Curso de R

Por
Pascal

UNIVERSIDAD COMPLUTENSE
MADRID

Grado en Ingeniería Informática
Facultad de Informática

Curso de R

Madrid, 2018–2019

Antes de empezar...

Sobre el curso

Este documento se ha realizado gracias a los cursos de **Universitat de les Illes Balears (UIB)** se agradece el conocimiento aportado.

Sobre la autoria

Se ha procedido a grabar la realización de todo el curso en LaTeX: https://drive.google.com/drive/folders/1eB_R1zuqLIMIbD7Jy0-sTREpGS2OJrwn?usp=sharing

Sobre TEFLON

Teflon(cc0 1.0(documentación) MIT(código))es una plantilla de LaTeX creada por David Pacios Izquierdo con fecha de Enero de 2018. Con atribuciones de uso CC0.

Esta plantilla fue desarrollada para facilitar la creación de documentación profesional para Trabajos de Fin de Grado o Trabajos de Fin de Máster. La versión usada es la 1.3.

V:1.3 Overleaf V2 with pdfLaTeX, margin 1in, NO-bib

Contacto
Autor: David Pacios Izquiero
Correo: dpacios@ucm.es
ASCII: asciifdi@gmail.com
Despacho 110 - Facultad de Informática

Índice general

Página

Capítulo 1

Instalación y uso básico de R y de RStudio

R realiza los cálculos y RStudio es el entorno donde se van a realizar esos cálculos. Primero explicaremos cómo instalar R y después como instalar Rstudio.

1.1. Instalación

1.1.1. Instalar R

Para instalar R primero nos dirigiremos a la web https://www.r-project.org/. Una vez que la hemos introducido en el buscador veremos lo siguiente:

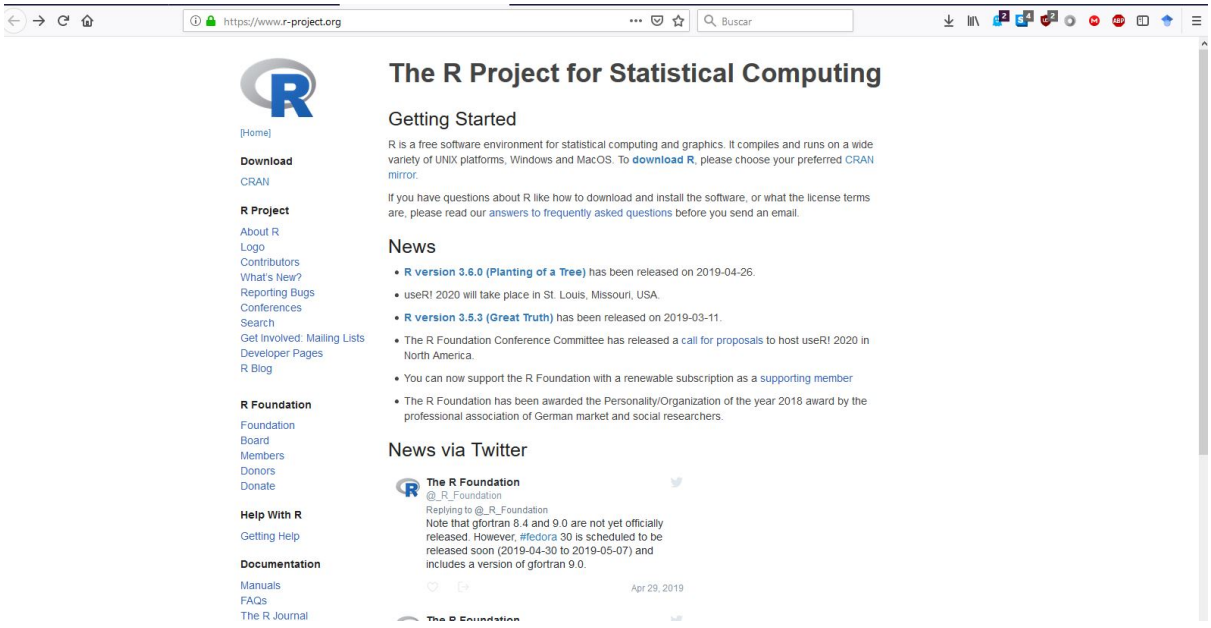

Figura 1.1: Página web RProyect

Una vez que estemos en la página seleccionaremos CRAN en la esquina superior izquierda, en Download. Cuando entremos, veremos muchas CRAN de muchos países, en nuestro caso buscaremos la de Spain, que es la siguiente:

Figura 1.2: CRAN de España

Seleccionamos cualquiera de las direcciones que vemos. Una vez seleccionadas, nos dejará instalar R en Linux, Mac o Windows. Cliqueamos el sistema operativo que tengamos y procederemos a la instalación.

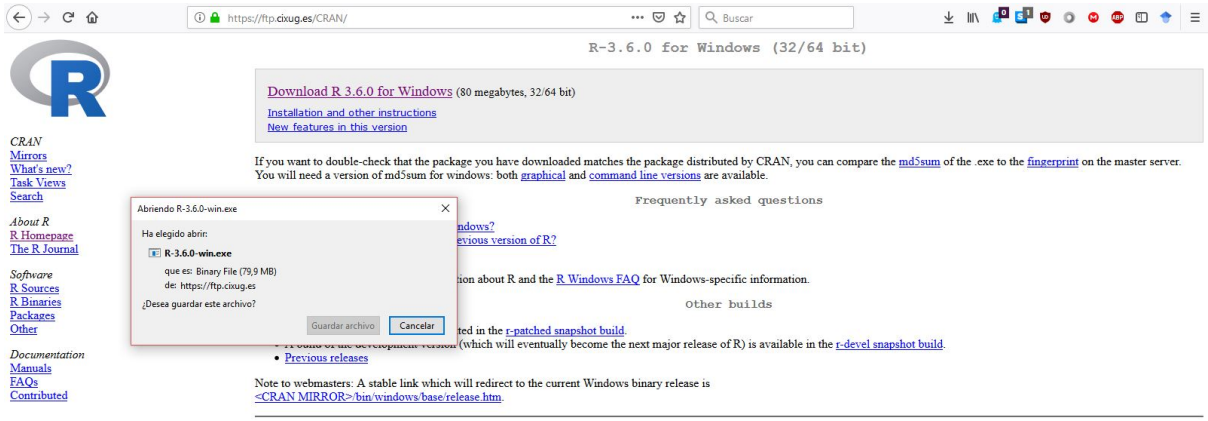

Figura 1.3: Instalación de R

Iniciamos la instalación y lo primero que nos pedirá será el idioma a utilizar durante la instalación.

