

VNIVERSITAT [0%]  
DE VALÈNCIA Facultat d'Economia

POSTGRAU

MÁSTER  
EN CIENCIAS  
ACTUARIALES  
Y FINANCIERAS

**Estadística Avanzada para Actuarios**

**Introducción a R**



**R :un lenguaje de programación y un entorno para análisis estadístico .**

**Fue inicialmente escrito por Robert Gentleman y Ross Ihaka del Departamento de Estadística de la Universidad de Auckland en Nueva Zelanda.**

**R actualmente es el resultado de un esfuerzo de colaboración de personas del todo el mundo.**

**Ya que tiene la posibilidad de modificación directa del código fuente.**

**Por otra parte, R es un proyecto GNU similar a S, desarrollado éste por los Laboratorios Bell. Las diferencias entre R y S son importantes, pero la mayoría del código escrito para S corre bajo R sin modificaciones.**

La pagina principal del proyecto es

[http://www.r-project.org.](http://www.r-project.org)



En España

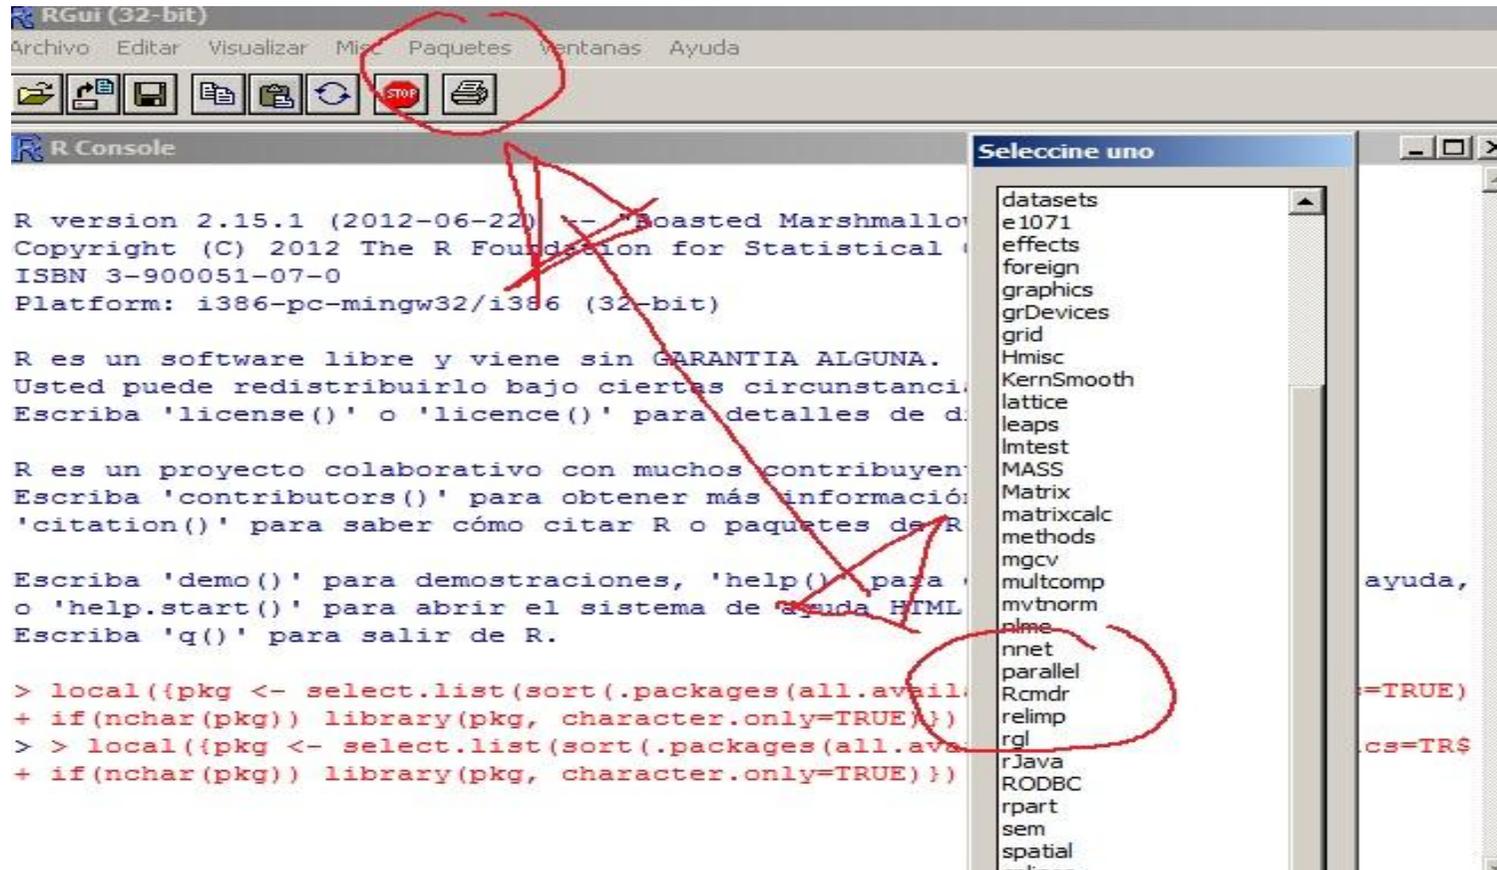
<http://cran.es.r-project.org/>

### Característica principal de R

Cualquier expresión evaluada por R tiene como resultado un objeto.

Cada objeto pertenece a una clase, de forma que las funciones pueden tener comportamientos diferentes en función de la clase a la que pertenece su objeto

## Instalar R- Commander



Luego se procede con la ejecución, siguiendo las instrucciones. Para la instalación de Rcmdr, se arranca R desde Inicio→Todos los programas→ R. A continuación, Paquetes→Instalar Paquete(s) y elegido el mirror desde el cual se quiere instalar el paquete, por ejemplo Spain (Madrid), se selecciona Rcmdr.

Si se cierra Rcmdr (sin cerrar R), para volver a cargarlo se debe ejecutar la instrucción `Commander()`.

---

## Los datos : Análisis Exploratorio de Datos

En una primera instancia , los datos se supondrán obtenidos sobre un conjunto de **n** individuos físicos, de los que se conoce una serie de **k** caracteres u observaciones de igual o distinta naturaleza

