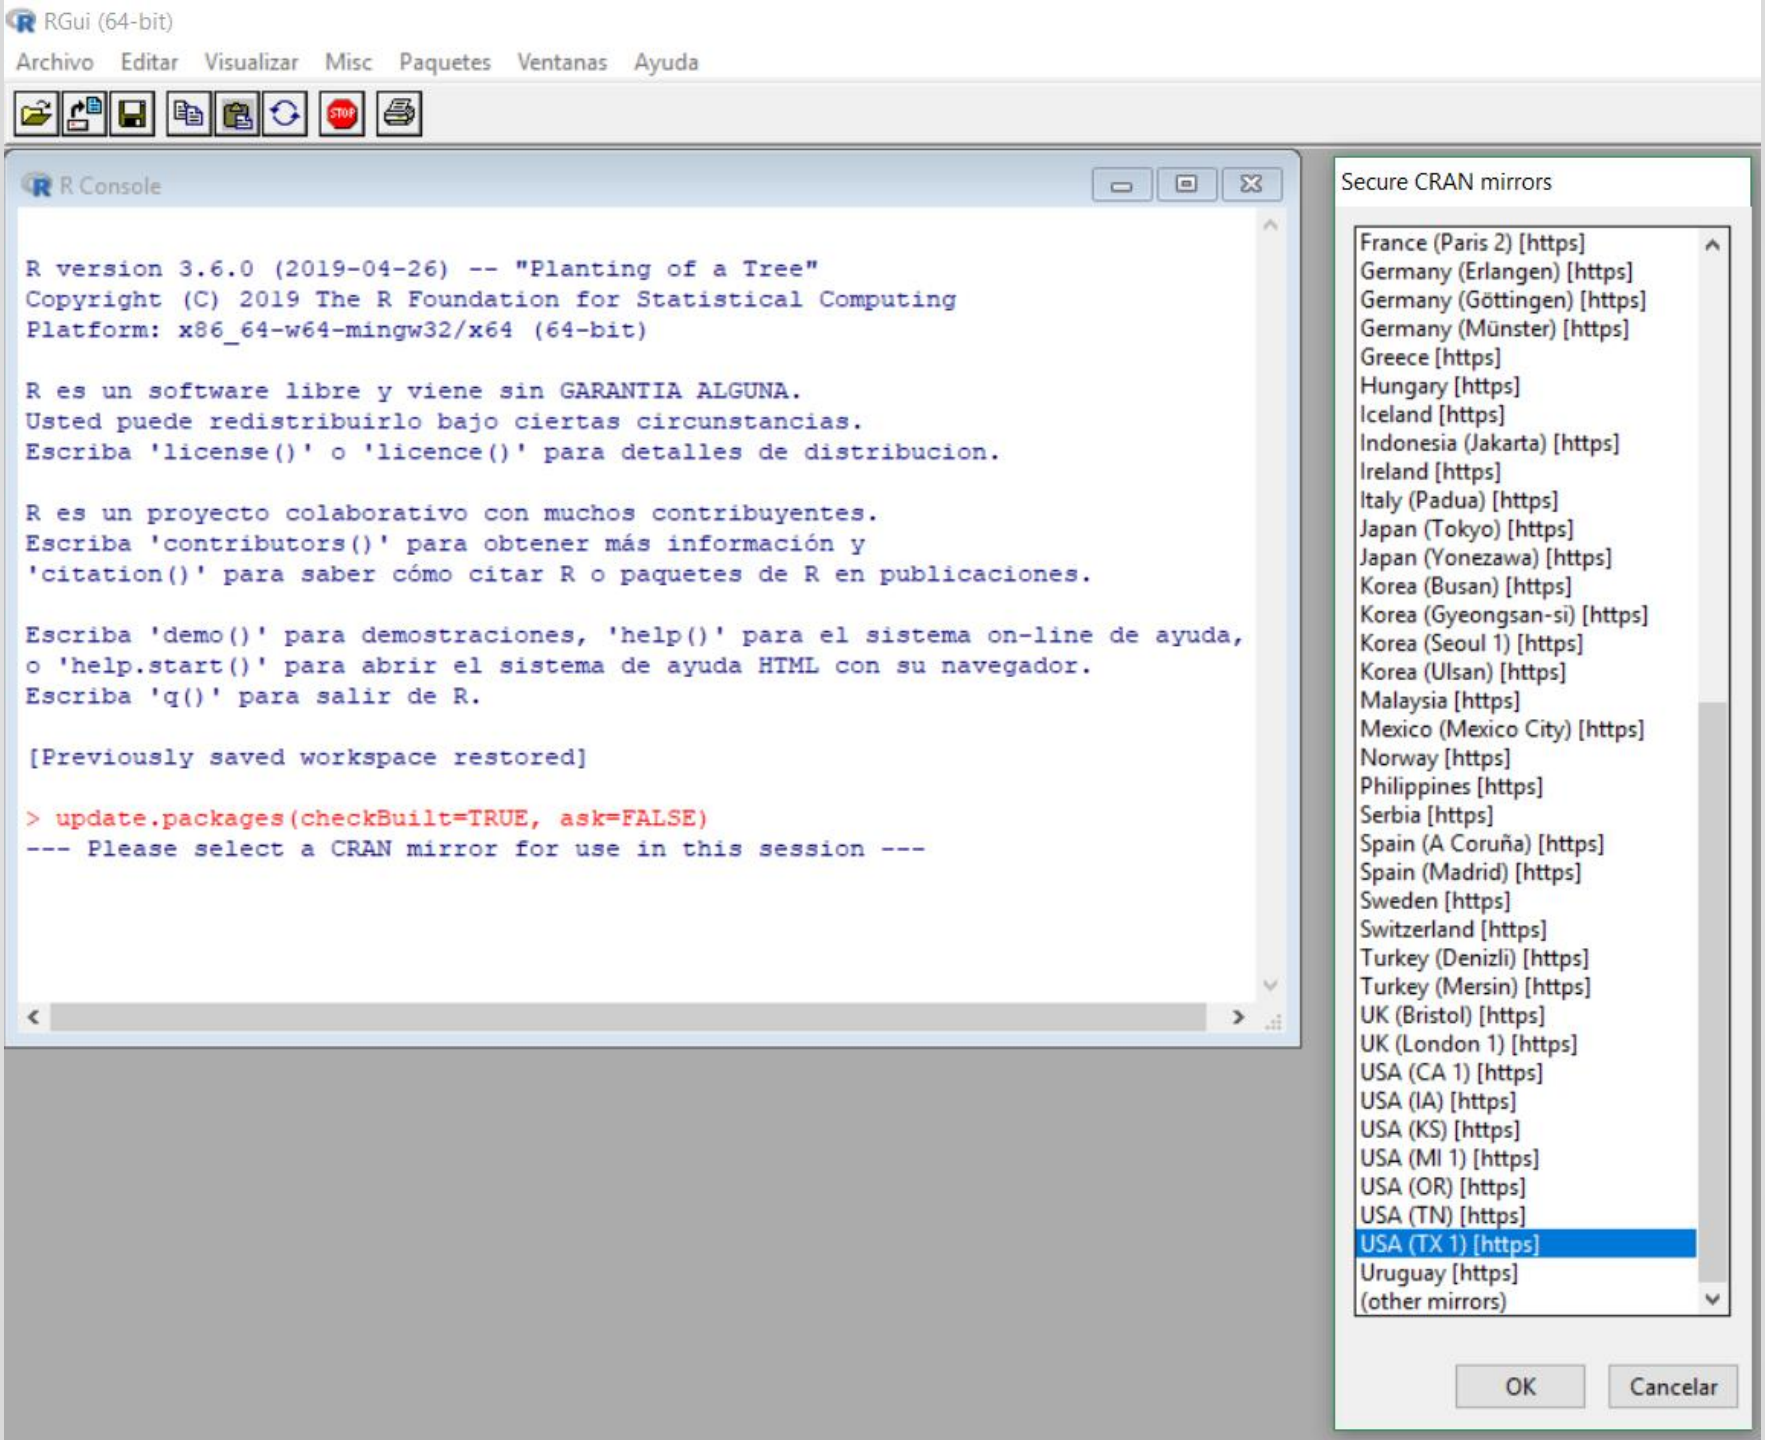
RGui (64-bit)
Archivo Editar Visualizar Misc Paquetes Ventanas Ayuda
R Console
R version 3.6.0 (2019-04-26) -- "Planting of a Tree"
Copyright (C) 2019 The R Foundation for Statistical Computing
Platform: x86_64-w64-mingw32/x64 (64-bit)
R es un software libre y viene sin GARANTIA ALGUNA.
Usted puede redistribuirlo bajo ciertas circunstancias.
Escriba 'license()' o 'licence()' para detalles de distribucion.
R es un proyecto colaborativo con muchos contribuyentes.
Escriba 'contributors()' para obtener más información y
'citation()' para saber cómo citar R o paquetes de R en publicaciones.
Escriba 'demo()' para demostraciones, 'help()' para el sistema on-line de ayuda,
o 'help.start()' para abrir el sistema de ayuda HTML con su navegador.
Escriba 'q()' para salir de R.
[Previously saved workspace restored]
> update.packages(checkBuilt=TRUE, ask=FALSE)
--- Please select a CRAN mirror for use in this session ---
Secure CRAN mirrors
France (Paris 2) [https]
Germany (Erlangen) [https]
Germany (Göttingen) [https]
Germany (Münster) [https]
Greece [https]
Hungary [https]
Iceland [https]
Indonesia (Jakarta) [https]
Ireland [https]
Italy (Padua) [https]
Japan (Tokyo) [https]
Japan (Yonezawa) [https]
Korea (Busan) [https]
Korea (Gyeongsan-si) [https]
Korea (Seoul 1) [https]
Korea (Ulsan) [https]
Malaysia [https]
Mexico (Mexico City) [https]
Norway [https]
Philippines [https]
Serbia [https]
Spain (A Coruña) [https]
Spain (Madrid) [https]
Sweden [https]
Switzerland [https]
Turkey (Denizli) [https]
Turkey (Mersin) [https]
UK (Bristol) [https]
UK (London 1) [https]
USA (CA 1) [https]
USA (IA) [https]
USA (KS) [https]
USA (MI 1) [https]
USA (OR) [https]
USA (TN) [https]
USA (TX 1) [https]
Uruguay [https]
(other mirrors)
OK
Cancelar

Lenguaje R

```
R.version.string
```

```
## [1] "R version 3.4.1 (2017-06-30)"
```

```
citation()
```

```
##
## To cite R in publications use:
##
##   R Core Team (2017). R: A language and environment for
##   statistical computing. R Foundation for Statistical Computing,
##   Vienna, Austria. URL https://www.R-project.org/.
##
## A BibTeX entry for LaTeX users is
##
##   @Manual{,
##     title = {R: A Language and Environment for Statistical Computing},
##     author = {{R Core Team}},
##     organization = {R Foundation for Statistical Computing},
##     address = {Vienna, Austria},
##     year = {2017},
##     url = {https://www.R-project.org/},
##   }
##
## We have invested a lot of time and effort in creating R, please
## cite it when using it for data analysis. See also
## 'citation("pkgname")' for citing R packages.
```

IDE RStudio

RStudio Decktop
Open Source Edition
Licencia AGPL v3

Integrated Development Environment (IDE)

¿Donde descargar RStudio?

https://www.rstudio.com/

RStudio incluye

- Editor de código
- Debugger y profiler
- Herramientas de visualización de resultados
- Documentación integrada
- Sistema visual de gestión de paquetes