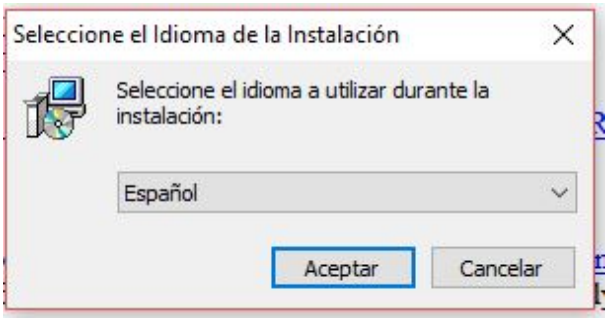

Figura 1.4: Idioma instalación R

Le damos a siguiente en el acuerdo de términos y condiciones, colocamos donde queremos instalar R.

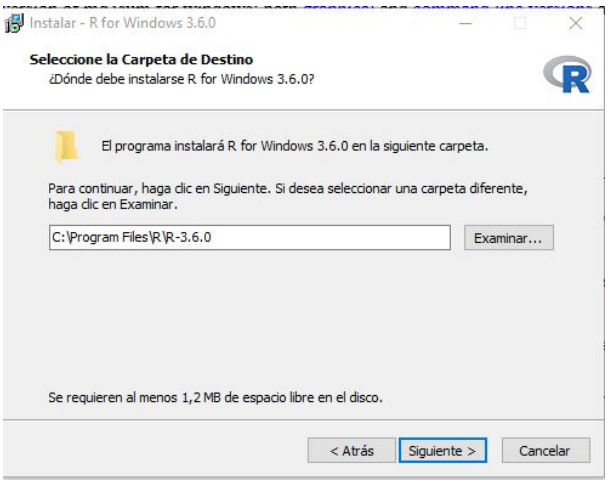

Figura 1.5: Localización de R

Seguidamente, seleccionamos que no deseamos utilizar las opciones de configuración y también seleccionamos las tareas adicionales.

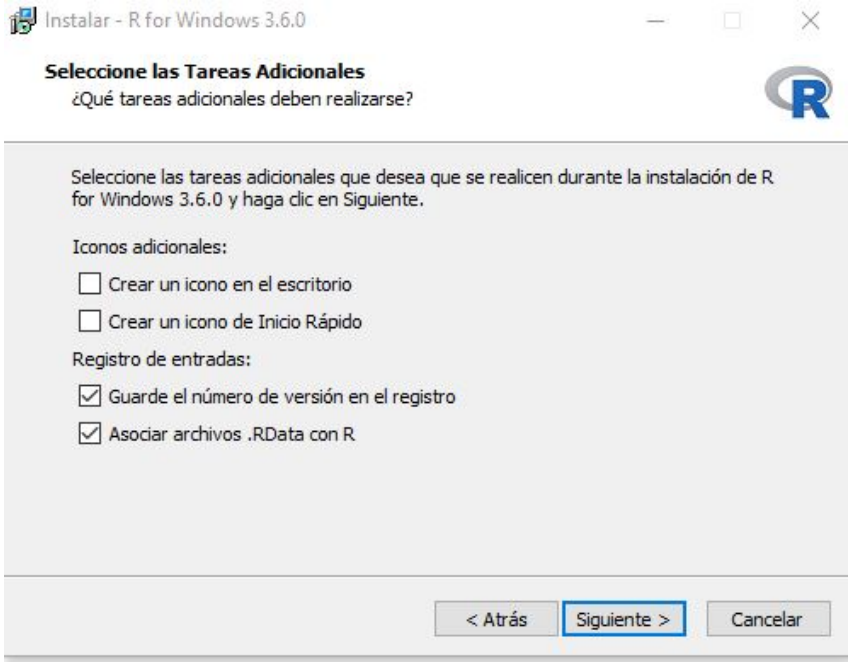

Figura 1.6: Tareas de R

Finalmente, seguimos dando a Siguiente hasta que nos permita instalarlo. El proceso tardará como máximo 2 minutos.

1.1.2. Instalación de RStudio

Como hemos dicho antes, RStudio es el entorno gráfico que nos permite utilizar de una manera más cómoda a R. Nos permite autocompletar el código, detectar errores en la sintaxis e incluye un sistema de menús de ayuda. Para instalarlo iremos a la web https://www.rstudio.com/, y una vez la pongamos en nuestro buscador veremos lo siguiente:

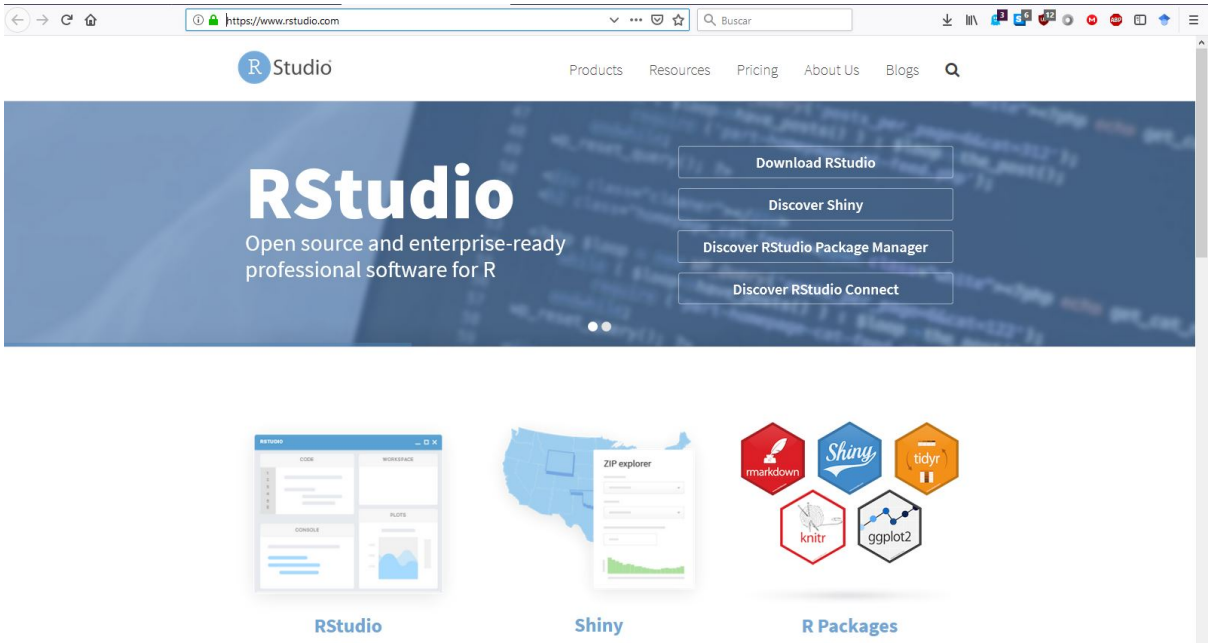

Figura 1.7: Web RStudio

Una vez dentro elegimos la opción de **Dowload Rstudio** y seleccionamos la versión RStudio Desktop, que es la versión gratuita.