Los datos obtenidos se organizarán en una matriz **n × k**, donde cada fila representa a un individuo o registro y las columnas a las características observadas. Las columnas tendrán naturaleza homogénea, pudiendo tratarse de caracteres nominales, dicotómicos o politómicos, presencias–ausencias, ordenaciones, conteos, escalas de intervalo, razones,...ratios , densidades

Si se consideran los individuos identificados por los términos  $I_1, I_2, \dots, I_n$  y los caracteres por  $C_1, C_2, \dots, C_k$ , la casilla  $x_{ij}$  representa el comportamiento del individuo  $I_i$  respecto al carácter  $C_j$ .

Los huecos que queden en la matriz se referirán como valores omitidos o, más comunmente, como valores missing. En R estos valores se representan con **NA (Not Available)**. En función del tipo de análisis que se esté realizando, el procedimiento desestimaré sólo el dato o todo el registro completo.

### Tipos de datos/información y su “ aporte” informativo

# INFORMACIÓN



## Tipos de medidas y gráficos habituales según escala

Escala de Medida	Medidas centrales	Medidas de dispersión	Representaciones gráficas
Atributo	Moda Porcentajes		Diagrama de sectores
Ordenación	Mediana Percentiles	Recorrido Intercuartílico	Diagrama de barras
Recuento	Media	Desviación típica	Diagramas de barras
Intervalo	Media	Desviación típica	Histograma
Razón	Media geométrica	Coefficiente de variación	Histograma Diagrama de dispersión Diagrama de cajas

> 2+2	Escribimos 2+2 y damos enter
[1] 4	Sale el resultado. [1] indica que es el primer (y único resultado) de nuestra orden.
>	Al terminar el comando, el sistema vuelve a presentar su indicador.

## R como calculadora , funciones

> 2*5 [1] 10	Multiplicación de dos números
> 5/2 [1] 2.5	División real de dos números
> 5%/%2 [1] 2	División entera: se devuelve la parte entera solamente
> 5%%2 [1] 1	Módulo: resto de dividir un número por otro
> 11%%3 [1] 2	Otro ejemplo de la operación módulo
> 5^2 [1] 25	Potenciación
> 5^2.3 [1] 40.51641	Potenciación, exponente real
> exp(1) [1] 2.718282	El número e

