Introducción a R

Oscar Perpiñán Lamigueiro

Universidad Politécnica de Madrid

¿Qué es R?

Es un entorno de programación orientado al cálculo, manipulación de datos, y representación gráfica, publicado como software libre con licencia GNU-GPL.

http://www.R-project.org

R está muy bien documentado

- Manuales Oficiales
  - Introduction to R
  - R Data Import/Export
  - R Installation and Administration
  - Writing R Extensions
  - R language definition
  - R Internals
- Manuales externos

Otros recursos de información

- Listas de correo (sin olvidar respetar estos consejos)
  - Generales: R-announce, R-help, R-devel
  - Special Interest Group (SIG) mailing lists
- R-bloggers
- stackoverflow

R es un proyecto colaborativo

- Una de las grandes riquezas de R es la cantidad de paquetes que amplían sus funcionalidades.
- La lista completa está en `http://cran.es.r-project.org/web/packages/`.
- Las CRAN Task Views agrupan por temáticas: `http://cran.r-project.org/web/views/`

Lectura de datos

Importamos datos en formato tabular de un fichero disponible en un enlace externo.

```
myURL <- "https://raw.githubusercontent.com/oscarperpinan/R/master/data/aranjuez.
    csv"

## Las columnas están separadas por comas
## La primera fila es la cabecera
datos <- read.table(myURL,
                    sep=',',
                    header=TRUE)
```

Accedemos al contenido

```
summary(datos)
```

```
      X                TempAvg          TempMax          TempMin           HumidAvg
 Length:2898        Min.   :-5.309   Min.   :-2.362   Min.   :-12.980   Min.   : 19.89
 Class :character   1st Qu.: 7.692   1st Qu.:14.530   1st Qu.:  1.515   1st Qu.: 47.04
 Mode  :character   Median :13.810   Median :21.670   Median :  7.170   Median : 62.58
                    Mean   :14.405   Mean   :22.531   Mean   :  6.888   Mean   : 62.16
                    3rd Qu.:21.615   3rd Qu.:30.875   3rd Qu.: 12.590   3rd Qu.: 77.38
                    Max.   :30.680   Max.   :41.910   Max.   : 22.710   Max.   :100.00
                                                      NA's   :4
    HumidMax         WindAvg          WindMax           Rain          Radiation
 Min.   : 35.88   Min.   :0.251   Min.   : 0.000   Min.   : 0.000   Min.   : 0.277
 1st Qu.: 81.60   1st Qu.:0.667   1st Qu.: 3.783   1st Qu.: 0.000   1st Qu.: 9.370
 Median : 90.90   Median :0.920   Median : 5.027   Median : 0.000   Median :16.660
 Mean   : 87.22   Mean   :1.174   Mean   : 5.208   Mean   : 1.094   Mean   :16.742
 3rd Qu.: 94.90   3rd Qu.:1.431   3rd Qu.: 6.537   3rd Qu.: 0.200   3rd Qu.:24.650
 Max.   :100.00   Max.   :8.260   Max.   :10.000   Max.   :49.730   Max.   :32.740
 NA's   :13       NA's   :8       NA's   :128      NA's   :4        NA's   :13
       ET
 Min.   :0.000
 1st Qu.:1.168
 Median :2.758
 Mean   :3.091
 3rd Qu.:4.926
 Max.   :8.564
 NA's   :18
```

Modificamos los datos

```
## Convertimos unidades (MJ -> kWh)
datos$Radiation2 <- datos$Radiation / 3.6
```

```
## 10 primeras filas de las dos variables
datos[1:10,
     c("Radiation", "Radiation2")]
```

```
   Radiation Radiation2
1      5.490   1.525000
2      6.537   1.815833
3      8.810   2.447222
4      9.790   2.719444
5     10.300   2.861111
6      9.940   2.761111
7      7.410   2.058333
8      4.630   1.286111
9      4.995   1.387500
10     8.930   2.480556
```