IDE RStudio

Área de código

La consola y terminal

Visor de variables, historia, conexiones

Navegador de módulos, archivos, ayuda, visualizador de gráficos

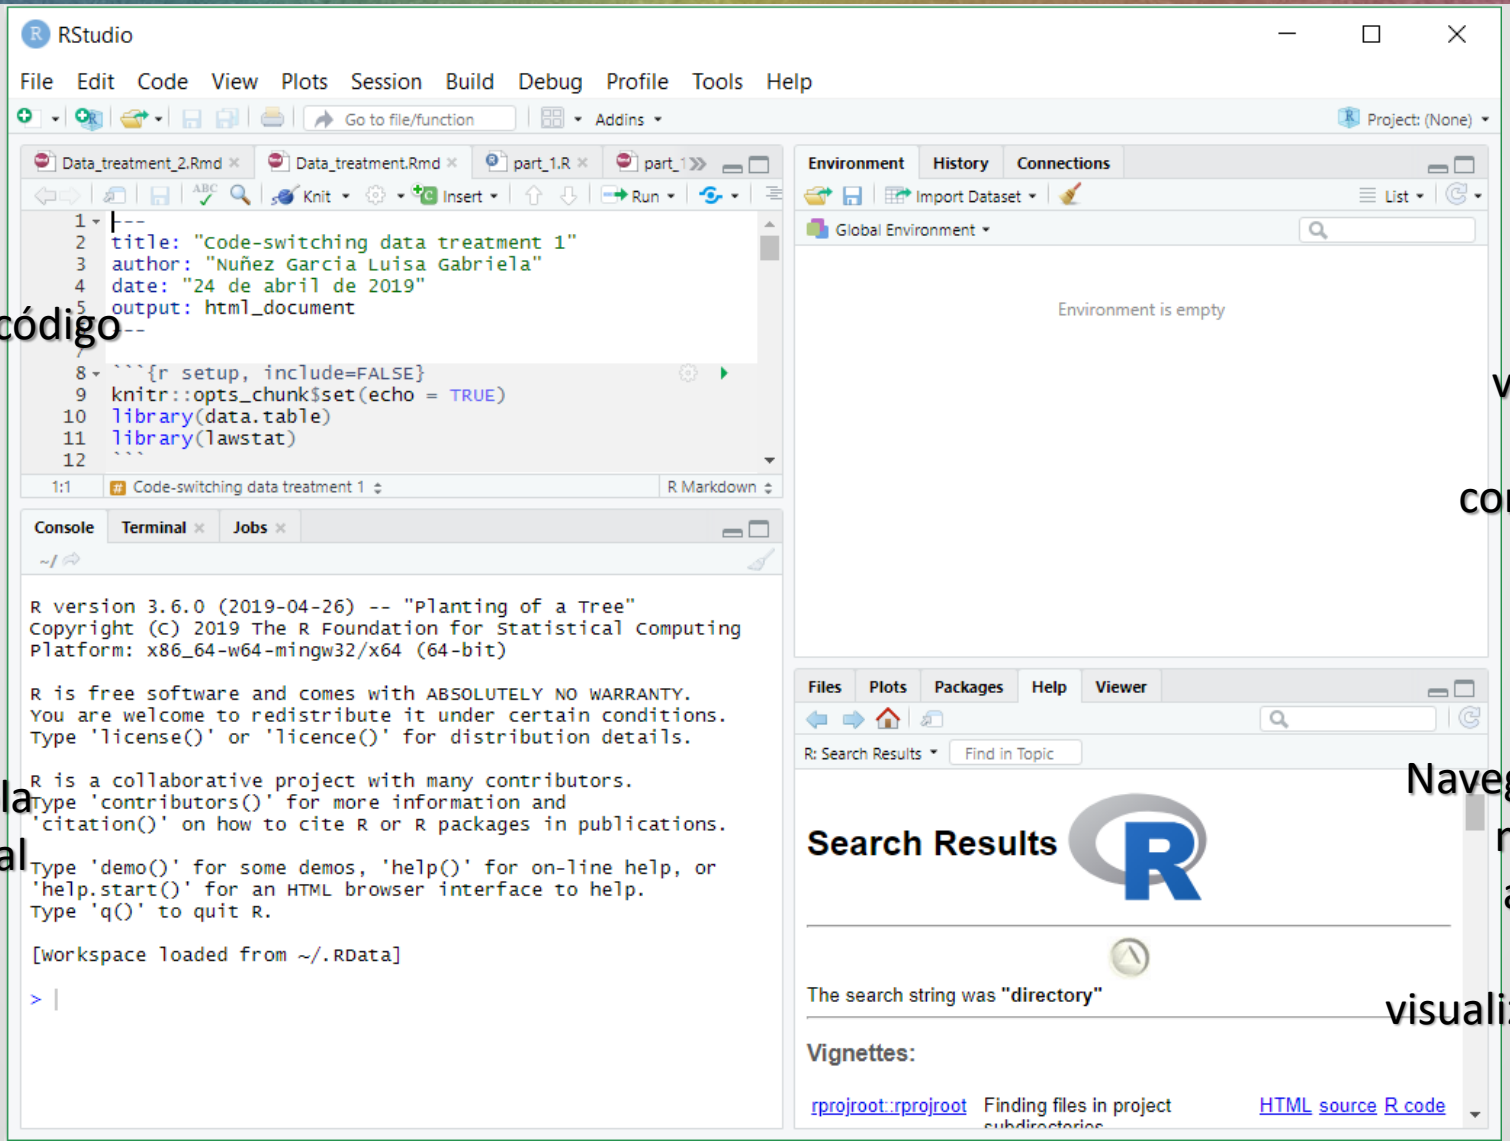

Lenguaje R

```
demo(graphics)
```

Algunos ejemplos:

```
demo(graphics)
demo(image)
```

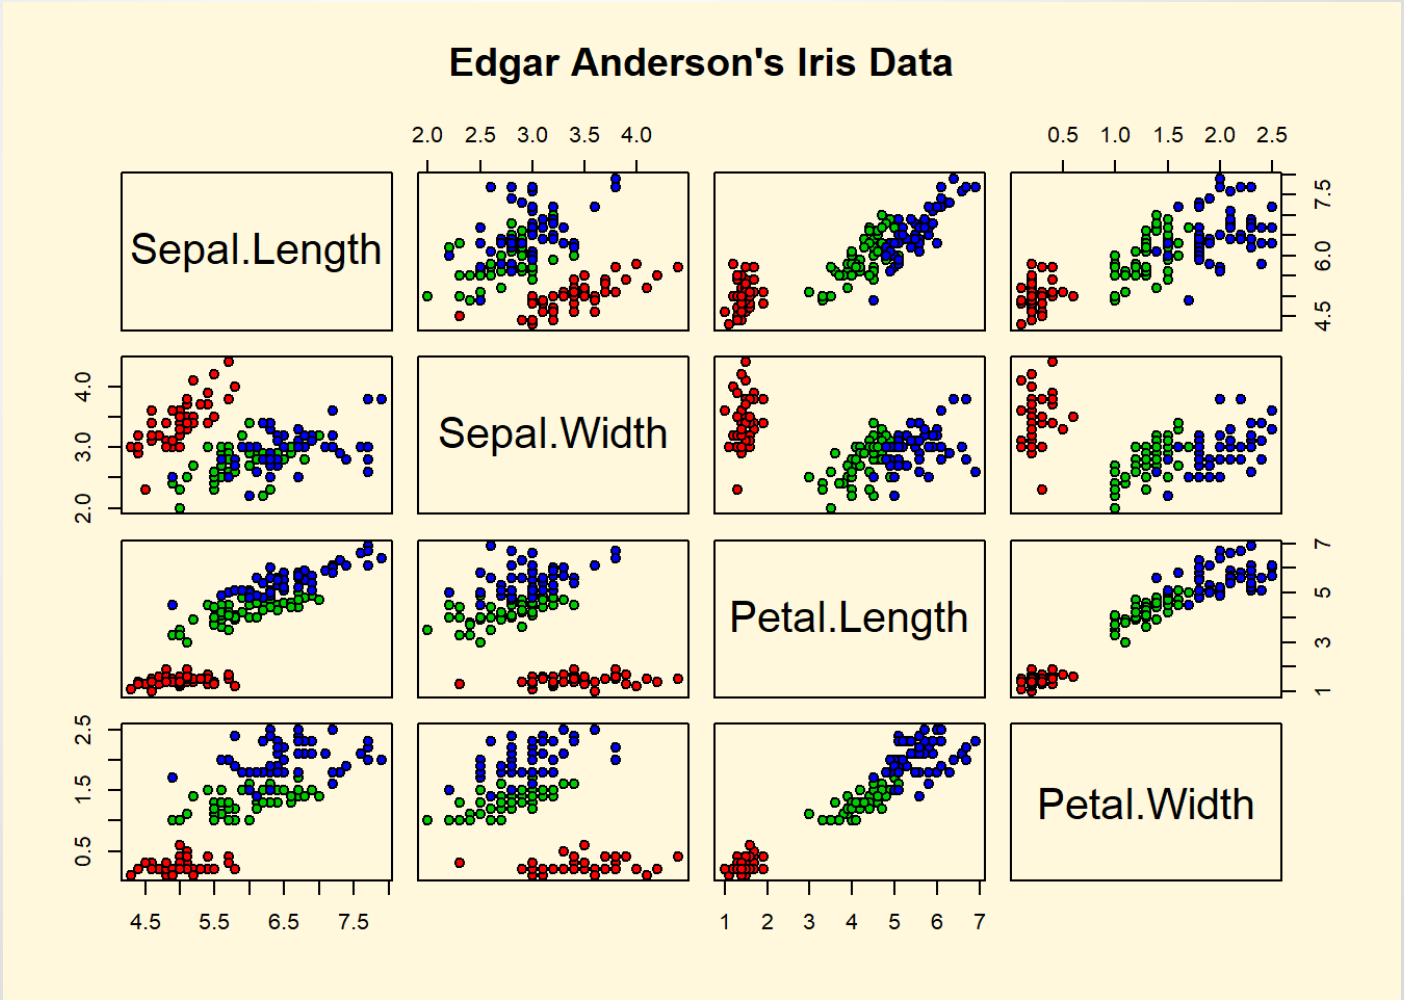

PROFACAD: Producto 1 para el portafolio

Producto para el portafolio: Producto 1.

Fecha de entrega del producto: 21 de julio 2019

Actividades: En forma individual revisar las fuentes bibliográficas recomendadas sobre el lenguaje R y redactar el texto del producto 1.

Producto para el portafolio: En el documento Google Docs realizar una síntesis sobre las características del lenguaje R, su organización, políticas de uso de código abierto y desarrollo por comunidad, texto en una cuartilla máximo.