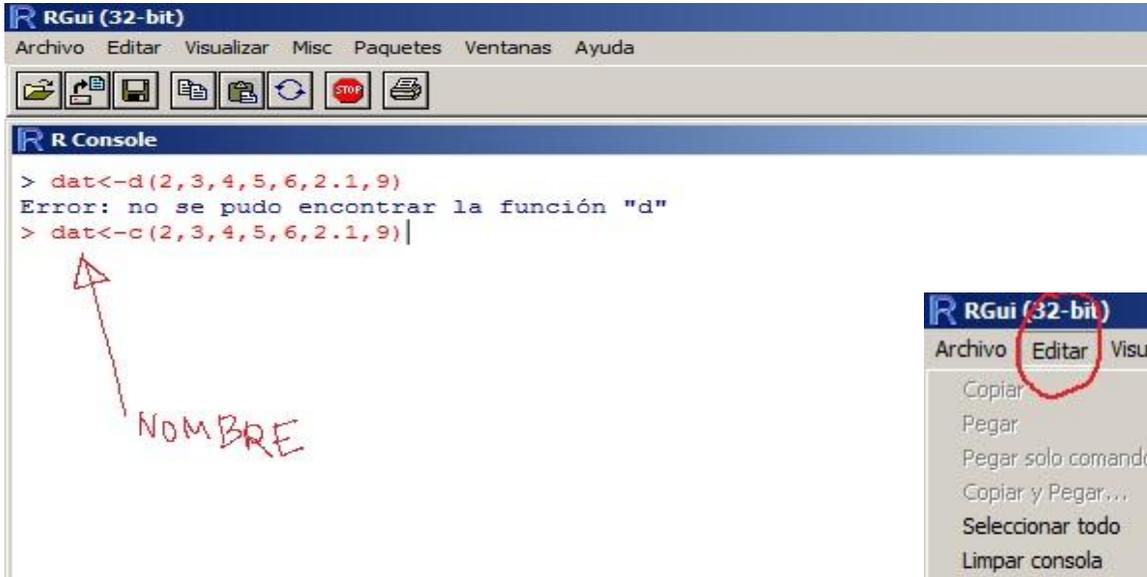
> <code>exp(3)</code> [1] 20.08554	El número $e^3$
> <code>sqrt(2)</code> [1] 1.414214	La raíz cuadrada de 2
> <code>log(3)</code> [1] 1.098612	El logaritmo neperiano de 3
> <code>log(3,10)</code> [1] 0.4771213	El logaritmo de 3 en base 10
> <code>abs(-3.4)</code> [1] 3.4	Valor absoluto de un número
> <code>pi</code> [1] 3.141593	El número pi

## R como calculadora , funciones

Más información con las funciones →

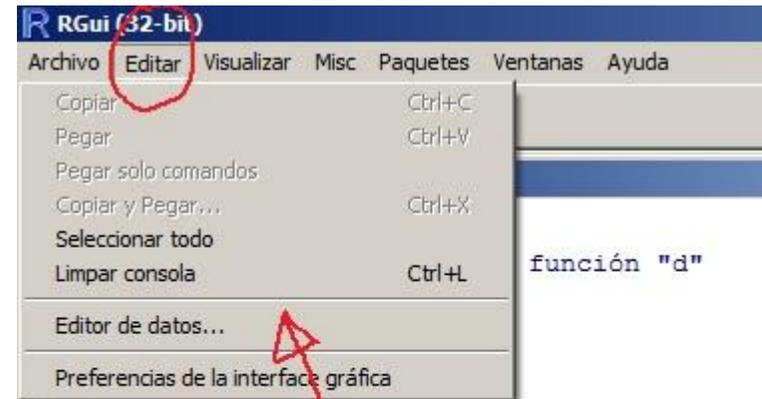
```
help("Math")
help("Arithmetic")
help("Trig")
help("Log")
help("Special")
```

## Introducir datos directamente una sola variable



```
> dat<-d(2,3,4,5,6,2.1,9)
Error: no se pudo encontrar la función "d"
> dat<-c(2,3,4,5,6,2.1,9)|
```

NOMBRE



Los datos se pueden modificar con el editor

Comprobar cambios con la función **mean(nombre)**

## Más de una variable , matrices

RGui (32-bit)  
 Archivo Editar Visualizar Misc Paquetes Ventanas Ayuda

R Console  
 > datos<-matrix(c(20,65,174,22,70,180,19,68,270),nrow=3,byrow=T)

*Función* → (pointing to 'matrix')

*índi* → (pointing to 'nrow=3' and 'byrow=T')

R Console  
 > datos<-matrix(c(20,65,174,22,70,180,19,68,170),nrow=3,byrow=T)  
 > datos  
 [,1] [,2] [,3]  
 [1,] 20 65 174  
 [2,] 22 70 180  
 [3,] 19 68 170  
 > dimnames(datos)<-list(c("antón","Juan","Alex"), # hola estoy aqui  
 + c("edad","peso","altura"))  
 > datos  
 edad peso altura  
 antón 20 65 174  
 Juan 22 70 180  
 Alex 19 68 170  
 > |