Representamos gráficamente los datos

```
library(lattice)

xyplot(Radiation ~ TempAvg, data = datos,
      type = c("p", "r"),
      pch = 21, col = 'black', fill = 'gray')
```

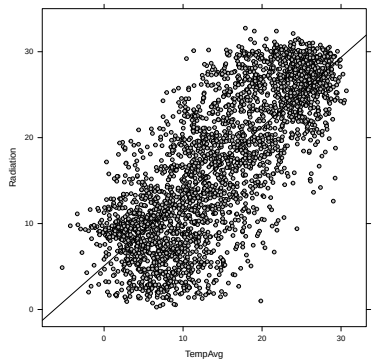

Objetos en R

- Existen varios objetos en R:
  - Vectores
  - Listas
  - Funciones
  - ...
- A partir de estos objetos se definen varias clases:
  - `matrix`
  - `data.frame`
  - `factor`
  - `Date`, `POSIXct`
  - ...

Primeros pasos

```
x <- 1:5
x
```

```
[1] 1 2 3 4 5
```

```
length(x)
```

```
[1] 5
```

```
class(x)
```

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

Generar vectores con seq

```
x1 <- seq(1, 100, by=2)
x1
```

```
[1]  1  3  5  7  9 11 13 15 17 19 21 23 25 27 29 31 33 35 37 39 41 43 45 47 49 51 53 55 57
[30] 59 61 63 65 67 69 71 73 75 77 79 81 83 85 87 89 91 93 95 97 99
```

```
seq(1, 100, length=10)
```

```
[1]   1  12  23  34  45  56  67  78  89 100
```

Unir vectores con c

```
x <- c(1, 2, 3)
x
```

```
[1] 1 2 3
```

```
x <- seq(1, 100, length=10)
y <- seq(2, 100, length=50)
z <- c(x, y)
z
```

```
[1]   1  12  23  34  45  56  67  78  89 100   2   4   6   8  10  12  14  16  18  20  22  24
[23]  26  28  30  32  34  36  38  40  42  44  46  48  50  52  54  56  58  60  62  64  66  68
[45]  70  72  74  76  78  80  82  84  86  88  90  92  94  96  98 100
```

Operaciones sencillas con vectores

```
x <- 1:5
x + 1
```

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

```
x^2
```

```
[1]  1  4  9 16 25
```

```
y <- 1:10
x + y
```

```
[1]  2  4  6  8 10  7  9 11 13 15
```

```
x * y
```

```
[1]  1  4  9 16 25  6 14 24 36 50
```

```
x^2 + y^3
```

```
[1]    2   12   36   80  150  217  347  521  745 1025
```

Ejercicio

Dibuja una circunferencia

Sabiendo que la función `plot(x, y)` dibuja el vector `y` frente al vector `x`, ¿qué código es necesario para dibujar una circunferencia de un radio determinado?

Construir una matriz

```
z <- 1:12
M <- matrix(z, nrow=3)
M
```

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

```
class(M)
```

```
[1] "matrix" "array"
```

```
dim(M)
```

```
[1] 3 4
```

```
summary(M)
```

```
      V1             V2             V3             V4
Min.   :1.0   Min.   :4.0   Min.   :7.0   Min.   :10.0
1st Qu.:1.5   1st Qu.:4.5   1st Qu.:7.5   1st Qu.:10.5
Median :2.0   Median :5.0   Median :8.0   Median :11.0
Mean   :2.0   Mean   :5.0   Mean   :8.0   Mean   :11.0
3rd Qu.:2.5   3rd Qu.:5.5   3rd Qu.:8.5   3rd Qu.:11.5
Max.   :3.0   Max.   :6.0   Max.   :9.0   Max.   :12.0
```