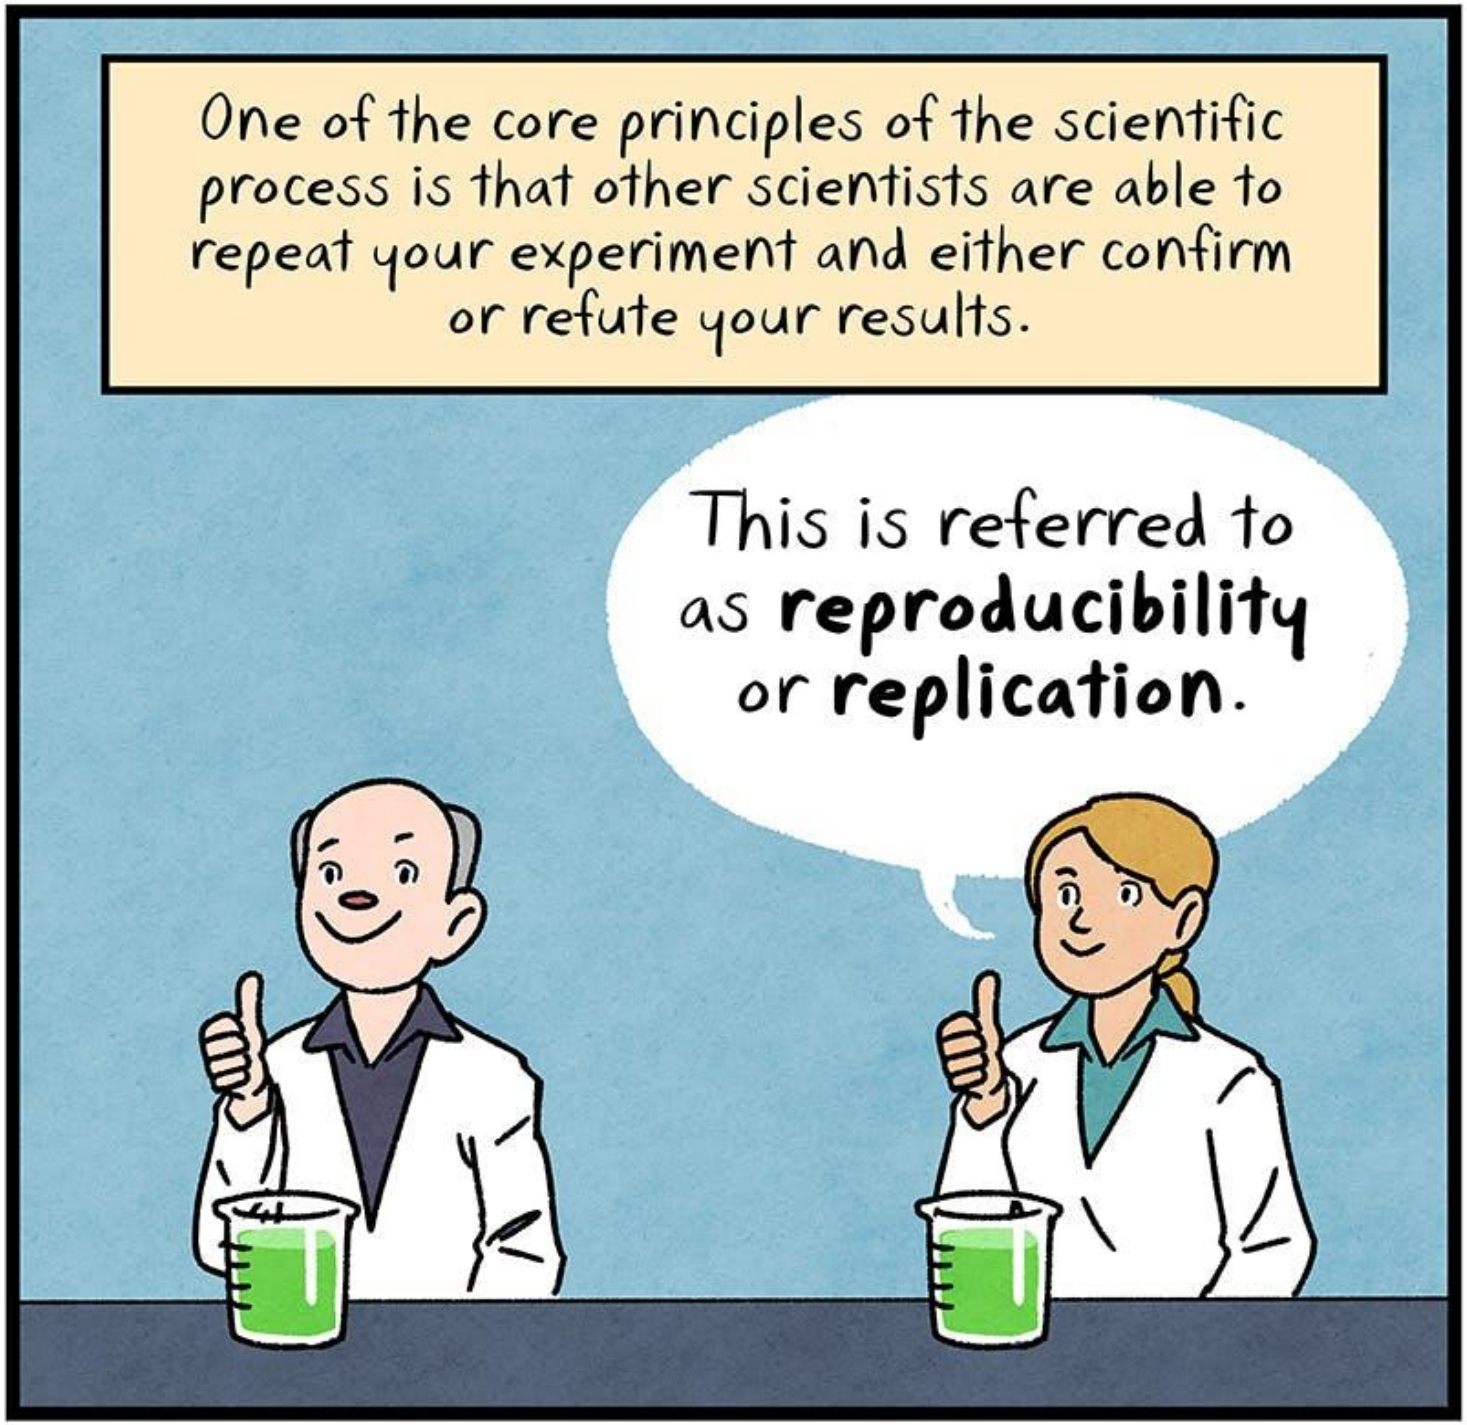

Investigación reproducible / repetible

WORLD VIEW · 24 MAY 2018

https://www.nature.com/articles/d41586-018-05256-0

Before reproducibility must come preproducibility

Instead of arguing about whether results hold up, let's push to provide enough information for others to repeat the experiments, says Philip Stark.

"Just as I have pledged not to review papers that are not preproducible, I have also pledged not to submit papers without providing the software I used, and — to the extent permitted by law and ethics — the underlying data. I urge you to do the same."

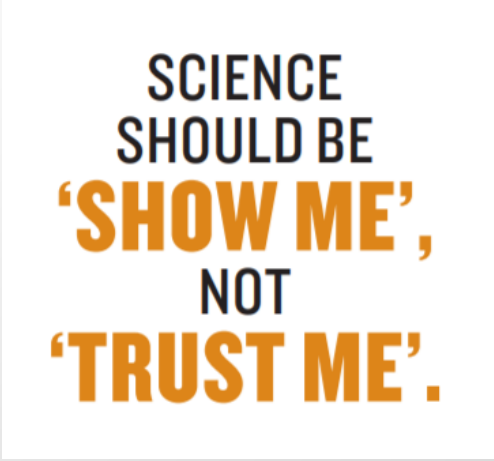

Investigación reproducible / repetible

Hacer *investigación reproducible* es poder permitir a ti mismo y a los demás repetir y obtener los mismos resultados de un trabajo científico.

Para esto es necesario que el producto de la investigación incluya:

- Publicación en forma de un artículo científico, un preprint o tesis, etc.
- Descripción completa de materiales y métodos
- Datos utilizados
- Código de cómputo utilizado
- Versión del software utilizado
- Cualquier otra información necesaria para repetir los experimentos y análisis

Inspirado por los materiales de Alicia Mastretta Yanes (UNAM, CONABIO http://mastrettayanes-lab.org/), curso “Introducción a la bioinformática reproducible para ecología y genética” impartido en CUCBA octubre 2016

Investigación reproducible / repetible

¿Reproducible para quién?

1. Quién hizo la investigación, 6 meses (o 6 días, o algunos años) después

   Evitar:

   - ¿Cómo, por Dios, era esto?
   - El archivo bueno es final.xlsx. No, espera, tal vez sea final_elbueno.xlsx, o final_3_revisado.xlsx. Deja reviso la última fecha de modificación. Hum....
   - Ahorita me acuerdo

   Ganar:

   - Volver a correr fácilmente los mismos datos con pequeñas modificaciones a los parámetros o datos de entrada
   - Reutilizar código o datos para nuevos análisis
   - Confianza en tus resultados

Inspirado por los materiales de Alicia Mastretta Yanes (UNAM, CONABIO http://mastrettayanes-lab.org/), curso “Introducción a la bioinformática reproducible para ecología y genética” impartido en CUCBA octubre 2016

Investigación reproducible / repetible

¿Reproducible para quién?

2. Tus colegas y asesor/a

   No temer escuchar:

   - ¿Me ayudas a hacer este análisis?
   - ¿Puedes explicarme como obtuviste esto?
   - ¿Puedes repetir esta gráfica agregando este dato nuevo?

3. La comunidad científica
   - Corroborar resultados
   - Construir sobre lo construido
   - Aportar al futuro de la Humanidad

Inspirado por los materiales de Alicia Mastretta Yanes (UNAM, CONABIO http://mastrettayanes-lab.org/), curso “Introducción a la bioinformática reproducible para ecología y genética” impartido en CUCBA octubre 2016

Investigación reproducible / repetible

Los “tips” prácticos para realizar la investigación y análisis de datos reproducibles (Gandrud 2015)

- Documenta todo
- Todo flujo de trabajo debe estar reflejado en los archivos de texto
- Todos archivos con análisis deben ser legibles por una persona
- Vincula los archivos de datos con el análisis de forma explicita
- Planifica desde principio como vas a organizar, almacenar y publicar tus archivos

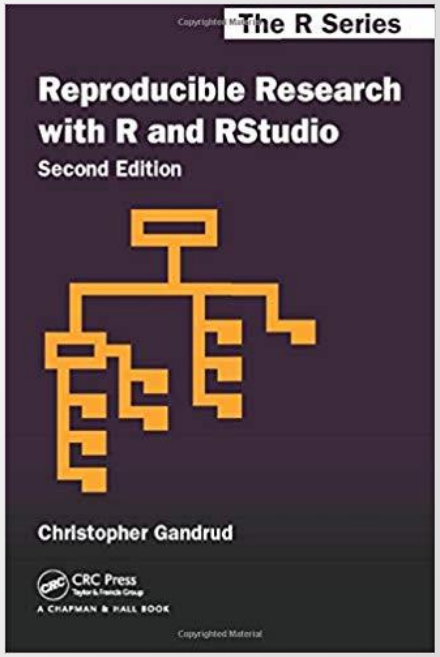

Investigación reproducible / repetible

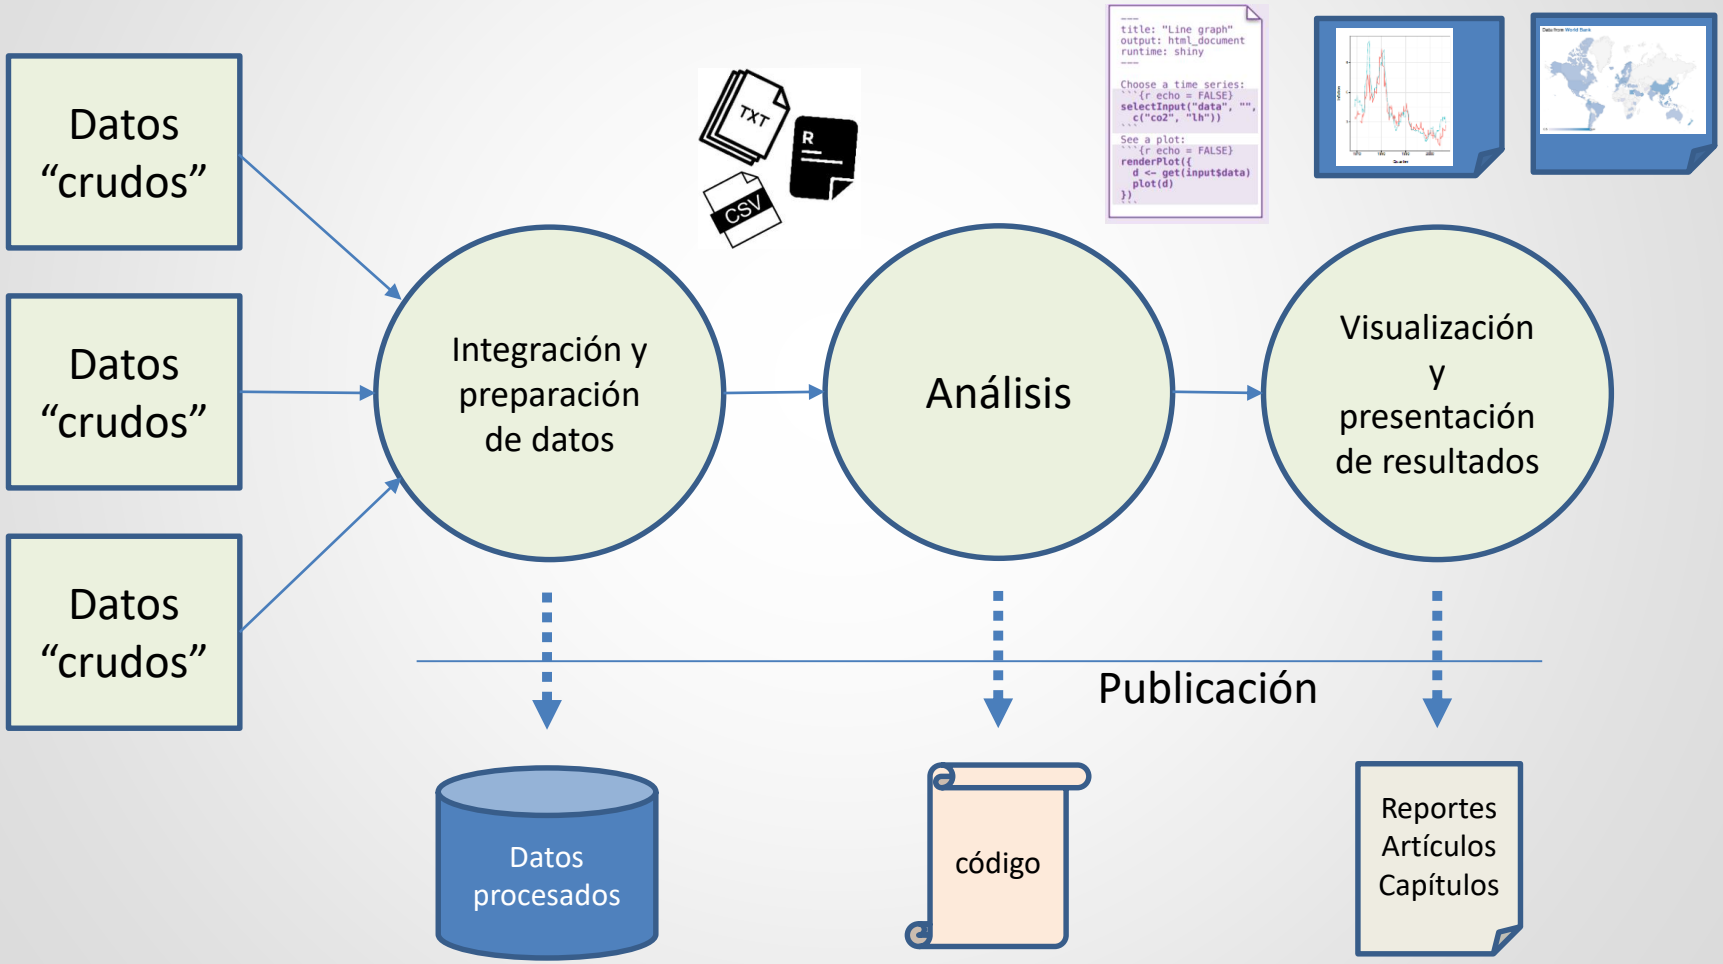

GigaScience integrates and publishes all research objects
to maximize reproducibility, transparency and reuse