Función dimnames →

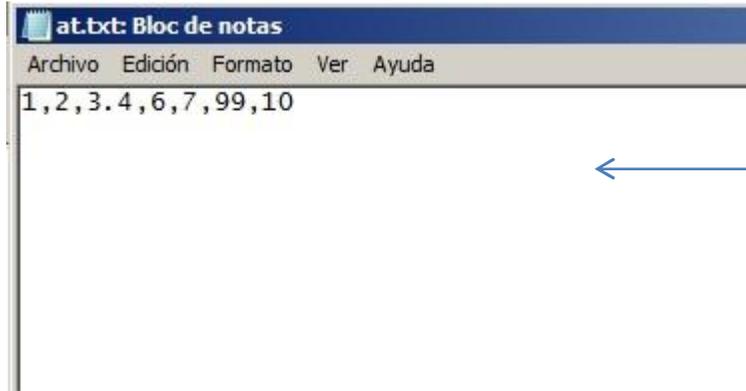
<b>data</b>	datos que forman la matriz
<b>nrow</b>	número de filas de la matriz
<b>ncol</b>	número de columnas de la matriz
<b>byrow</b>	Los datos se colocan por filas o por columnas según se van leyendo. Por defecto se colocan por columnas.

## Función SEQ , genera números

```
R Console
> seq(1,6)
[1] 1 2 3 4 5 6
> seq(1,6,by=0.5)
[1] 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0 5.5 6.0
> seq(1,6,length=10)
[1] 1.000000 1.555556 2.111111 2.666667 3.222222 3.777778 4.333333 4.888889
[9] 5.444444 6.000000
> |
```

Inserta datos desde la propia aplicación  
Y los guarda en “datos”

```
RGui (32-bit)
Archivo Editar Visualizar Misc Paquetes Ventanas Ayuda
[Icons: File Explorer, Print, Save, Copy, Paste, Refresh, Stop, Print]
R Console
> datos<-scan()
1: 3
2: 4
3: 56
4: 7
5:
Read 4 items
> mean(datos)
[1] 17.5
> |
```



Archivo de texto creado

Función y argumentos para utilizarlo

```
R Console  
> datos<-scan()  
1: 3  
2: 4  
3: 56  
4: 7  
5:  
Read 4 items  
> mean(datos)  
[1] 17.5  
> datos<-scan("c:\\datos\\at.txt", sep=",")  
Read 7 items  
> datos  
[1] 1.0 2.0 3.4 6.0 7.0 99.0 10.0  
> |
```

## Datos desde excel o archivo csv

	A	B	C	D	E
1	indi	a	b		
2	1	0,3	3		
3	2	0,4	4		
4	3	1	5		
5	4	1	4		
6	5	2	3		
7	6	1	4		
8	7	1	3		
9	8	1	4		
10	9	1	3		
11					
12					

← Hoja de excel guardar como csv

```
R Console
> data<-read.csv("c:/datos/dat1.csv",header=T, sep=";")
> data
  indi  a b
1    1 0,3 3
2    2 0,4 4
3    3  1 5
4    4  1 4
5    5  2 3
6    6  1 4
7    7  1 3
8    8  1 4
9    9  1 3
> |
```

**Función read.csv**

**header=T primera fila nombres**

**sep=";" el separador es ;**

## Insertar datos con txt

	indi	a	b
1	1	0,3	3
2	2	0,4	4
3	3	1	5
4	4	1	4
5	5	2	3
6	6	1	4
7	7	1	3
8	8	1	4
9	9	1	3

```

RGui (32-bit)
Archivo Editar Visualizar Misc Paquetes Ventanas Ayuda

R Console
> data<-read.table("c:/datos/dat1.txt",header=T, sep="")
> data
  indi  a b
1    1 0,3 3
2    2 0,4 4
3    3  1 5
4    4  1 4
5    5  2 3
6    6  1 4
7    7  1 3
8    8  1 4
9    9  1 3
> mean(data)
      indi      a      b
5.000000      NA 3.666667
Mensajes de aviso perdidos
1: mean(<data.frame>) is deprecated.
  Use colMeans() or sapply(*, mean) instead.
2: In mean.default(X[[2L]], ...) :
   argument is not numeric or logical: returning NA
>

```

Si calculamos las media observamos que la de la variable "a" no puede calcularse, por el problema de la coma

**solución :** `data<-read.table("c:/datos/dat1.txt",header=T, sep="", dec=",")`

dat2.txt: Bloc de notas

	indi	dia	número	
1		lunes	3	
2		lunes	4	
3		martes	5	
4		miercoles		4
5		jueves	3	
6		jueves	4	
7		lunes	3	
8		lunes	4	
9		viernes	3	