Matrices a partir de vectores: rbind y cbind

```
z <- y <- x <- 1:10

M <- cbind(x, y, z)
M
```

```
x  y  z
 [1,]  1  1  1
 [2,]  2  2  2
 [3,]  3  3  3
 [4,]  4  4  4
 [5,]  5  5  5
 [6,]  6  6  6
 [7,]  7  7  7
 [8,]  8  8  8
 [9,]  9  9  9
[10,] 10 10 10
```

```
M <- rbind(x, y, z)
M
```

```
  [,1] [,2] [,3] [,4] [,5] [,6] [,7] [,8] [,9] [,10]
x    1    2    3    4    5    6    7    8    9    10
y    1    2    3    4    5    6    7    8    9    10
z    1    2    3    4    5    6    7    8    9    10
```

Álgebra matricial

`t()`	Transpuesta de una matriz
`*`	Multiplicación elemento a elemento
`%*%`	Multiplicación de matrices
`solve(A)`	Inversa de una matriz (cuadrada)
	...

Para crear una lista usamos la función `list`

```
lista <- list(a=c(1,3,5),
              b=c('l', 'p', 'r', 's'),
              c=3)
lista
```

```
$a
[1] 1 3 5

$b
[1] "l" "p" "r" "s"

$c
[1] 3
```

```
class(lista)
```

```
[1] "list"
```

```
length(lista)
```

```
[1] 3
```

Para crear un `data.frame`...

```
df <- data.frame(x = 1:5,
                 y = rnorm(10),
                 z = 0)
df
```

```
x          y z
1  1 -0.22757628 0
2  2 -0.48875115 0
3  3 -0.38748855 0
4  4 -2.01658725 0
5  5 -0.25411460 0
6  1 -1.48586859 0
7  2  0.34842203 0
8  3 -1.34725519 0
9  4 -0.09036966 0
10 5 -1.42688469 0
```

```
length(df)
```

```
[1] 3
```

```
dim(df)
```

```
[1] 10  3
```

A partir de ficheros

```
dats <- read.table('data/aranjuez.csv',
                   sep=',',
                   header=TRUE)
```

```
head(dats)
```

```
           X TempAvg TempMax TempMin HumidAvg HumidMax WindAvg WindMax Rain Radiation
1 2004-01-01   4.044   10.71  -1.969     88.3     95.9   0.746   3.528    0     5.490
2 2004-01-02   5.777   11.52   1.247     83.3     98.5   1.078   6.880    0     6.537
3 2004-01-03   5.850   13.32   0.377     75.0     94.4   0.979   6.576    0     8.810
4 2004-01-04   4.408   15.59  -2.576     82.0     97.0   0.633   3.704    0     9.790
5 2004-01-05   3.081   14.58  -2.974     83.2     97.0   0.389   2.244    0    10.300
6 2004-01-06   2.304   11.83  -3.379     84.5     96.5   0.436   2.136    0     9.940
         ET
1 0.5352688
2 0.7710499
3 0.8361229
4 0.6861381
5 0.5152422
6 0.4886631
```

Atención: usa `setwd` para configurar ruta

A partir de ficheros remotos

```
remoto <- read.table('https://raw.githubusercontent.com/oscarperpinan/R/master/
    data/aranjuez.csv',
                  sep=',',
                  header=TRUE)
```

```
head(remoto)
```

```
          X TempAvg TempMax TempMin HumidAvg HumidMax WindAvg WindMax Rain Radiation
1 2004-01-01   4.044   10.71  -1.969     88.3     95.9   0.746   3.528    0     5.490
2 2004-01-02   5.777   11.52   1.247     83.3     98.5   1.078   6.880    0     6.537
3 2004-01-03   5.850   13.32   0.377     75.0     94.4   0.979   6.576    0     8.810
4 2004-01-04   4.408   15.59  -2.576     82.0     97.0   0.633   3.704    0     9.790
5 2004-01-05   3.081   14.58  -2.974     83.2     97.0   0.389   2.244    0    10.300
6 2004-01-06   2.304   11.83  -3.379     84.5     96.5   0.436   2.136    0     9.940
         ET
1 0.5352688
2 0.7710499
3 0.8361229
4 0.6861381
5 0.5152422
6 0.4886631
```

```
identical(dats, remoto)
```

```
[1] TRUE
```

Ejercicio

Dibuja una circunferencia

¿Qué código hay que emplear para dibujar una circunferencia de forma que todos los vectores implicados sean columnas de un `data.frame`?