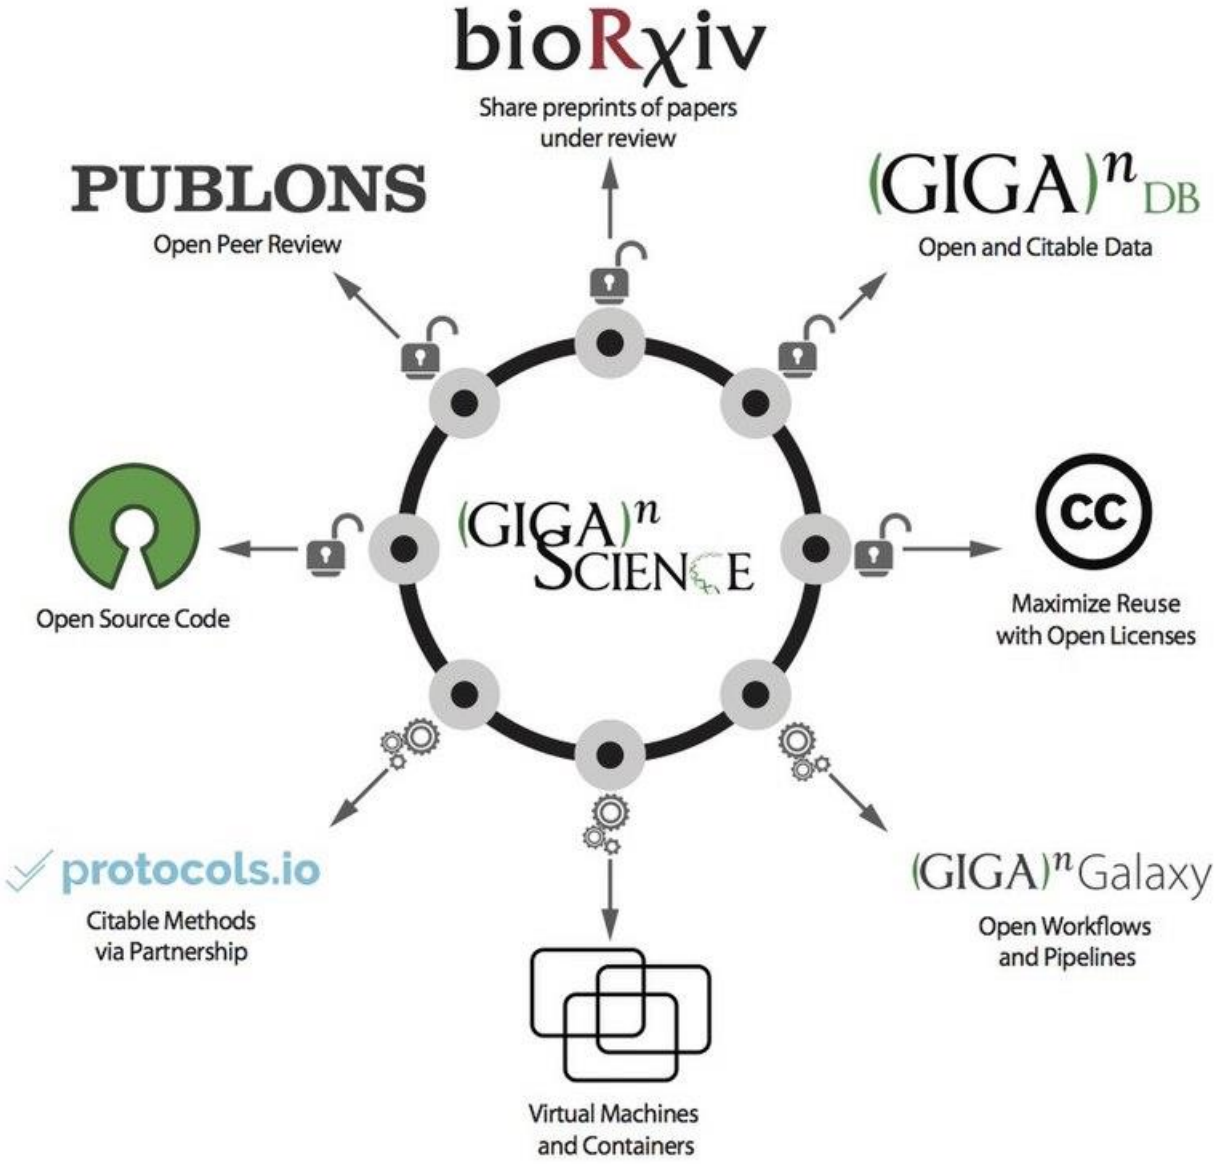

https://doi.org/10.1093/gigascience/gix064

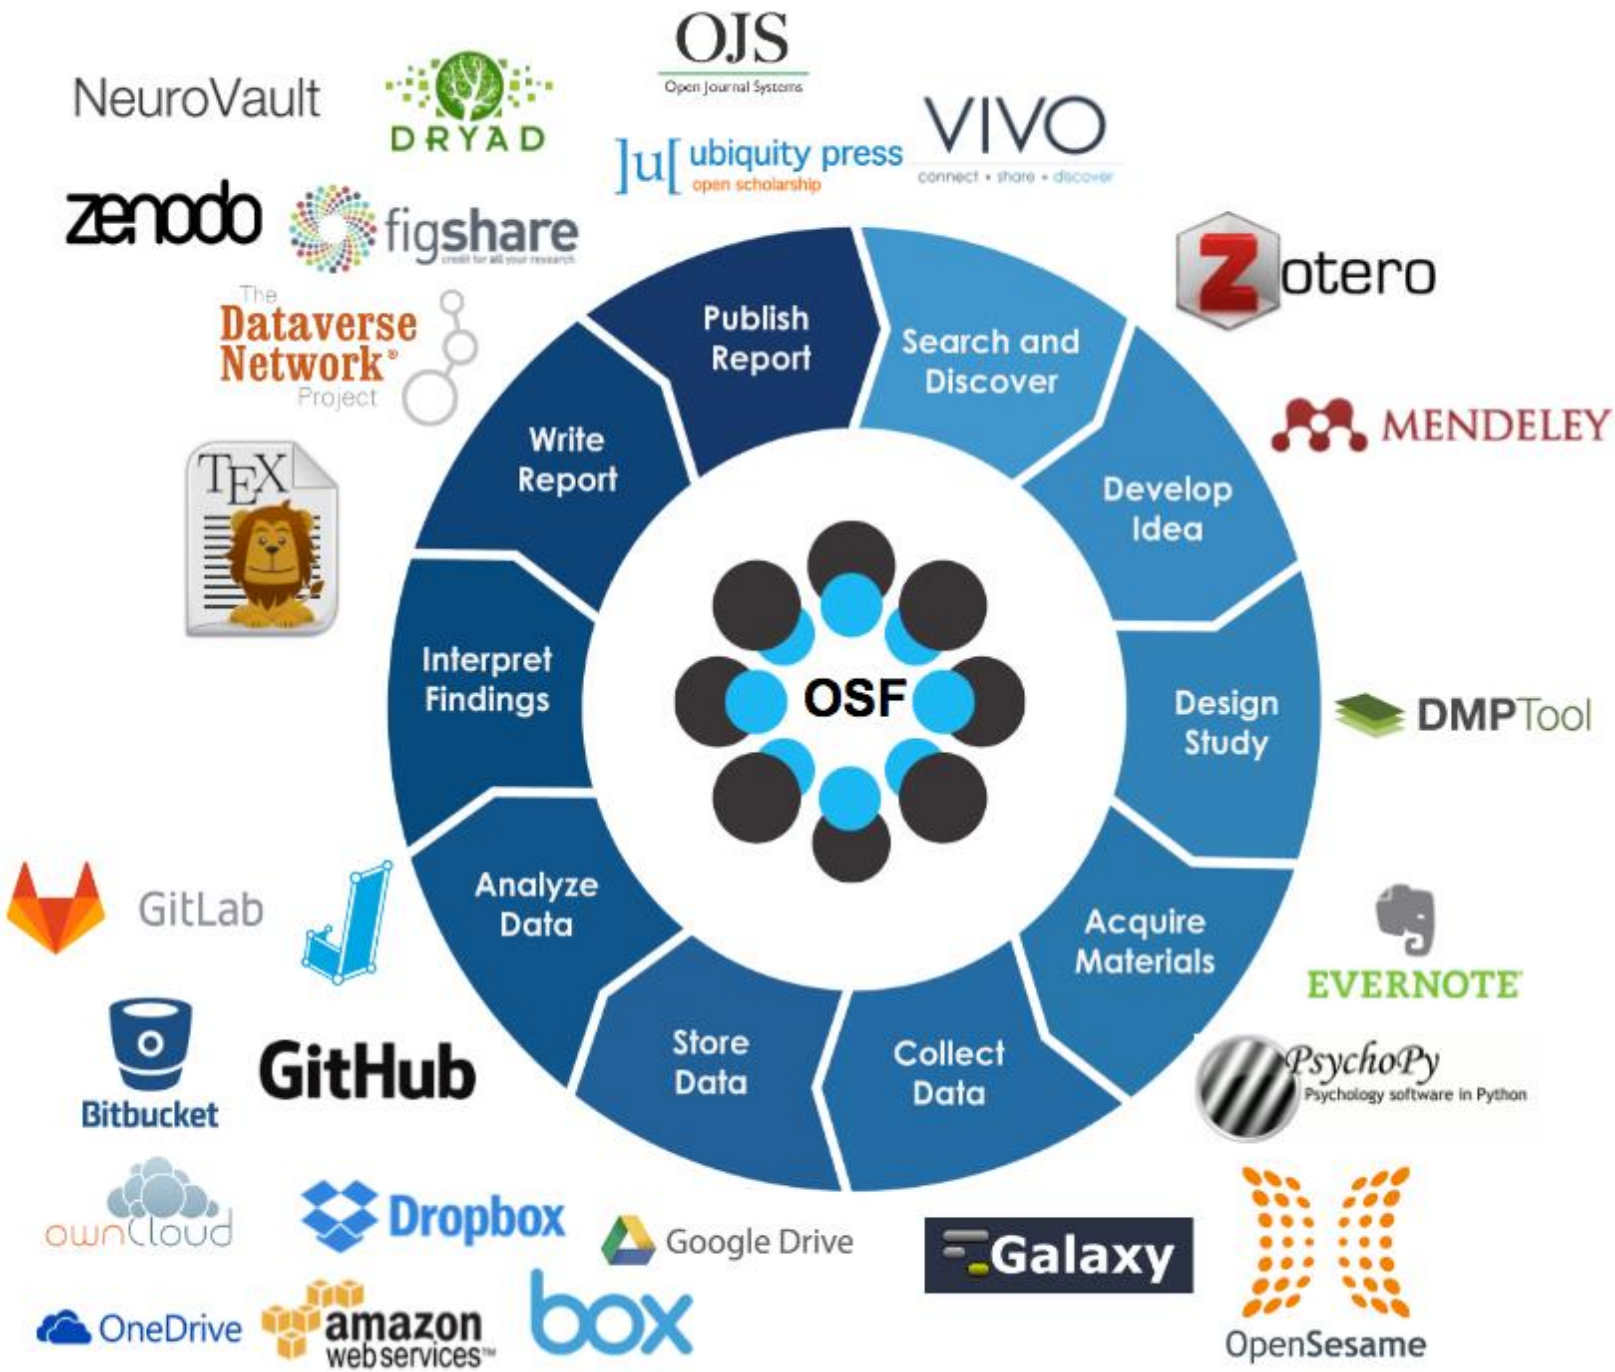

https://vickysteeves.gitlab.io/

Investigación reproducible / repetible

Excusas comunes para no compartir nuestro código

- Me da pena que vean mi código
- No quiero que otros saquen provecho de mi código, me pertenece o a mi institución
- Otros no publican su código ¿por qué yo sí?
- Me da flojera pulir mi código para publicarlo
- Si publico mi código le van a encontrar errores y demandar correcciones o ayuda

Si respondiste sí (o tus colaboradores) a cualquier de los puntos anteriores checa esta lectura recomendada:
Publish your computer code: it is good enough de Nick Barnes
https://www.nature.com/news/2010/101013/full/467753a.html

Inspirado por los materiales de Alicia Mastretta Yanes (UNAM, CONABIO http://mastrettayanes-lab.org/), curso “Introducción a la bioinformática reproducible para ecología y genética” impartido en CUCBA octubre 2016

Investigación reproducible / repetible

¿Cómo compartir código?