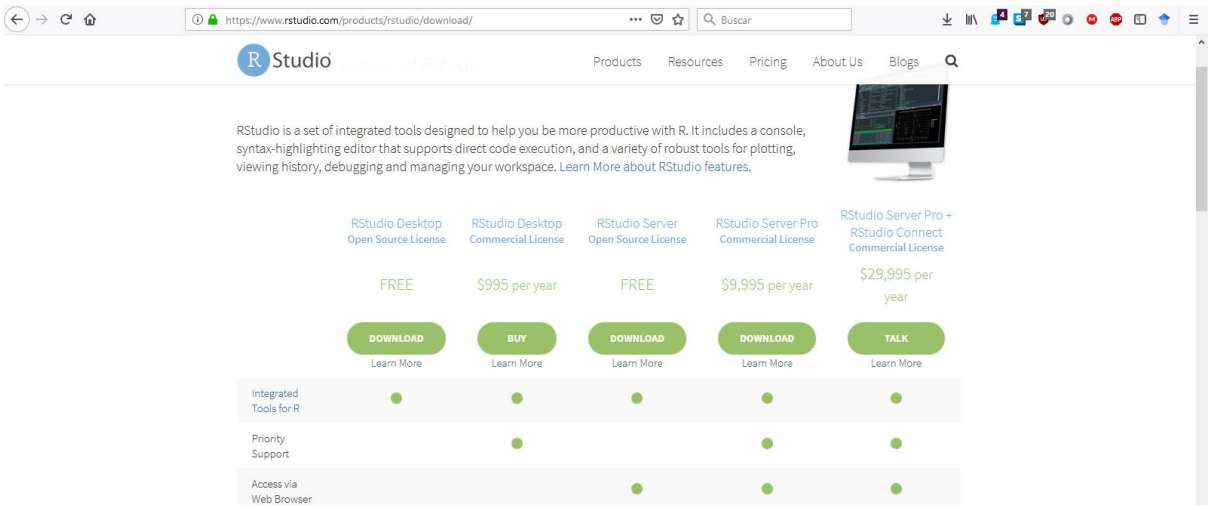

Figura 1.8: RStudio Desktop

La seleccionamos y nos dejará instalarla para las siguientes plataformas:

- Windows.
- Mac.
- Ubuntu.
- Fedora.
- Debian.

- OpenSUSE.
- SLES.

Installers for Supported Platforms

Installers	Size	Date	MD5
RStudio 1.2.1335 - Windows 7+ (64-bit)	126.9 MB	2019-04-08	d0e2470f1f8ef4cd35a669aa323a2136
RStudio 1.2.1335 - Mac OS X 10.12+ (64-bit)	121.1 MB	2019-04-08	6c570b0e2144583f7c48c284ce299eef
RStudio 1.2.1335 - Ubuntu 14/Debian 8 (64-bit)	92.2 MB	2019-04-08	c1b07d0511469abfe582919b183eee83
RStudio 1.2.1335 - Ubuntu 16 (64-bit)	99.3 MB	2019-04-08	c142d69c210257fb10d18c045fff13c7
RStudio 1.2.1335 - Ubuntu 18 (64-bit)	100.4 MB	2019-04-08	71a8d1990c0d97939804b46cfb0aea75
RStudio 1.2.1335 - Fedora 19+/RedHat 7+ (64-bit)	114.1 MB	2019-04-08	296b6ef88969a91297fab6545f256a7a
RStudio 1.2.1335 - Debian 9+ (64-bit)	100.6 MB	2019-04-08	1e32d4d6f6e216f086a81ca82ef65a91
RStudio 1.2.1335 - OpenSUSE 15+ (64-bit)	101.6 MB	2019-04-08	2795a63c7efd8e2aa2dae86ba09a81e5
RStudio 1.2.1335 - SLES/OpenSUSE 12+ (64-bit)	94.4 MB	2019-04-08	c65424b06ef6737279d982db9eefcae1

Figura 1.9: Plataformas disponibles

Hacemos una instalación como si fuera un programa normal, le vamos dando a Siguiente en todos los pasos hasta que se instale. Una vez instalado veremos lo siguiente:

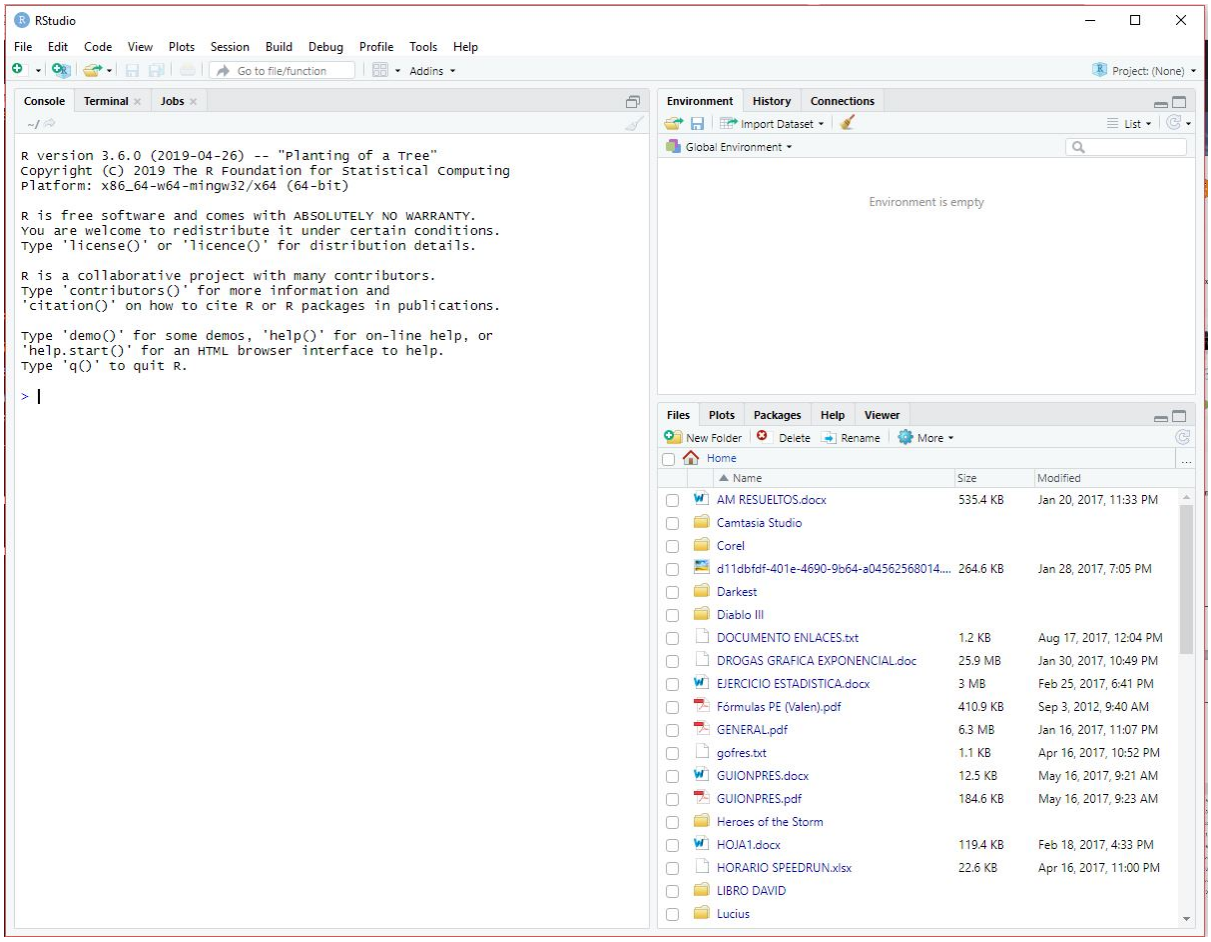

Figura 1.10: Interfaz RStudio

- A la izquierda está la consola donde se ejecutan los comandos R.
- A la derecha, en la parte superior tenemos una ventana que nos muestra nuestro entorno de trabajo, donde se verán las variables y funciones que se van cargando.
- A la derecha, en la parte inferior tenemos el directorio home donde R arranca por defecto. Esta ventana contiene varias pestañas:

  a). **Files**: Archivos en el directorio actual.

  b). **Plots**: Gráficos generados por el programa.

  c). **Packages**: Librerías instaladas.

  d). **Help**: Sistema de ayuda.

  e). **Viewer**: Contenido web local.

1.2. Paneles de RStudio

Tenemos tres paneles, el primer panel es la consola, donde daremos nombres a nuestras variables, el segundo es el editor donde guardaremos nuestros scripts y por último, tenemos el script que nos permite crear nuestro programa y guardarlo.

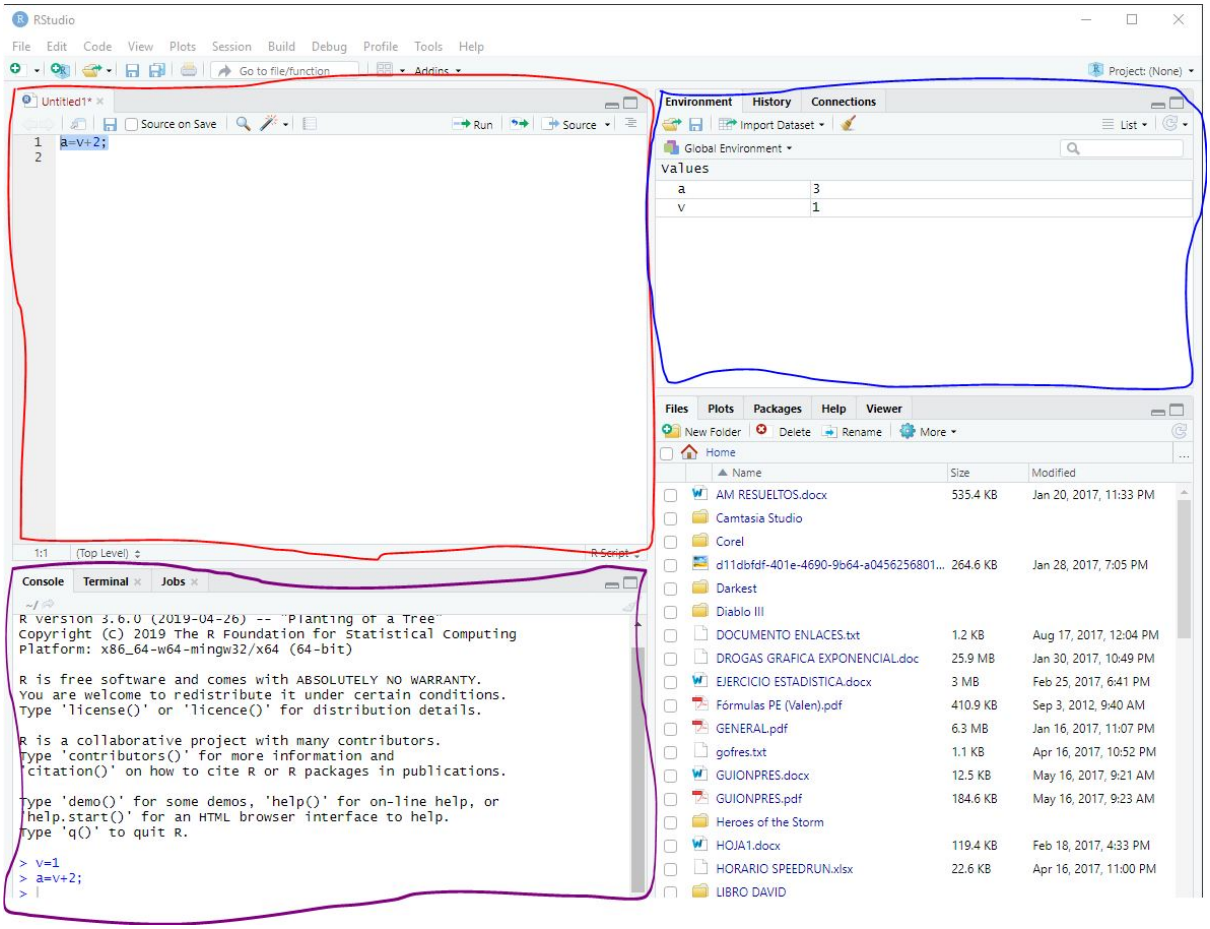

Figura 1.11: Paneles

En este caso, tendremos la Consola de color morado, el Entorno de color azul y el Editor de color rojo.
Además, en el Entorno podremos ver los valores de nuestras funciones, el historial de las funciones y volver a ejecutarlas.
Finalmente, tendremos en un cuarto panel la presentación de nuestros gráficos, los paquetes utilizados y la herramienta más importante, la ayuda donde podremos buscar los nombres de las distintas funciones por si se nos olvida algún nombre.