Condiciones simples

```
x <- seq(-1, 1, .1)
x
```

```
 [1] -1.0 -0.9 -0.8 -0.7 -0.6 -0.5 -0.4 -0.3 -0.2 -0.1  0.0  0.1  0.2  0.3  0.4  0.5  0.6
[18]  0.7  0.8  0.9  1.0
```

```
x < 0
```

```
 [1]  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE FALSE FALSE FALSE FALSE
[15] FALSE FALSE FALSE FALSE FALSE FALSE FALSE
```

```
x >= 0
```

```
 [1] FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE  TRUE  TRUE  TRUE  TRUE
[15]  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE
```

```
x == 0
```

```
 [1] FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE  TRUE FALSE FALSE FALSE
[15] FALSE FALSE FALSE FALSE FALSE FALSE FALSE
```

```
x != 0
```

```
 [1]  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE FALSE  TRUE  TRUE  TRUE
[15]  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE
```

Condiciones múltiples

```
cond <- (x > 0) & (x < .5)
cond
```

```
[1] FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE  TRUE  TRUE  TRUE
[15]  TRUE FALSE FALSE FALSE FALSE FALSE FALSE
```

```
cond <- (x >= .5) | (x <= -.5)
cond
```

```
[1]  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE
[15] FALSE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE
```

Con las condiciones se pueden hacer operaciones

```
sum(cond)
```

```
[1] 12
```

```
sum(!cond)
```

```
[1] 9
```

```
as.numeric(cond)
```

```
[1] 1 1 1 1 1 1 0 0 0 0 0 0 0 0 0 1 1 1 1 1 1
```

Indexado numérico

```
x <- seq(1, 100, 2)
x
```

```
[1]  1  3  5  7  9 11 13 15 17 19 21 23 25 27 29 31 33 35 37 39 41 43 45 47 49 51 53 55 57
[30] 59 61 63 65 67 69 71 73 75 77 79 81 83 85 87 89 91 93 95 97 99
```

```
x[1:5]
```

```
[1] 1 3 5 7 9
```

```
x[10:5]
```

```
[1] 19 17 15 13 11  9
```

Indexado con condiciones lógicas

```
x[x != 9]
```

```
 [1]  1  3  5  7 11 13 15 17 19 21 23 25 27 29 31 33 35 37 39 41 43 45 47 49 51 53 55 57 59
[30] 61 63 65 67 69 71 73 75 77 79 81 83 85 87 89 91 93 95 97 99
```

```
x[x > 20]
```

```
 [1] 21 23 25 27 29 31 33 35 37 39 41 43 45 47 49 51 53 55 57 59 61 63 65 67 69 71 73 75 77
[30] 79 81 83 85 87 89 91 93 95 97 99
```

```
x[x %in% seq(0, 10, .5)]
```

```
[1] 1 3 5 7 9
```

Indexado con condiciones múltiples

```
z <- seq(-10, 10, by = .5)
z
```

```
 [1] -10.0  -9.5  -9.0  -8.5  -8.0  -7.5  -7.0  -6.5  -6.0  -5.5  -5.0  -4.5  -4.0  -3.5
[15]  -3.0  -2.5  -2.0  -1.5  -1.0  -0.5   0.0   0.5   1.0   1.5   2.0   2.5   3.0   3.5
[29]   4.0   4.5   5.0   5.5   6.0   6.5   7.0   7.5   8.0   8.5   9.0   9.5  10.0
```

```
z[z < -5 | z > 5]
```

```
 [1] -10.0  -9.5  -9.0  -8.5  -8.0  -7.5  -7.0  -6.5  -6.0  -5.5   5.5   6.0   6.5   7.0
[15]   7.5   8.0   8.5   9.0   9.5  10.0
```

```
cond <- (z >= 0 & z <= 5)
cond
```

```
 [1] FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE
[15] FALSE FALSE FALSE FALSE FALSE FALSE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE
[29]  TRUE  TRUE  TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE
```

```
z[cond]
```

```
 [1] 0.0 0.5 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0
```