- Scripts comentados y con un README
- En lo posible utilizar formato Markdown
- Los archivos del proyecto organizados en una estructura transferible
- Crear repositorio de código
- DataDryad (como parte del repositorio de datos)
- GitHub (mejor para funciones y proyectos que continuarán actualizándose)

Ejemplo de estructura de catálogos y archivos del proyecto (Gandrud 2015)

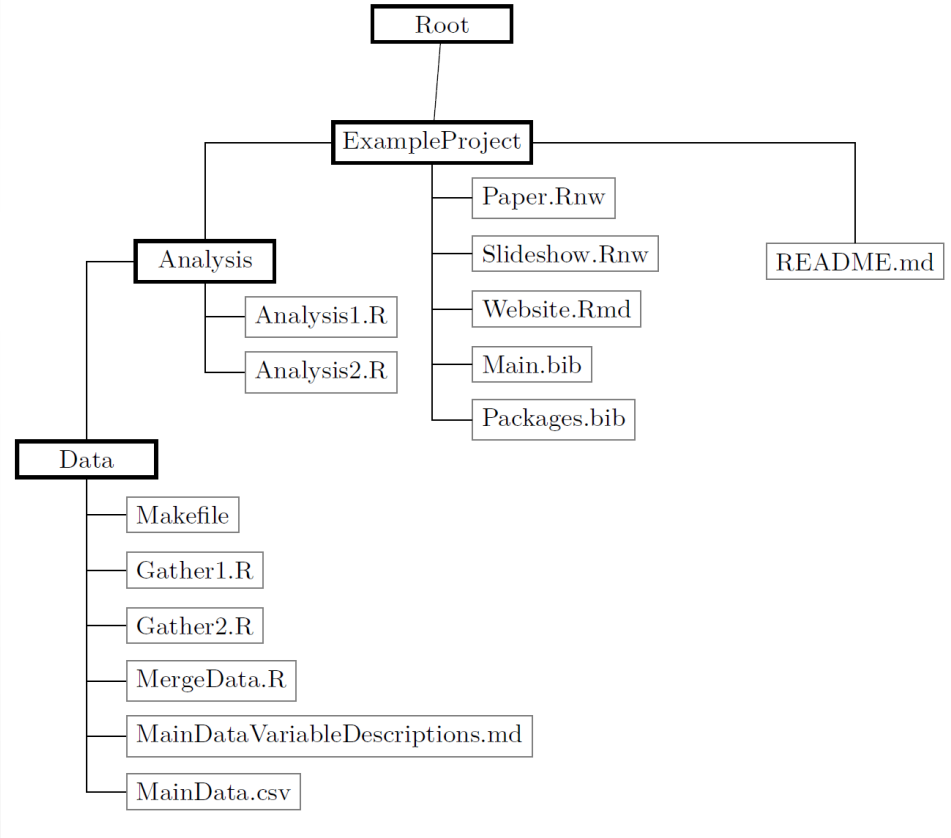

Inspirado por los materiales de Alicia Mastretta Yanes (UNAM, CONABIO http://mastrettayanes-lab.org/), curso “Introducción a la bioinformática reproducible para ecología y genética” impartido en CUCBA octubre 2016

Investigación reproducible / repetible

GitHub

Es un repositorio de código abierto

Utiliza el protocolo **git** para llevar un sistema de control de versiones

Su símbolo es un gatopulpo

Tiene una interfase Web pública

Se puede bajar como una aplicación de escritorio

Permite escribir/ revisar código en equipo

https://github.com/

Scripts

Un script es una recopilación por escrito de las instrucciones que queremos que la computadora corra, de modo que al tener esas instrucciones cualquiera pueda repetir el análisis tal cual se hizo.

El script consta de dos tipos de texto:

1. ***El código*** (comandos) que queremos que se ejecute, en el orden que queremos que lo ejecute.

    Es decir lo mismo que escribiríamos en la Terminal de computadora para hacer un análisis, pero guardado en un archivo de texto que tiene todos los comandos juntos y que podemos abrir para repetir o compartir el análisis.

2. ***Comentarios*** escritos para un ser humano en un lenguaje de humanos, dígase no solo en español/ingles, sino que nos permita entender qué hace el código, qué tipo de información requiere y cualquier otra cosa que una persona cualquiera necesite para poder utilizar el código del script de forma correcta.

Inspirado por los materiales de Alicia Mastretta Yanes (UNAM, CONABIO http://mastrettayanes-lab.org/), curso “Introducción a la bioinformática reproducible para ecología y genética” impartido en CUCBA octubre 2016

Markdown

¿Que es el Markdown?

“Markdown es la herramienta de conversión de texto al formato HTML pensada para los quien escriben para la web. Markdown permite escribir utilizando el formato de texto plano fácil para leer y escribir, para después convertirlo al formato XHTML (o HTML) valido estructuralmente.”

- John Gruber, creador de Markdown

What is Markdown?

“ Markdown is a text-to-HTML conversion tool for web writers. Markdown allows you to write using an easy-to-read, easy-to-write plain text format, then convert it to structurally valid XHTML (or HTML). ”

- John Gruber, creator of Markdown

R Markdown

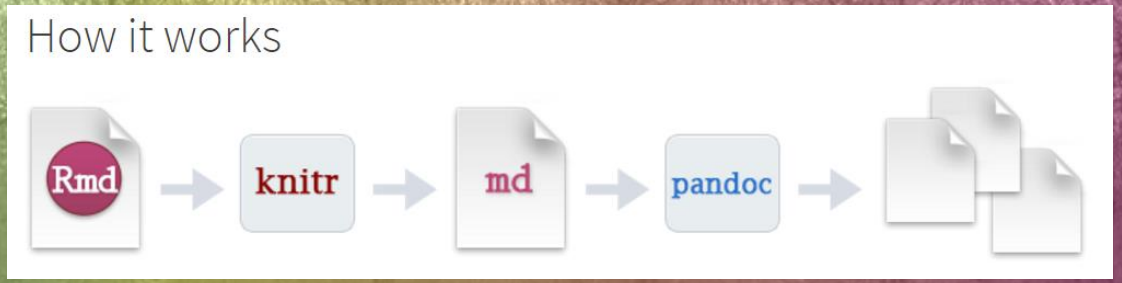

R Markdown from RStudio

Get Started Gallery Formats Articles

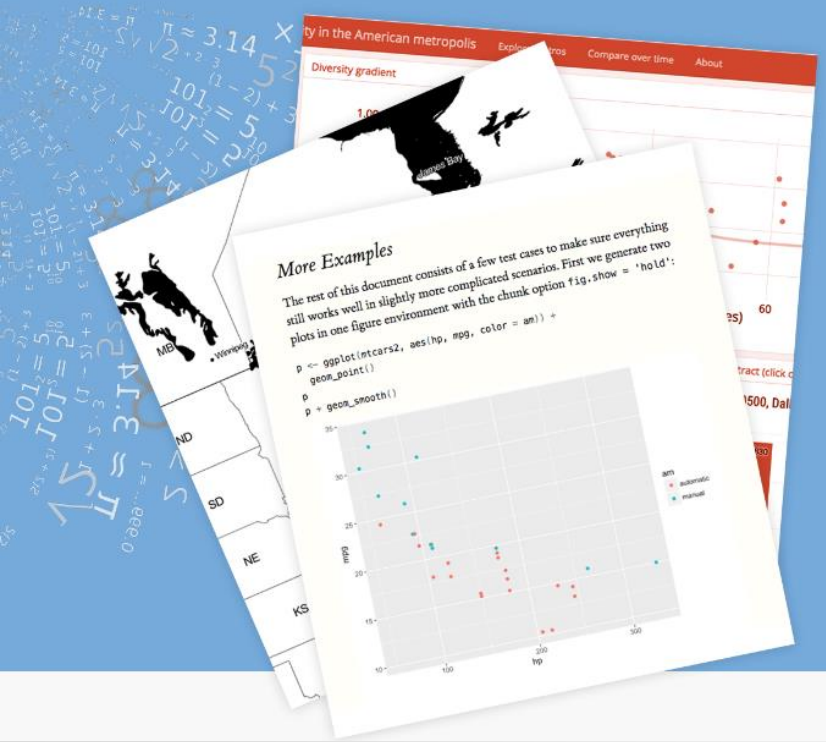

Analyze. Share. Reproduce.

Your data tells a story. Tell it with R Markdown. Turn your analyses into high quality documents, reports, presentations and dashboards.

Consulta la pagina web http://rmarkdown.rstudio.com para conocer la ideología R Markdown

R Markdown

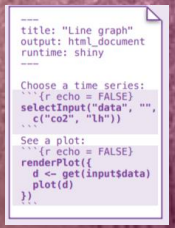

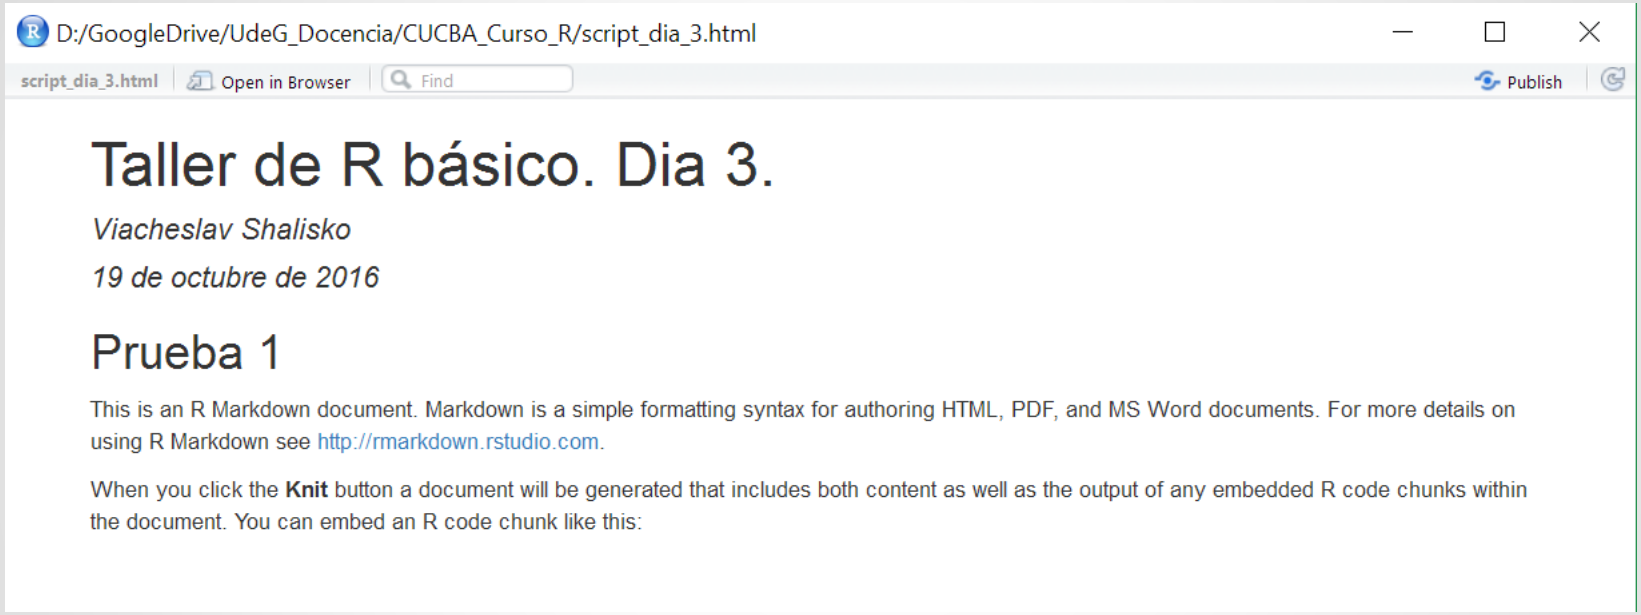

El formato *R Markdown* permite elaborar los documentos que contienen el código fuente en R, los resultados de su ejecución y el texto de comentarios.