## Datos en txt, con atributos

Utilización de variable de una base de datos \$



Creación de tabla de contingencia

```
> data2<-read.table("c:/datos/dat2.txt",header=T, sep=" ", dec=",")
> data2
  indi      dia número
1    1    lunes     3
2    2    lunes     4
3    3   martes     5
4    4 miercoles     4
5    5   jueves     3
6    6   jueves     4
7    7    lunes     3
8    8    lunes     4
9    9   viernes     3
> mean(data2$número)
[1] 3.666667
> table(data2$dia, data2$número)

      3 4 5
jueves 1 1 0
lunes  2 2 0
martes 0 0 1
miercoles 0 1 0
viernes 1 0 0
> |
```

<code>cor</code>	Correlación (admite uno o dos argumentos)
<code>cumsum</code>	Suma cumulativa de un vector
<code>mean</code>	Media aritmética
<code>median</code>	El percentil 0.5: la mediana
<code>min</code>	El mínimo de una serie de números
<code>max</code>	El máximo de una serie de números
<code>prod</code>	El producto de los elementos de un vector
<code>quantile</code>	Los percentiles de una distribución
<code>range</code>	Mínimo y máximo de un vector
<code>sample</code>	Muestreo aleatorio (y permutaciones)
<code>sum</code>	Suma aritmética
<code>var</code>	Varianza y covarianza
<code>summary</code>	Resumen de estadísticas

Ejemplo , correlación a,b  
cuartiles de a



```
R Console
> data<-read.table("c:/datos/dat1.txt",header=T, sep="", dec=",")
> data
  indi  a b
1     1 0.3 3
2     2 0.4 4
3     3 1.0 5
4     4 1.0 4
5     5 2.0 3
6     6 1.0 4
7     7 1.0 3
8     8 1.0 4
9     9 1.0 3
> cor(data$a,data$b)
[1] -0.147442
> quantile(data)
Error en `[.data.frame`(x, order(x, na.last = na.last, decreasing = d
  undefined columns selected
> quantile(data$a)
  0%  25%  50%  75% 100%
0.3  1.0  1.0  1.0  2.0
> |
```

## Algunos ejemplos aplicación de funciones

```
R Console
> cumsum(data$a) #suma acumulativa
[1] 0.3 0.7 1.7 2.7 4.7 5.7 6.7 7.7 8.7
> quantile(data$a,probs=c(0.1,0.4,0.9)) #cuantiles ad-hoc
 10%  40%  90%
0.38 1.00 1.20
> sample(1:10,5,rep=T) # muestreo con repetición
[1] 8 4 4 4 9
> sample(1:100,5,rep=T) # muestreo con repetición
[1] 84 71 46 99 45
> sample(1:100,5)# sin repetición
[1] 92 58 85 90 61
> # PROBABILIDADES
> rnorm(1) # Generación de un dato de la normal estandar
[1] 0.8210304
> rnorm(5,mean=10,sd=3.4) # Generación de un dato de una normal no estandar
[1] 15.33650 17.44111 13.21422 16.74950 10.33399
> dnorm(0) # Evaluación de la función de densidad normal en el punto 0
[1] 0.3989423
> pnorm(0) # Probabilidad acumulada bajo la normal en el punto 0
[1] 0.5
> |
```

## Distribuciones de probabilidad

binom	Binomial
cauchy	Cauchy
chisq	Chi cuadrado
beta	Beta
exp	Exponencial
gamma	Gamma
geom	Geométrica
hyper	Hipergeométrica
lnorm	Log-normal
logis	Logística
nbinom	Binomial negativa
nchisq	Chi cuadrado no central
norm	Normal
pois	Poisson
signrank	Distribución del test de Wilcoxon de rangos con signo
t	Student
unif	Uniforme
weibull	Weibull
wilcox	Distribución de la suma de rangos de Wilcoxon

Trabajar con los prefijos : r= un dato,valor ; d= abcisa densidad; p=prob. acumulada;  
q=cuantiles

## Trabajar con matrices

<code>chol</code>	Descomposición de Cholesky
<code>crossprod</code>	Producto cruzado: <code>crossprod(x,y)</code> es lo mismo que <code>t(x) %*% y</code>
<code>diag</code>	Crea una matriz diagonal o extrae la diagonal de una matriz
<code>eigen</code>	Valores propios
<code>outer</code>	Producto exterior de dos vectores
<code>scale</code>	Escala las columnas de una matriz
<code>solve</code>	Resuelve sistemas de ecuaciones lineales y calcula la inversa
<code>svd</code>	Descomposición en valores singulaers
<code>qr</code>	Descomposición QR
<code>t</code>	Traspuesta