Indexado de matrices

```
M[1:2, ]
```

```
  [,1] [,2] [,3] [,4] [,5] [,6] [,7] [,8] [,9] [,10]
x    1    2    3    4    5    6    7    8    9    10
y    1    2    3    4    5    6    7    8    9    10
```

```
M[1:2, 2:3]
```

```
  [,1] [,2]
x    2    3
y    2    3
```

```
M[1, c(1, 4)]
```

```
[1] 1 4
```

Indexado de matrices

```
M[-1,]
```

```
  [,1] [,2] [,3] [,4] [,5] [,6] [,7] [,8] [,9] [,10]
y    1    2    3    4    5    6    7    8    9    10
z    1    2    3    4    5    6    7    8    9    10
```

```
M[-c(1, 2),]
```

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

Podemos acceder a los elementos...

- Por su nombre

```
lista$a
```

```
[1] 1 3 5
```

- o por su índice

```
lista[1]
```

```
$a
[1] 1 3 5
```

```
lista[[1]]
```

```
[1] 1 3 5
```

Podemos acceder a los elementos

```
df <- data.frame(x = 1:5,
                 y = rnorm(10),
                 z = 0)
```

- Por su nombre (como una lista)

```
df$x
```

```
[1] 1 2 3 4 5 1 2 3 4 5
```

- Por su índice (como una matriz)

```
df[1,]
```

```
  x          y z
1 1 -0.3500724 0
```

```
df[,1]
```

```
[1] 1 2 3 4 5 1 2 3 4 5
```

Indexado lógico

- Hay que explicitar dos veces el `data.frame`:

```
df[df$y > 0,]
```

```
  x         y z
2 2 0.04632892 0
3 3 1.33865797 0
9 4 0.82965402 0
```

- La función `subset` simplifica el código:

```
subset(df, y > 0)
```

```
  x         y z
2 2 0.04632892 0
3 3 1.33865797 0
9 4 0.82965402 0
```

Uso de `with`

- Problema: el código con varias variables puede ser ilegible

```
df$x^2 + df$y^2
```

- La función `with` permite acceder a varias variables con una única llamada:

```
with(df, x^2 + y^2)
```

```
[1]  1.122551  4.002146 10.792005 16.493282 28.046680  1.218178  4.024233  9.028306
[9] 16.688326 27.881580
```

```
with(df, x[y > 0])
```

```
[1] 2 3 4
```

Componentes de una función

- Una función se define con `function`

```
name <- function(arg_1, arg_2, ...) expression
```

- Está compuesta por:
  - Nombre de la función (`name`)
  - Argumentos (`arg_1`, `arg_2`, `...`)
  - Cuerpo (`expression`): emplea los argumentos para generar un resultado

Argumentos: nombre y orden

Una función identifica sus argumentos por su nombre y por su orden (sin nombre)

```
eleva <- function(x, p)
{
   x ^ p
}
```

```
eleva(x = 1:10, p = 2)
```

```
[1]   1   4   9  16  25  36  49  64  81 100
```

```
eleva(1:10, p = 2)
```

```
[1]   1   4   9  16  25  36  49  64  81 100
```

```
eleva(p = 2, x = 1:10)
```

```
[1]   1   4   9  16  25  36  49  64  81 100
```

Argumentos: valores por defecto

- Se puede asignar un valor por defecto a los argumentos

```
eleva <- function(x, p = 2)
{
   x ^ p
}
```

```
eleva(1:10)
```

```
[1]   1   4   9  16  25  36  49  64  81 100
```

```
eleva(1:10, 2)
```

```
[1]   1   4   9  16  25  36  49  64  81 100
```