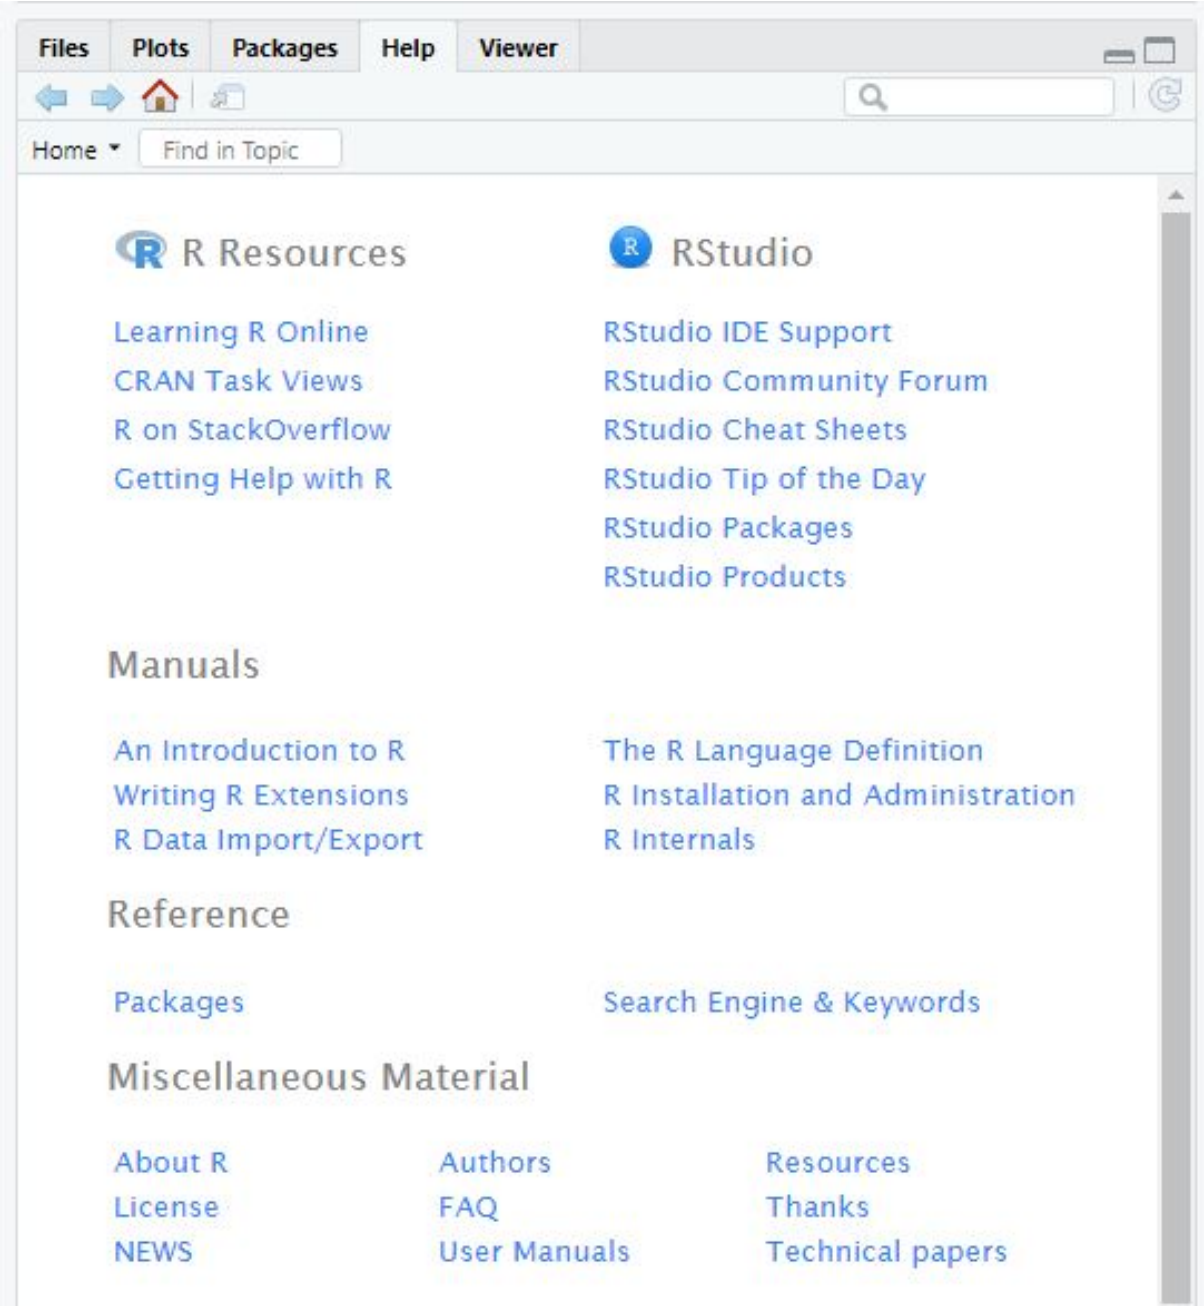

Figura 1.12: Pestaña ayuda

En la zona de búsqueda superior podremos buscar el nombre de la función directamente y en la zona inferior un tema o una palabra en concreto de alguna de las funciones.

1.3. Como guardar el trabajo

Para abrir el editor, vamos al icono superior izquierdo y seleccionamos nuevo Script.

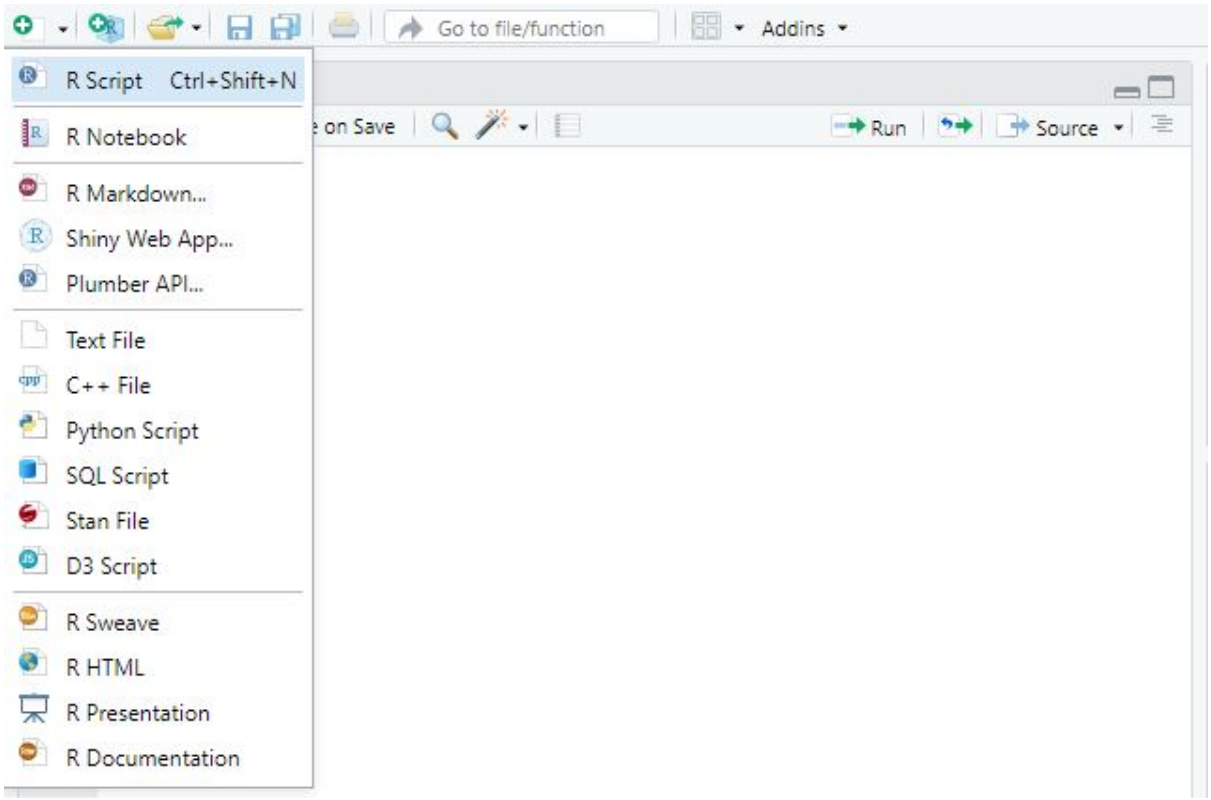

Figura 1.13: Editor RStudio

Vamos a poner un programa sencillo que nos haga la raíz cuadrada, para ello, vamos a poner mediante comentarios los distintos pasos que hacemos. Para ello, utilizamos la almohadilla (#), todo el texto que pongamos después de ella será comentado y no se ejecutará. El programa sencillo a ejecutar es el siguiente:

Listing 1.1: Código programa a ejecutar

```
#Guión para resolver ecuaciones de segundo grado

#Definición de variables
va=3
vb=2
vc=-2

#Cálculo de la primera raíz
r1=(-vb+sqrt(vb^2-4*va*vc))/(2*va)
```

Este programa lo veremos en el editor de la siguiente manera:

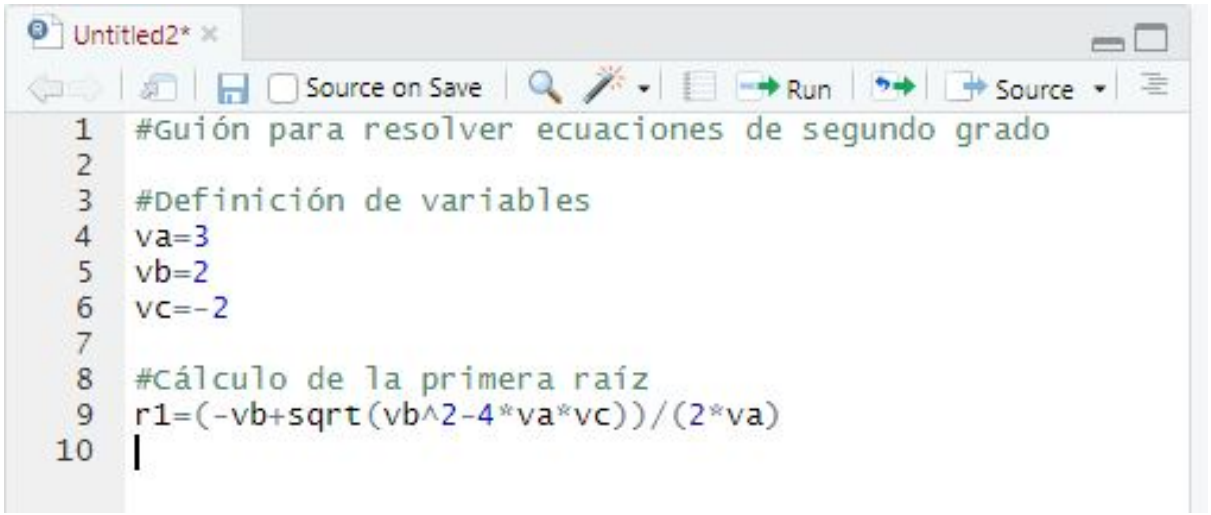

Figura 1.14: Programa sencillo a ejecutar

Tenemos varias opciones, darle al botón de Run para que se ejecute nuestro programa o podremos guardarlo seleccionando el icono del disco. Una vez seleccionado, como hay acentos en nuestro programa seleccionamos la codificación UTF-8, elegimos el nombre del archivo y nos lo guardará como un Programa.R.

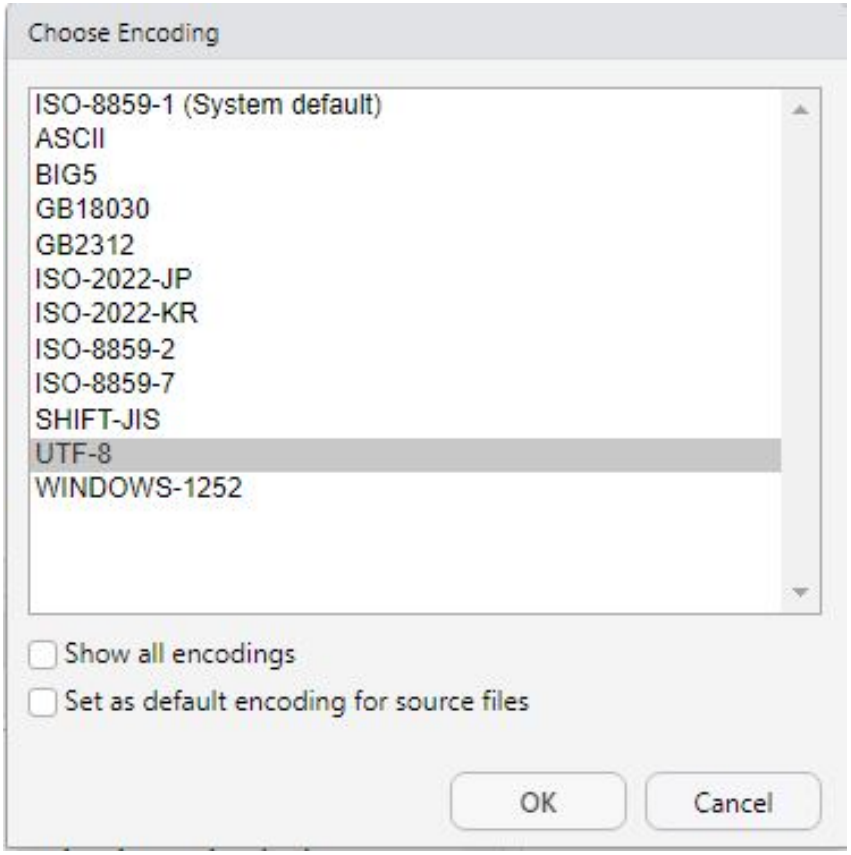

Figura 1.15: Codificación programa

Una vez que hemos guardado el programa, cuando volvamos a ejecutar RStudio nos encontraremos lo siguiente en el Editor:

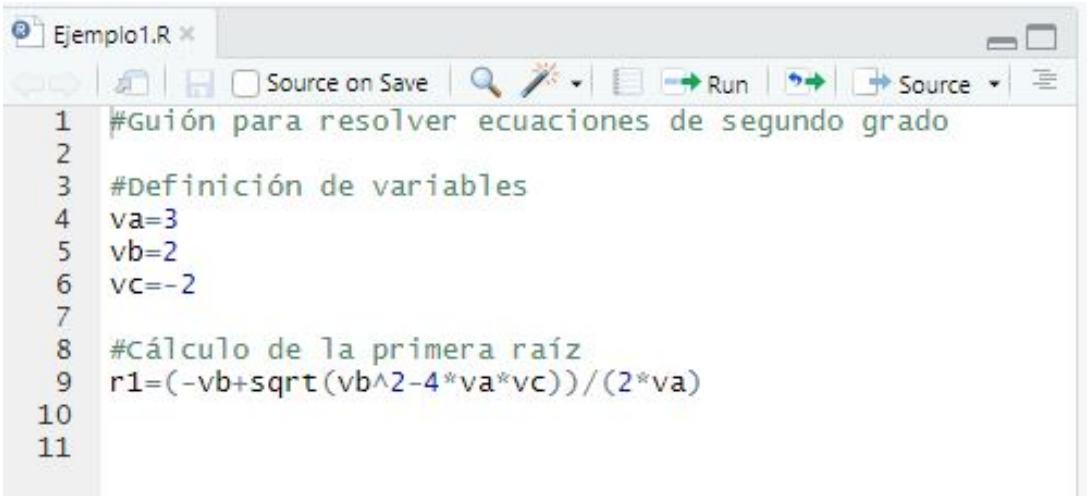

Figura 1.16: Nombre programa

Además, no solo nos permite salvar editor, también nos permite salvar las variables en el Workspace. Cuando salgamos del RStudio nos indicará si queremos salvar el Workspace, le damos que si y al volvernos a meter tendremos nuestras variables guardadas.

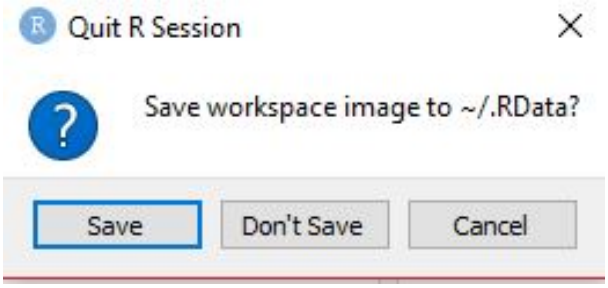

Figura 1.17: Salvar Workspace

En el caso del salvar el Workspace de este programa, al volver a entrar nos encontraremos lo siguiente:

Figura 1.18: Variables salvadas

1.4. Paquetes

Una de las mejoras características de R es que podemos ampliarlo mediante el uso de paquetes. En este capítulo vamos a ver como instalar y guardar paquetes.
Para instalarlo primero nos tendremos que bajar el paquete de algún repositorio y lo segundo que tendremos que hacer es cargar el paquete. Para cargar e instalar paquetes utilizaremos la pestaña superior derecha, con nombre Packages.

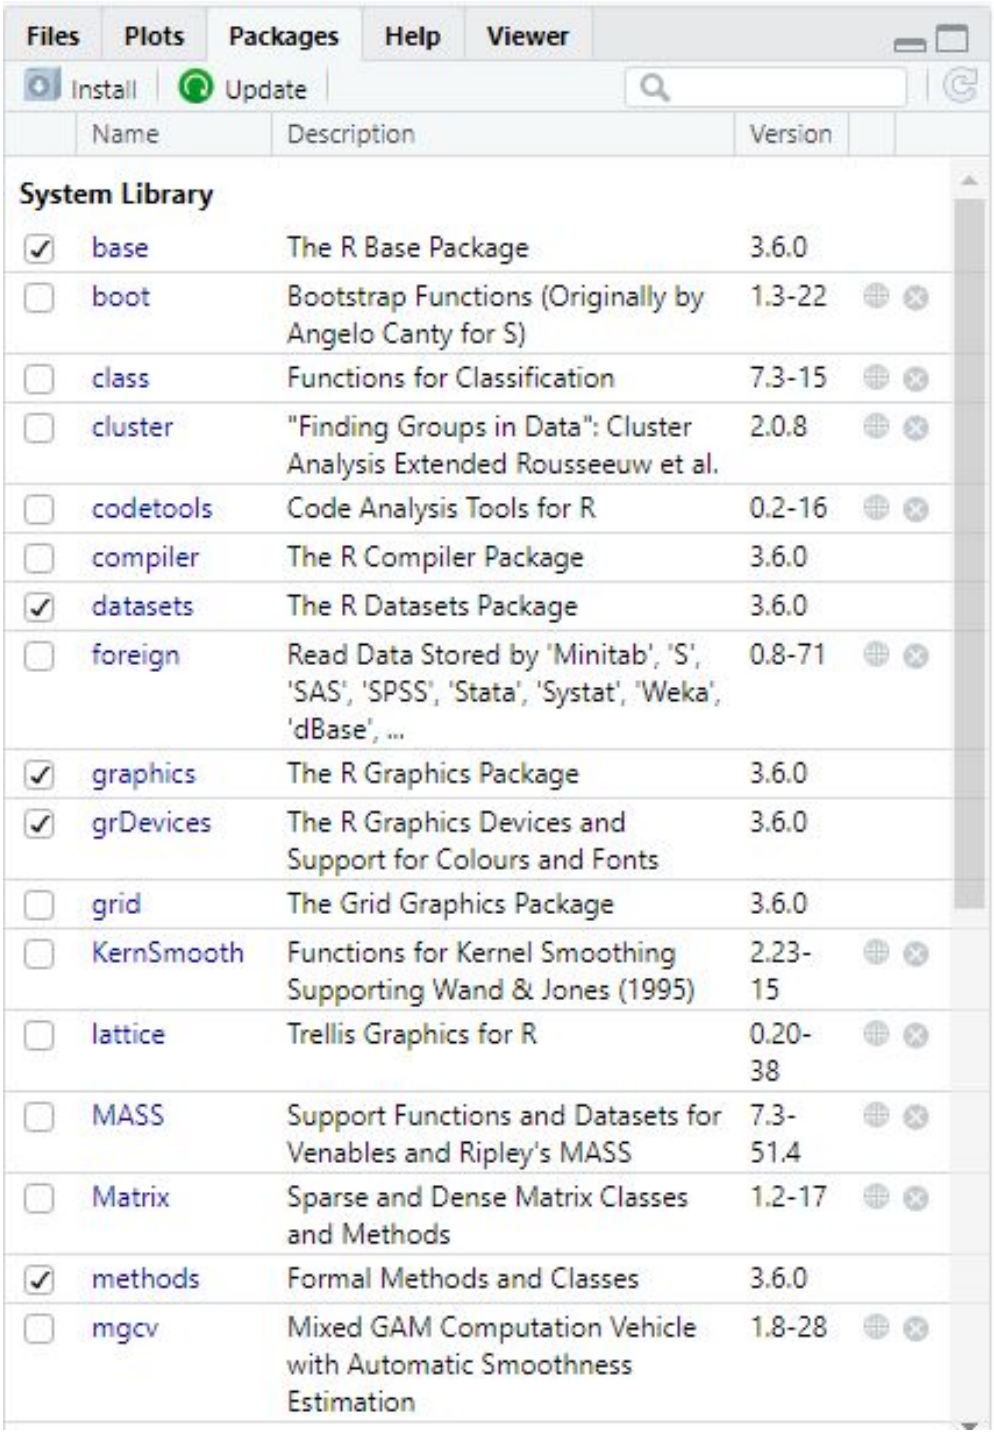

Figura 1.19: Paquetes pendientes de cargar

Por otro lado, hemos encontrado un paquete que nos interesa instalar. Este paquete se

llama fun y para descargarlo e instalarlo vamos a seguir los siguientes pasos:

- Selecciono Install.
- Le indico que busque en el repositorio CRAN.
- Le indico que intale todas las dependencias y que lo instale.