Inclusión del código junto con los resultados en el mismo documento es parte de la estrategia para realizar la investigación reproducible. La entrega del código fuente de análisis junto con los resultados permite a otros científicos comprender la estructura del procedimiento y repetirlo. El formato es lo suficientemente flexible para habilitar o deshabilitar inclusión del código y de los resultados específicos.

R Markdown

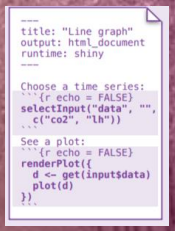

Notas:

- Para poder representar de forma correcta los símbolos especiales (letras con acento, letras del alfabeto griego, etc.) a veces se requiere especificar la codificación UTF-8.
- Guardar el script como el archivo en el formato *R Markdown* con la extensión .Rmd
- *Knit* as HTML (o *Knit* as PDF)
- Primera vez que se ejecuta *Knit* puede ser necesario instalar las bibliotecas adicionales (`knitr` y dependencias)

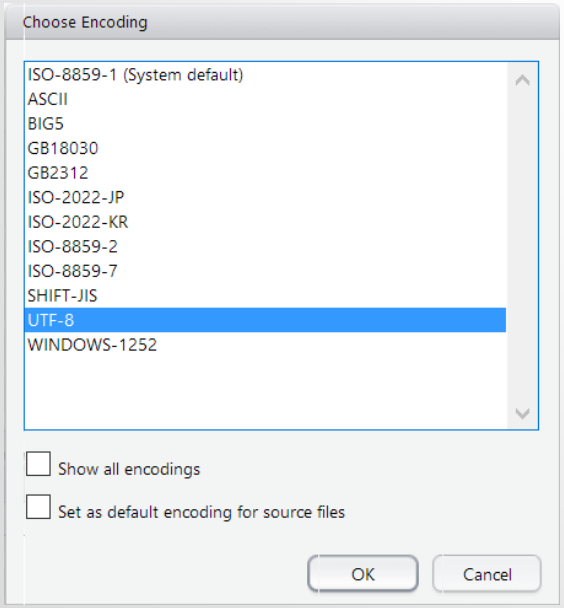

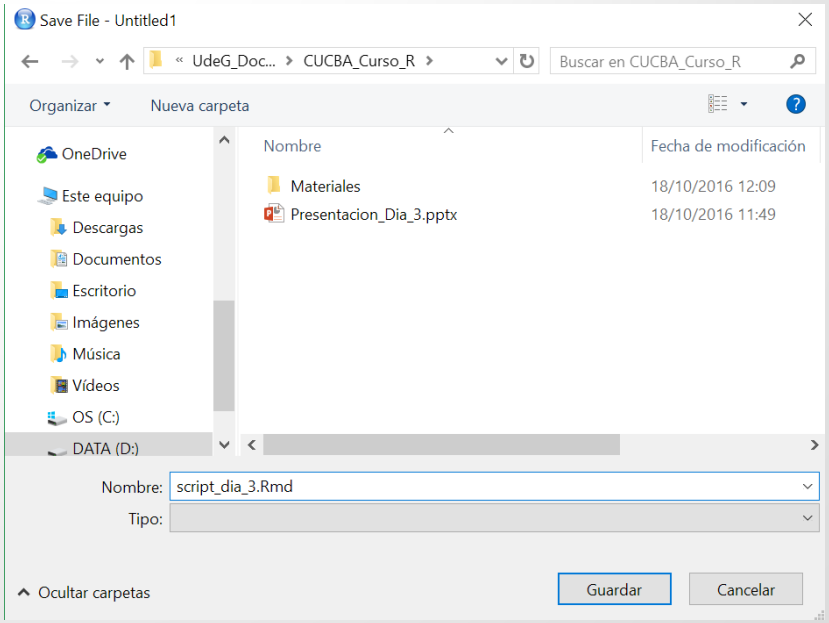

R Markdown

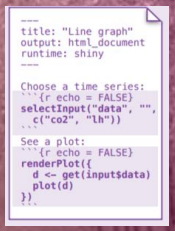

Ejemplo de R Markdown

Así se ve el código en el editor de RStudio

```
### A. Cargar la tabla de datos
#### Estructura de datos (tabla `Datos_del_censo.csv`):
1. *Centro* - código del CU
2. *Especie* - nombre científico
3. *Codigo* - identificador único del arbol
4. *AB* - área basal del árbol (dm^2^)
5. *DTr* - diametro del tronco equivalente (cm)
6. *Alt* - estatura del árbol (m)
7. *DCop* - diametro promedio de la copa (m)
8. *ExcCop* - excentricidad de la copa

```{r}
arbolado <- read.csv("Materiales/Datos_del_censo.csv")
dim(arbolado)
```
```

fragmento del código R (“chunk”)

El resultado de ejecución con el compilador *Knit*

A. Cargar la tabla de datos

Estructura de datos (tabla `Datos_del_censo.csv`):

1. *Centro* - código del CU
2. *Especie* - nombre científico
3. *Codigo* - identificador único del arbol
4. *AB* - área basal del árbol (dm^2)
5. *DTr* - diametro del tronco equivalente (cm)
6. *Alt* - estatura del árbol (m)
7. *DCop* - diametro promedio de la copa (m)
8. *ExcCop* - excentricidad de la copa

```
arbolado <- read.csv("Materiales/Datos_del_censo.csv")
dim(arbolado)
```

```
## [1] 4785    8
```

R Markdown

Paquete rticles

Otro Markdown Cheatsheet
https://github.com/adam-p/markdown-here/wiki/Markdown-Cheatsheet

Github's Markdown Guide
https://help.github.com/en/categories/writing-on-github

PROFACAD: Producto 2 para el portafolio

Producto para el portafolio: Producto 2. Ejercicio 1.

Fecha de entrega del producto: 21 de julio 2019

> Ejercicio 1: En forma individual realizar diseño de una plantilla en el formato R Markdown que puede servir como base para la presentación del proceso y los resultados del análisis de datos en conformidad con los principios de la investigación repetible. La plantilla debe contener las secciones (comentarios y espacio para código 'code chunk' donde se aplica):
>
> 1) Encabezado YAML, 2) Descripción, 3) Parámetros generales, 4) Datos fuente, 5) Análisis y resultados, 6) Exportación de resultados

Producto para el portafolio: Plantilla en el formato R Markdown PDF que determina la estructura de presentación de los procesos y resultados de análisis de datos científico, documento que cumple con las características definidas en las condiciones del ejercicio 1.

Estructuras de datos en R

Bibliografía complementaria

Gandrud, C. (2015). *Reproducible research with R and RStudio* (2nd ed.). Chapman and Hall/CRC.

Xie, Y., Allaire, J., Grolemund, G. (2018) *R Markdown: The Definitive Guide*. Chapman & Hall/CRC https://bookdown.org/yihui/rmarkdown/

Nüst, D. et al. (2018). *Writing reproducible geoscience papers using R Markdown, Docker, and GitLab*. https://vickysteeves.gitlab.io/repro-papers/index.html

Lenguaje R

Clases de *objetos* mas usados en R

1. **Estructuras de datos**
   a) Básicas (~5)
   b) Adicionales (definidos por módulos)
2. **Funciones**
   a) Básicas (parte del núcleo R)
   b) Externas (parte de los módulos)
3. **Estructuras de control**

R incluye varios modelos de objetos, pero esta tema es relevante para desarrolladores de módulos

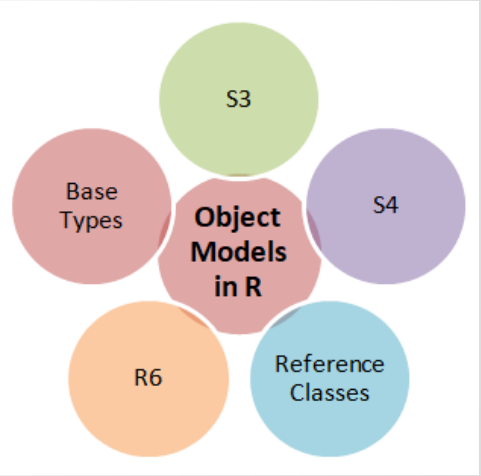

Figura de http://www.ciaburro.it/why-is-oop-in-r-so-confusing/

Nota 1: usualmente los objetos en R suelen tener un nombre (identificador)
Nota 2: existe una excepción de esta regla – las funciones anónimas

Estructuras de datos en R

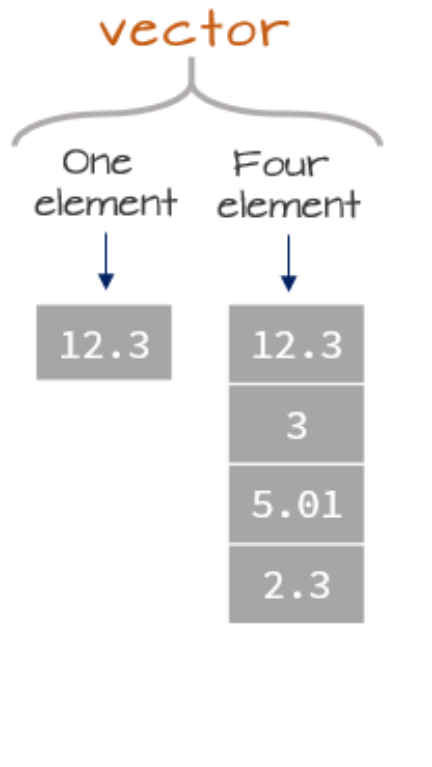

Vector es la estructura de datos más simple

Trata de un conjunto ordenado de elementos de mismo tipo

Los tipos de elementos pueden ser:

a) Números enteros (numeric integer, 32 bits con signo)
b) Números reales de doble precisión (numeric double, de 64 bits)
c) Valores lógicos (logical)
d) Cadenas de texto (character)
e) Factores (factor, tipo de datos compuesto)

Figura de Exploratory Data Analysis in R course
https://mgimond.github.io/ES218/index.html

Estructuras de datos en R

Ejemplo: vectores numéricos

```
a <- 1:10
a
```

```
##  [1]  1  2  3  4  5  6  7  8  9 10
```

```
b <- c(1.0, -3.4, 2, 140.1)
b
```

```
## [1]   1.0  -3.4   2.0 140.1
```

```
typeof(a)
```

```
## [1] "integer"
```

```
typeof(b)
```

```
## [1] "double"
```

Ejemplo: vectores de caracteres y lógicos

```
c <- c("lunes", "martes", "miercoles", "jueves", "viernes")
c
```

```
## [1] "lunes"     "martes"    "miercoles" "jueves"    "viernes"
```

```
d <- c(TRUE, FALSE, FALSE, TRUE)
d
```

```
## [1]  TRUE FALSE FALSE  TRUE
```

```
typeof(c)
```

```
## [1] "character"
```

```
typeof(d)
```

```
## [1] "logical"
```

Estructuras de datos en R

Coerción de tipos es el proceso de transformación forzada de un tipo a otro

La coerción de tipos se realiza de los tipos de datos más restrictivos a los más flexibles

Existe la coerción ***implícita*** y ***explicita***

Para la coerción explicita se usan funciones de la familia `as.` como:
`as.integer()`,
`as.numeric()`,
`as.character()`,
`as.logical()`

Secuencia de coerción

lógico -> entero -> numérico -> cadena de texto

```
c(a, b)
```

```
##  [1]   1.0   2.0   3.0   4.0   5.0   6.0   7.0   8.0   9.0  10.0   1.0
## [12]  -3.4   2.0 140.1
```

```
c(a,b,c)
```

```
##  [1] "1"         "2"         "3"         "4"         "5"
##  [6] "6"         "7"         "8"         "9"         "10"
## [11] "1"         "-3.4"      "2"         "140.1"     "lunes"
## [16] "martes"    "miercoles" "jueves"    "viernes"
```

```
c(a,b,c,d)
```

```
##  [1] "1"         "2"         "3"         "4"         "5"
##  [6] "6"         "7"         "8"         "9"         "10"
## [11] "1"         "-3.4"      "2"         "140.1"     "lunes"
## [16] "martes"    "miercoles" "jueves"    "viernes"   "TRUE"
## [21] "FALSE"     "FALSE"     "TRUE"
```

```
c(a,d)
```

```
##  [1]  1  2  3  4  5  6  7  8  9 10  1  0  0  1
```

Estructuras de datos en R

Vector de **factores** es la estructura de datos compuesta muy utilizada.