Argumentos sin nombre: . . .

```
pwrSum <- function(x, p, ...)
{
   sum(x ^ p, ...)
}
```

```
x <- 1:10
pwrSum(x, 2)
```

```
[1] 385
```

```
x <- c(1:5, NA, 6:9, NA, 10)
pwrSum(x, 2)
```

```
[1] NA
```

```
pwrSum(x, 2, na.rm=TRUE)
```

```
[1] 385
```

Podemos construir a partir de funciones

```
foo <- function(x, ...){
  mx <- mean(x, ...)
  medx <- median(x, ...)
  sdx <- sd(x, ...)
  c(mx, medx, sdx)
  }
```

```
foo(1:10)
```

```
[1] 5.50000 5.50000 3.02765
```

```
foo(rnorm(1e5))
```

```
[1] -0.0003060223  0.0015256563  0.9995854917
```

Ejercicio

Dibuja una circunferencia

Define una función de dos argumentos, `theta` (vector de ángulos) y `r` (radio), que entregue un `data.frame` de dos columnas, `x` e `y`, con las coordenadas del arco de circunferencia que corresponde a los argumentos de la función, y emplea esta función para dibujar una circunferencia completa.

Funciones en paquetes

- `R` proporciona un amplio conjunto de funciones predefinidas agrupadas en paquetes
  - Algunos paquetes vienen instalados y se cargan al empezar (*base*):

```
sessionInfo()
```

- Otros vienen instalados pero hay que cargarlos (*recommended*):

```
library(lattice)

packageDescription('lattice')
```

- Otros hay que instalarlos y después cargarlos (*contributed*):

```
install.packages('data.table')
```

```
library('data.table')
packageDescription('data.table')
```

La función apply

```
apply(M, 1, sum)
```

```
 x  y  z
55 55 55
```

```
rowSums(M)
```

```
 x  y  z
55 55 55
```

```
apply(M, 2, mean)
```

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

```
colMeans(M)
```

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

lapply y sapply

```
lista <- list(x = 1:10,
              y = seq(0, 10, 2),
              z = rnorm(30))
lapply(lista, sum)
```

```
$x
[1] 55

$y
[1] 30

$z
[1] -3.336446
```

```
sapply(lista, sum)
```

```
       x        y        z
55.000000 30.000000 -3.336446
```

Ejercicio

- Calcula la media de cada una de las columnas de `remoto`.
- Calcula la media, mediana y desviación estándar de cada una de las columnas de `remoto`.
- Calcula la media de los valores positivos de cada una de las columnas de `remoto`.

```
remoto <- read.csv('https://raw.githubusercontent.com/oscarperpinan/R/master/data/
    aranjuez.csv')
```

for

- En R suele usarse más la familia de funciones *apply con funciones vectorizadas.
- No obstante, for puede tener su utilidad:

```
for(n in c(2,5,10,20,50)) {
   x <- rnorm(n)
   cat(n,":", sum(x^2),"\n")
}
```

```
2 : 4.932688
5 : 2.157926
10 : 8.083215
20 : 25.41919
50 : 65.38123
```

if

- En R suele usarse más el indexado lógico (vectorizado).
- ¿Cuál es el equivalente a este bucle for-if?

```
x <- rnorm(10)
x2 <- numeric(length(x))
for (i in seq_along(x2)){
   if (x[i]<0) x2[i] <- 0 else x2[i] <- 1
   }
cbind(x, x2)
```

```
x x2
 [1,]  1.7627900  1
 [2,]  1.4448042  1
 [3,] -0.2972944  0
 [4,] -0.4727084  0
 [5,] -1.4427823  0
 [6,] -0.7957261  0
 [7,] -0.5507784  0
 [8,]  0.1496416  1
 [9,]  1.8065169  1
[10,] -0.5753609  0
```

ifelse

```
x <- rnorm(10)
x
```

```
[1]  0.6054286 -0.5163819 -1.2246463  0.5722188  1.4663268  0.5186201  1.1129771  0.1959783
 [9]  0.1385206 -1.0808002
```

```
ifelse(x>0, 1, 0)
```

```
[1] 1 0 0 1 1 1 1 1 1 0
```