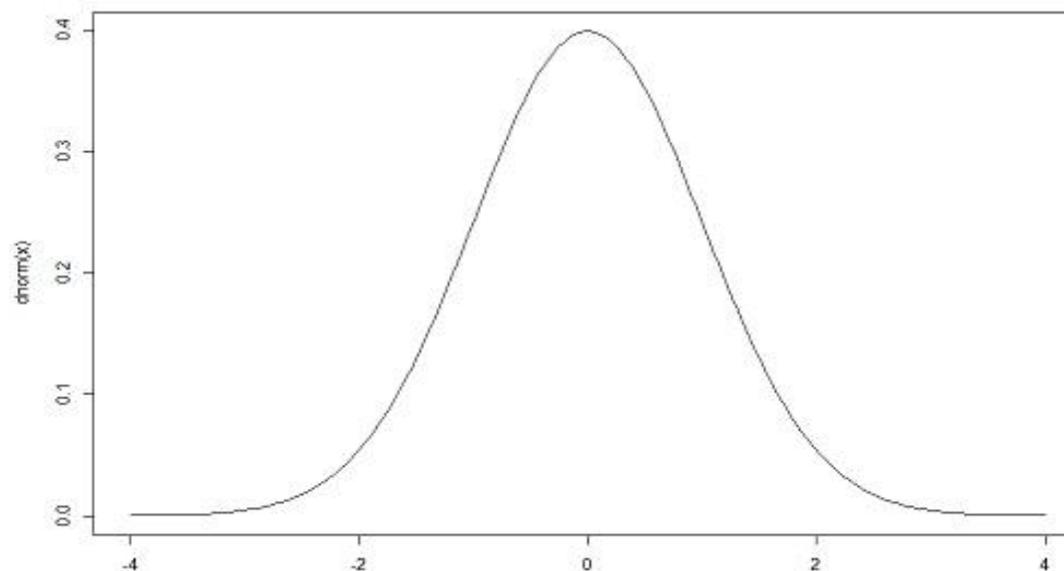
### Ejemplo

```
R Console
> A<-matrix(c(2,3,5,2),ncol=2,byrow=T)
> b<-c(8,9)
> solve(A,b)
[1] 1 2
> # ha resuelto el sistema 2x+3y=8 5x+2y=9
> |
```

## Gráficos demo("graphics")

### Gráficos , distribución Normal

`x<-seq(-4,4,length=200)` generamos 200 valores entre -4,4  
`plot(x,dnorm(x),type="l")` dibujamos



## Ejemplo de gráfico en avo.csv

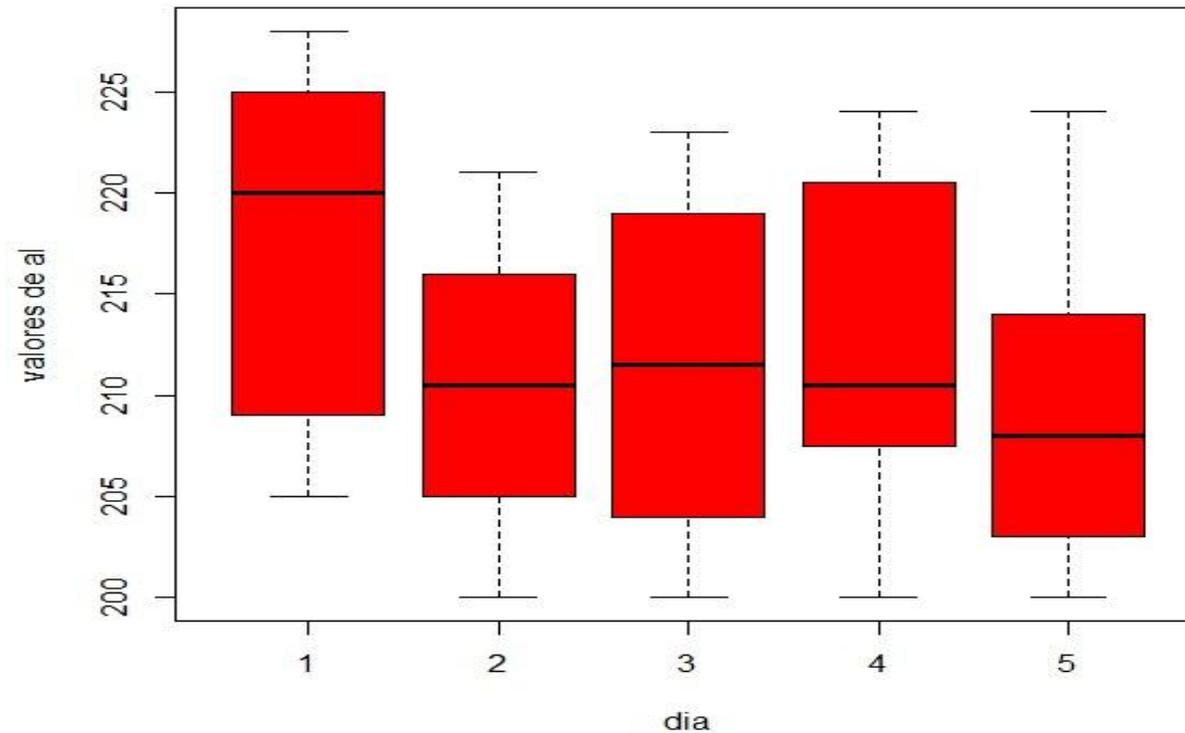


```
> data<-read.csv("c:/datos/avo.csv",header=T, sep=";")
```