En breve, es un vector numérico con las etiquetas asociadas.

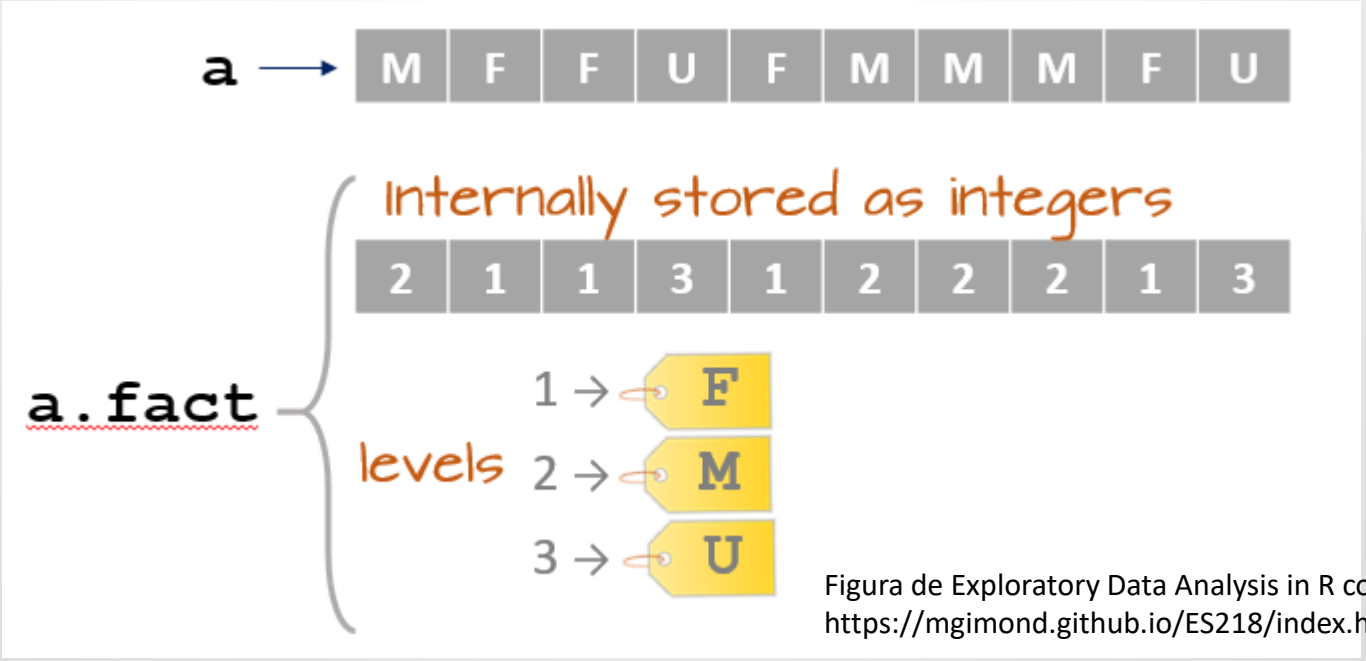

Figura de Exploratory Data Analysis in R course
https://mgimond.github.io/ES218/index.html

Estructuras de datos en R

Ejemplo: definición de un vector de factores

```
e <- c("masculino", "femenino", "masculino", "neutro", "femenino")
typeof(e)
```

```
## [1] "character"
```

```
e.fact <- as.factor(e)
levels(e.fact)
```

```
## [1] "femenino"  "masculino" "neutro"
```

```
e.fact
```

```
## [1] masculino femenino  masculino neutro    femenino
## Levels: femenino masculino neutro
```

```
typeof(e.fact)
```

```
## [1] "integer"
```

```
class(e.fact)
```

```
## [1] "factor"
```

Coerción a factores:
`as.factor()`

Lista de etiquetas:
`levels()`

Estructuras de datos en R

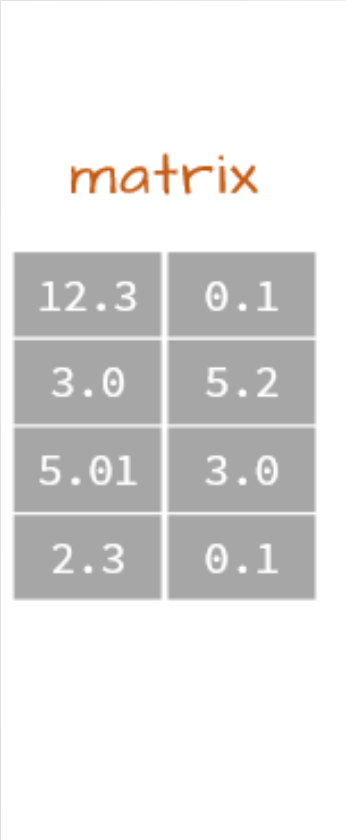

Matrices son las estructuras rectangulares bidimensionales

Pueden estar conformados por elementos de un solo tipo (mismos tipos que en vectores, excepto factores)

Arrays son similares a matrices pero pueden tener mas de dos dimensiones

Figura de Exploratory Data Analysis in R course
https://mgimond.github.io/ES218/index.html

Estructuras de datos en R

Ejemplo: definición de matriz

Definición de matrices:
`matrix(data, nrow = x, ncol = y)`

Número de dimensiones:
`dim()`

Combinación de matrices:
`cbind()`
`rbind()`

```
m1 <- matrix(1:12, nrow = 3, ncol = 4)
m1
```

```
##      [,1] [,2] [,3] [,4]
## [1,]    1    4    7   10
## [2,]    2    5    8   11
## [3,]    3    6    9   12
```

```
m2 <- matrix(runif(9,0,10), nrow = 3, ncol = 3)
m2
```

```
##           [,1]     [,2]     [,3]
## [1,] 9.9285730 3.642612 4.666548
## [2,] 0.9590461 9.656692 4.639480
## [3,] 4.3327996 9.009836 8.972147
```

```
dim(m1)
```

```
## [1] 3 4
```

```
dim(m2)
```

```
## [1] 3 3
```

```
cbind(m1,m2)
```

```
##      [,1] [,2] [,3] [,4]     [,5]      [,6]     [,7]
## [1,]    1    4    7   10 4.643617 9.8635540 9.129943
## [2,]    2    5    8   11 9.326838 1.8079605 7.103164
## [3,]    3    6    9   12 6.601292 0.6344612 7.829705
```

Estructuras de datos en R

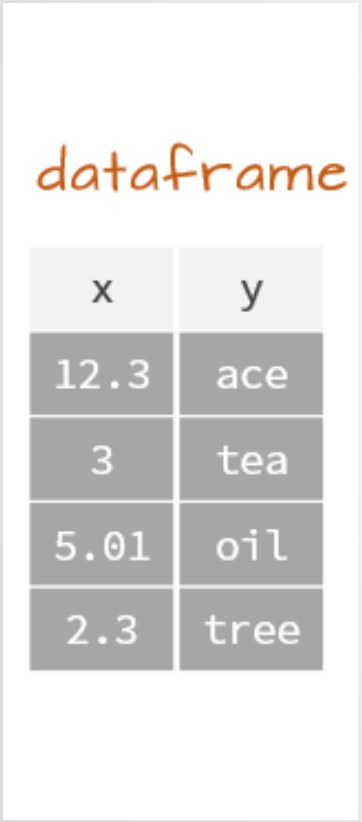

Los **dataframes** son las estructuras rectangulares bidimensionales similares a las tablas.

A diferencia de matrices, las columnas pueden tener datos de distintos tipos básicos.

Un **dataframe** esta compuesto por vectores (columnas).

El número de elementos en cada columna es fijo e igual a número de líneas en **dataframe.**

Figura de Exploratory Data Analysis in R course
https://mgimond.github.io/ES218/index.html

Estructuras de datos en R

La definición de dataframe se realiza por la función `data.frame()`

Es posible realizar una coerción de matriz a dataframe por medio de `as.data.frame()`

Las columnas y líneas de un dataframe pueden tener nombres

Estos se asignan y se acceden por medio de `names()` y `row.names()`

Igual que en matrices

Número de dimensiones:
`dim()`

Combinación de dataframes:
`cbind()`
`rbind()`

Estructuras de datos en R

Ejemplo: definición de un dataframe

```
ciudades.df <- data.frame(
  "id" = 1:4,
  "nombre" = c("Ciudad de México (ZMCM)", "Guadalajara (AMG)", "Monterrey (ZMM)", "León"),
  "tipo" = as.factor(c("megaciudad","ciudad","ciudad","ciudad")),
  "poblacion" = c(20.40, 4.75, 4.69, 1.24),
  "latitud" = c(19.428, 20.667, 25.6714, 21.129),
  "longitud" = c(-99.128, -103.392, -100.309, -101.674),
  stringsAsFactors = FALSE
)
```

```
ciudades.df
```

```
##   id                  nombre       tipo poblacion latitud longitud
## 1  1 Ciudad de México (ZMCM) megaciudad     20.40 19.4280  -99.128
## 2  2       Guadalajara (AMG)     ciudad      4.75 20.6670 -103.392
## 3  3         Monterrey (ZMM)     ciudad      4.69 25.6714 -100.309
## 4  4                  León     ciudad      1.24 21.1290 -101.674
```

Estructuras de datos en R

Ejemplo: propiedades de un dataframe

```
dim(ciudades.df)
```

```
## [1] 4 6
```

```
names(ciudades.df)
```

```
## [1] "id"        "nombre"    "tipo"      "poblacion" "latitud"   "longitud"
```

```
row.names(ciudades.df)
```

```
## [1] "1" "2" "3" "4"
```

```
str(ciudades.df)
```

```
## 'data.frame':    4 obs. of  6 variables:
##  $ id       : int  1 2 3 4
##  $ nombre   : chr  "Ciudad de México (ZMCM)" "Guadalajara (AMG)" "Monterrey (ZMM)" "León"
##  $ tipo     : Factor w/ 2 levels "ciudad","megaciudad": 2 1 1 1
##  $ poblacion: num  20.4 4.75 4.69 1.24
##  $ latitud  : num  19.4 20.7 25.7 21.1
##  $ longitud : num  -99.1 -103.4 -100.3 -101.7
```

Estructuras de datos en R

Listas son las estructuras unidimensionales conformados por elementos heterogéneos (que pueden ser de diferentes tipos y clases).

Los elementos de las listas pueden tener distintas dimensiones e incluso ser otras listas.

Lista solo tiene una solo dimensión que se puede acceder por medio de `length()`

Figura de Exploratory Data Analysis in R course
https://mgimond.github.io/ES218/index.html

Estructuras de datos en R

Ejemplo: definición de una lista

```
mi_vector <- 1:10
mi_factor <- as.factor(c("F1","F2"))
mi_matriz <- matrix(1:6, nrow = 2)
mi_df     <- data.frame("var_num" = 0:2, "var_text" = c("uno", "dos", "tres"))

mi_lista <- list("un_vector" = mi_vector, "un_factor" = mi_factor, "una_matriz" = mi_matriz, "un_df" = mi_df)
mi_lista
```

```
## $un_vector
##  [1]  1  2  3  4  5  6  7  8  9 10
##
## $un_factor
## [1] F1 F2
## Levels: F1 F2
##
## $una_matriz
##      [,1] [,2] [,3]
## [1,]    1    3    5
## [2,]    2    4    6
##
## $un_df
##   var_num var_text
## 1       0      uno
## 2       1      dos
## 3       2     tres
```

```
str(mi_lista)
```

```
## List of 4
##  $ un_vector : int [1:10] 1 2 3 4 5 6 7 8 9 10
##  $ un_factor : Factor w/ 2 levels "F1","F2": 1 2
##  $ una_matriz: int [1:2, 1:3] 1 2 3 4 5 6
##  $ un_df     :'data.frame':  3 obs. of  2 variables:
##   ..$ var_num : int [1:3] 0 1 2
##   ..$ var_text: Factor w/ 3 levels "dos","tres","uno": 3 1 2
```

```
length(mi_lista)
```

```
## [1] 4
```

Estructuras de datos en R

Estructura de datos	Dimensiones	Tipos de datos mixtos	Posibilidad utilizar factores
vector	1	-	+
matrix	2	-	-
array	n	-	-
data.frame	2	+	+
list	1 (n)	+	+

Estructuras de datos en R

Ejercicio 2A

Elaborar una estructura de datos en R que corresponde a una ficha de registro de participación de un deportista en competencia (maratón). Escribir el código y visualizar el contenido de la estructura elaborada.