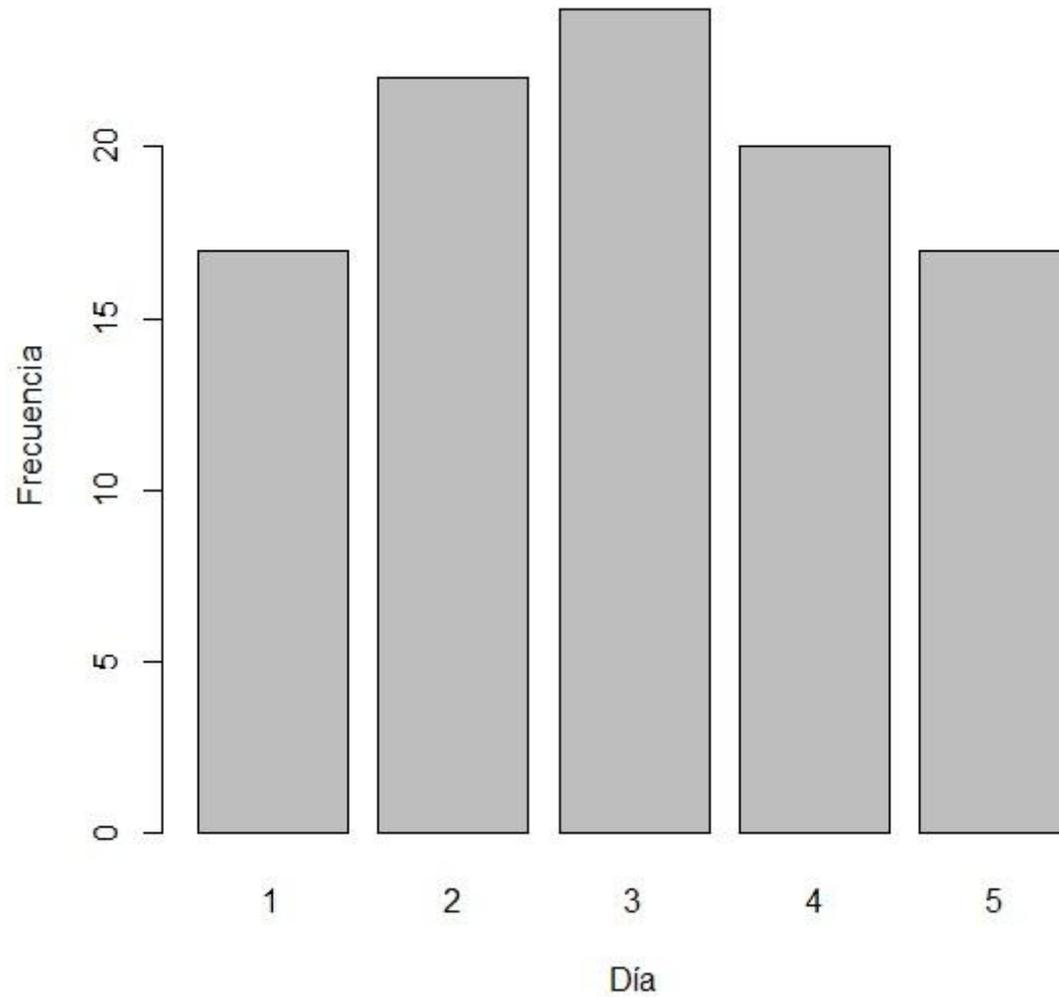
```
> data
```

	al	dia
1	221	1
2	228	1
3	209	1
4	209	1
5	220	1
6	228	1
7	205	1
8	228	1
9	206	1

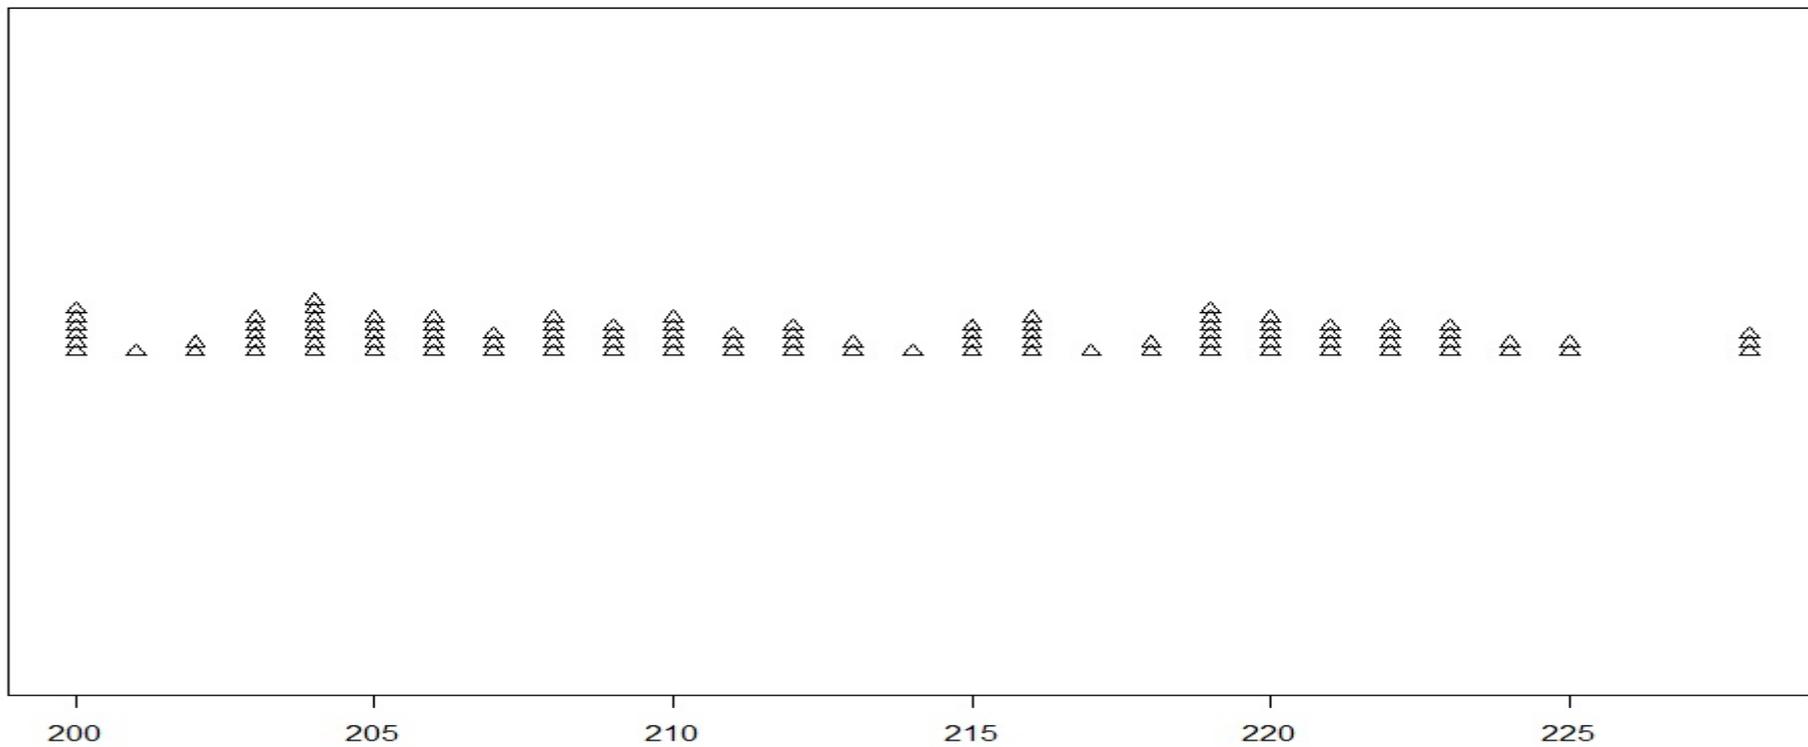
```
boxplot(al~dia, ylab="valores de al", xlab="dia",col="red" ,data=data)
```



```
barplot(table(data$dia), xlab="Día", ylab="Frecuencia")
```



```
stripchart(data$al, method = "stack", pch = 2)
```



```
RGui (32-bit) - [R Console]
Archivo Editar Visualizar Misc Paquetes Ventanas Ayuda
[Icons]
> z <- c(15, 25, 36, 40)
> z.nombres <- c("ni-nos", "jovenes", "maduros", "ancianos")
> pie(z, labels = z.nombres)
> |
```

## Diagrama de sectores