Ficha debe incluir:

- Nombre de deportista
- Su nacionalidad
- Su edad y género
- Dia de competencia
- Coordenadas geográficas de los puntos de inicio, de mitad y de final del recorrido en maratón
- Tiempo (horas, minutos, segundos por separado) cuando el deportista paso por cada uno de estos puntos

Inicio:	19.3328, -99.1870
Mitad:	19.4407, -99.2046
Final:	19.4323, -99.1333

Extracción de datos en R

- Todas las estructuras de datos en R cuentan con índices de posición de elementos. Los índices son las secuencias numéricas de valores enteros consecutivas `1..n`
- Los elementos en las estructuras de datos se puede extraer utilizando los índices mencionados.
- En caso de **vectores**, estos cuentan con la única dimensión, y acceso a sus elementos requiere el único índice.
- Los corchetes después de nombre del vector `[i]` se emplean para especificar el valor o valores del índice de elementos por consultar.

Ejemplos:

`c[3]` – extraer el elemento 3 del vector “c”
`c[2:5]` – extraer los elementos de 2 a 5 en del vector “c”
`c[c(1,4,6)]` – extraer los elementos 1, 4 y 5 en del vector “c”

Extracción de datos en R

Ejemplo:
extracción desde vectores

```
meses <- c("enero", "febrero", "marzo", "abril",
           "mayo", "junio", "julio", "agosto",
           "septiembre", "octubre", "noviembre", "diciembre")
```

```
meses[3]
```

```
## [1] "marzo"
```

```
meses[2:5]
```

```
## [1] "febrero" "marzo"   "abril"   "mayo"
```

```
meses[5:2]
```

```
## [1] "mayo"    "abril"   "marzo"   "febrero"
```

```
meses[c(1,6,12)]
```

```
## [1] "enero"     "junio"     "diciembre"
```

```
meses.selectos <- meses[7:9]
meses.selectos
```

```
## [1] "julio"     "agosto"    "septiembre"
```

```
meses[15]
```

```
## [1] NA
```

Nota: los valores NA corresponden a los elementos sin datos

Extracción de datos en R

- En caso de **matrices**, son las estructuras bidimensionales, y acceso a sus elementos requiere dos índices.
- Los corchetes después de nombre del matriz `[i,j]` se emplean para especificar los valores del índice líneas y columnas
- Resultados de extracción de matrices pueden ser vectores o matrices parciales

Ejemplos:

`m2[2,3]` – extraer el elemento de la segunda fila y tercera columna
`m2[1,]` – extraer todos los elementos de la primera fila
`m2[,2]` – extraer todos los elementos de la segunda columna
`m2[c(1,3),2]` – extraer el primer y tercer elemento de la segunda columna
`m2[c(1,3),1:2]` – extraer la primera y tercera fila de la primera y segunda columna (resultado una matriz 2 por 2)

Extracción de datos en R

Ejemplo: extracción desde matrices

```
m2
```

```
##           [,1]     [,2]      [,3]
## [1,] 2.410825 1.799516 6.4424895
## [2,] 3.654689 3.187548 1.2440275
## [3,] 8.489164 7.818309 0.2471724
```

```
m2[c(1,3),1:2]
```

```
##           [,1]     [,2]
## [1,] 2.862807 9.148732
## [2,] 2.473620 4.880261
```

```
m2[2,3]
```

```
## [1] 1.244027
```

```
m2[1,]
```

```
## [1] 2.410825 1.799516 6.442489
```

```
m2[,2]
```

```
## [1] 1.799516 3.187548 7.818309
```

```
m2[c(1,3),2]
```

```
## [1] 1.799516 7.818309
```

Extracción de datos en R

```
lista[i]
```

- Extracción de los elementos de una **lista** puede ser por medio de los índices numéricos similar a lo de vectores.
  - Extracción con este método tipo produce la lista.

```
lista[[i]]
```

- Para extraer el elemento como una estructura de datos asignada al elemento se requiere utilizar los corchetes dobles. Así se puede consultar un solo elemento, pero no grupos de elementos.

```
lista["nombre"]
```

- En lugar del índice numérico se puede utilizar los nombres de elementos en comillas dobles.

```
lista[["nombre"]]
```

- Un resultado similar a corchetes dobles se puede lograr utilizando el sintaxis con el símbolo $ y el nombre del elemento de la lista después.

```
lista$nombre
```

- Cada uno de los elementos extraídos de la lista puede contar con propia estructura interna, que en su cuenta puede ser sujeta de extracción anidada.

Extracción de datos en R

Ejemplos de extracción de una **lista**:

`mi_lista[3]` – extraer el tercer elemento (como una lista)
`mi_lista[[3]]` – extraer el tercer elemento (como la estructura de datos propia del elemento)
`mi_lista["una_matriz"]` – extraer el tercer elemento por su nombre
`mi_lista[c("una_matriz","un_df")]` – extraer dos elementos por nombre

`mi_lista$una_matriz` – forma alternativa de extraer elemento por nombre
`mi_lista$una_matriz[2,3]` – extracción anidada del elemento de matriz

Extracción de datos en R

Ejemplo: extracción desde una lista

```
mi_lista[3]
```

```
## $una_matriz
##      [,1] [,2] [,3]
## [1,]    1    3    5
## [2,]    2    4    6
```

```
mi_lista[[3]]
```

```
##      [,1] [,2] [,3]
## [1,]    1    3    5
## [2,]    2    4    6
```

```
mi_lista[c("una_matriz","un_df")]
```

```
## $una_matriz
##      [,1] [,2] [,3]
## [1,]    1    3    5
## [2,]    2    4    6
##
## $un_df
##   var_num var_text
## 1       0      uno
## 2       1      dos
## 3       2     tres
```

```
mi_lista["una_matriz"]
```

```
## $una_matriz
##      [,1] [,2] [,3]
## [1,]    1    3    5
## [2,]    2    4    6
```

```
mi_lista$una_matriz
```

```
##      [,1] [,2] [,3]
## [1,]    1    3    5
## [2,]    2    4    6
```

```
mi_lista$una_matriz[2,3]
```

```
## [1] 6
```

Extracción de datos en R

- Los **dataframes**, combinan características de matrices y listas.
- El acceso a los elementos de dataframe se puede realizar con índices numéricos y con nombres, o combinando dos enfoques.
- Resultados de extracción puede ser es otro dataframe o un vector.

```
ciudades.df[2]

ciudades.df["nombre"]

ciudades.df[["nombre"]]

ciudades.df$nombre
```

- La extracción con el único índice en corchetes simples `df[j]` regresa la columna o un conjunto de columnas en forma de un nuevo dataframe.
- En lugar del índice en corchetes se puede utilizar el nombre o nombres de las columnas.
- Acceso a valores en única columna puede ser con la notación de dobles corchetes o los nombres después del símbolo $, similar a lo de listas.

Extracción de datos en R

```
ciudades.df[1,2]
ciudades.df[1:2,c(2,4)]

ciudades.df[,2]
ciudades.df[,"nombre"]

ciudades.df[1,]
```

- La extracción con dos índices en corchetes `df[i,j]` permite acceder a un elemento o a grupo de elementos.
- La extracción omitiendo el primer índice en corchetes `df[,j]` permite extraer las columnas completas.
- En lugar de índices se puede utilizar nombres de columnas.
- La extracción omitiendo el segundo índice en corchetes `df[i,]` permite extraer las filas completas.

Extracción de datos en R

Ejemplos de extracción desde un **dataframe**:

```
ciudades.df[2]          – extraer la segunda columna (como un dataframe)
ciudades.df[2:4]        – extraer las columnas de dos a cuatro
ciudades.df["nombre"]   – extraer la columna por nombre (como un dataframe)
ciudades.df$nombre      – extraer la columna por nombre (como un vector, solo se
                                  puede acceder a una columna)

ciudades.df[2,]         – extraer la fila dos (como un vector)
ciudades.df[,2]         – extraer la columna dos (como un vector)

ciudades.df[,c("nombre", "poblacion")]      – dos columnas
ciudades.df[1,c("nombre", "poblacion")]     – una fila, dos columnas
ciudades.df[c(1,4),c(2,4)]                  – dos filas, dos columnas
```

Extracción de datos en R

Ejemplo: extracción desde un dataframe

```
ciudades.df[2]
```

```
##                     nombre
## 1 Ciudad de México (ZMCM)
## 2       Guadalajara (AMG)
## 3         Monterrey (ZMM)
## 4                   León
```

```
ciudades.df[2:4]
```

```
##                     nombre       tipo poblacion
## 1 Ciudad de México (ZMCM) megaciudad     20.40
## 2       Guadalajara (AMG)     ciudad      4.75
## 3         Monterrey (ZMM)     ciudad      4.69
## 4                   León     ciudad      1.24
```

Extracción de datos en R

```
ciudades.df["nombre"]
```

```
##                     nombre
## 1 Ciudad de México (ZMCM)
## 2       Guadalajara (AMG)
## 3         Monterrey (ZMM)
## 4                   León
```

```
ciudades.df$nombre
```

```
## [1] "Ciudad de México (ZMCM)" "Guadalajara (AMG)"
## [3] "Monterrey (ZMM)"         "León"
```

```
ciudades.df[,2]
```

```
## [1] "Ciudad de México (ZMCM)" "Guadalajara (AMG)"
## [3] "Monterrey (ZMM)"         "León"
```

Extracción de datos en R

```
ciudades.df[2,]
```

```
##   id            nombre   tipo poblacion latitud longitud
## 2  2 Guadalajara (AMG) ciudad      4.75  20.667 -103.392
```

```
ciudades.df[,c("nombre", "poblacion")]
```

```
##                    nombre poblacion
## 1 Ciudad de México (ZMCM)     20.40
## 2       Guadalajara (AMG)      4.75
## 3         Monterrey (ZMM)      4.69
## 4                   León       1.24
```

```
ciudades.df[1,c("nombre", "poblacion")]
```

```
##                    nombre poblacion
## 1 Ciudad de México (ZMCM)      20.4
```

Estructuras de datos en R

Ejercicio 2B

Considerando la ficha elaborada en el ejercicio 1. Consulta en su ficha:

a) Nombre de deportista
b) Momento de tiempo cuando deportista inicio el maratón
c) Momento de tiempo cuando deportista concluyo el maratón
d) * Calcula cuanto tiempo le llevo recorrer toda la distancia (puede ser en horas, minutos o segundos)
e) ** Genera en R un texto que dice: *Participante nombre logro recorrer el maratón en HH horas, MM minutos, SS segundos*.

Estructuras de datos en R

Ejercicio 2B

Puedes realizar las operaciones aritméticas con valores numéricos.

Explora algunas las funciones que pueden ser necesarias para realizar los puntos d) y e) del ejercicio 2.

unlist() – convertir valores de lista o dataframe a un vector
paste() – concatenar cadenas de texto
floor() – extraer parte entera de un número
striptime() – convertir entre tiempos y cadenas de texto
difftime() – calcular diferencia entre dos momentos de tiempo

PROFACAD: Producto 3 para el portafolio

Producto para el portafolio: Producto 3. Ejercicios 2A y 2B

Fecha de entrega del producto: 21 de julio 2019

Actividades: En equipos de 2 alumnos definir en R la estructura de datos que corresponde a la ficha de registro de actividad de un maratonista, y realizar consulta de información guardada en la ficha (ejercicios 2A y 2B).

Producto para el portafolio: Reporte de generación de ficha y su consulta en el formato del documento R Markdown PDF con los fragmentos de código insertados, que cumple con las características definidos en las condiciones de los ejercicios 2A y 2B.

Estructuras de datos en R

Bibliografía complementaria

Mendoza Vega, J. B. (2018). *R para principiantes*. Libro electrónico recuperado de https://bookdown.org/jboscomendoza/r-principiantes4/

Peng, R. D. (2016). *R Programming for Data Science*. Leanpub. https://leanpub.com/rprogramming

Wickham. H. y Grolemund, G. (2017). *R for Data Science*. O'Reilly. http://r4ds.had.co.nz/

Respuesta a ejercicio 2

https://github.com/vshalisko/R-intro-UdeG/tree/master/DataStructures