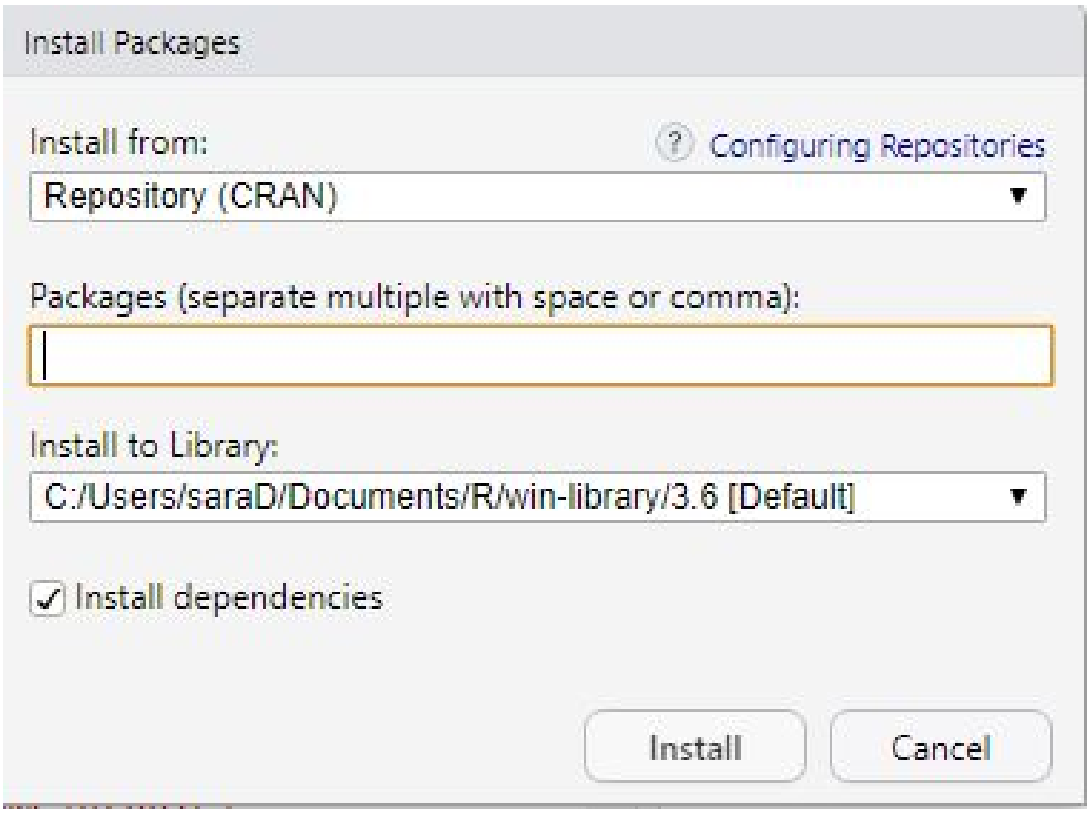

Figura 1.20: Instalar paquetes

Una vez hemos realizado estos pasos, se nos mostrará lo siguiente en la ventana de comandos y en la de los paquetes.

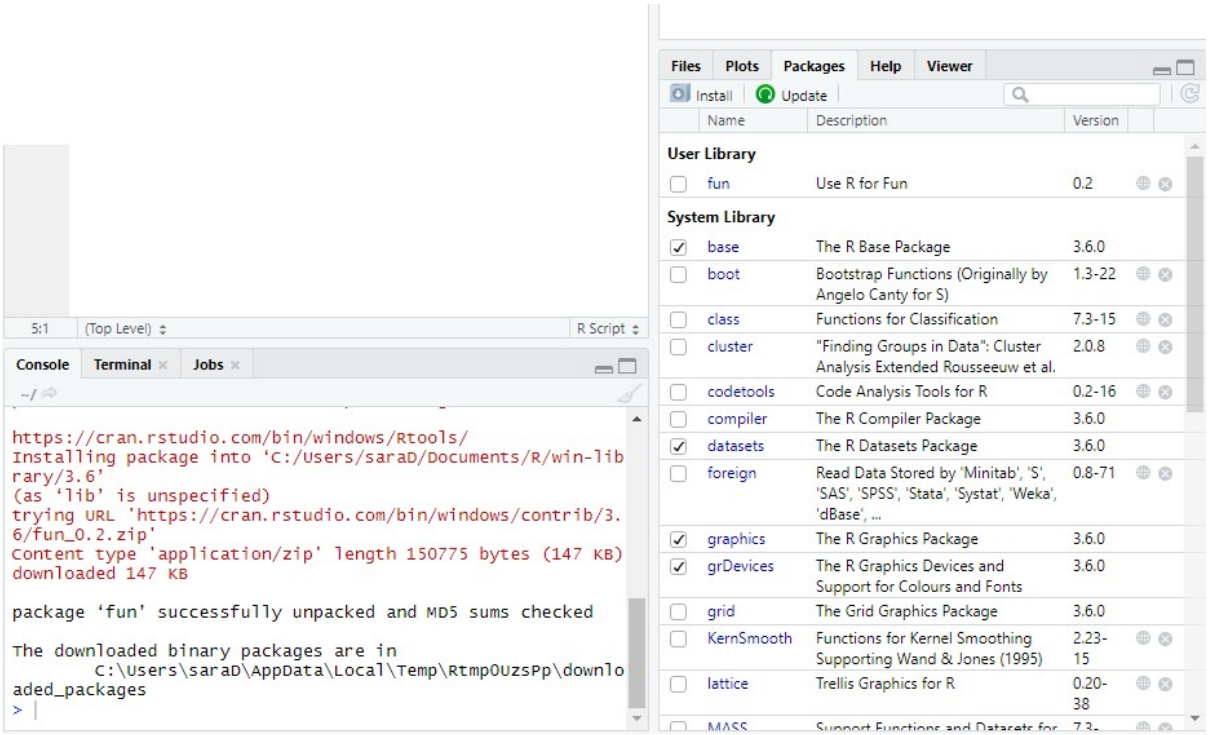

Figura 1.21: Instalar paquetes- Consola

Para cargar el paquete tenemos dos opciones, pinchar al cuadrado de los paquetes para que le ponga un tick o utilizar el comando library(¨Paquete a cargar¨), en nuestro caso sería el paquete fun.

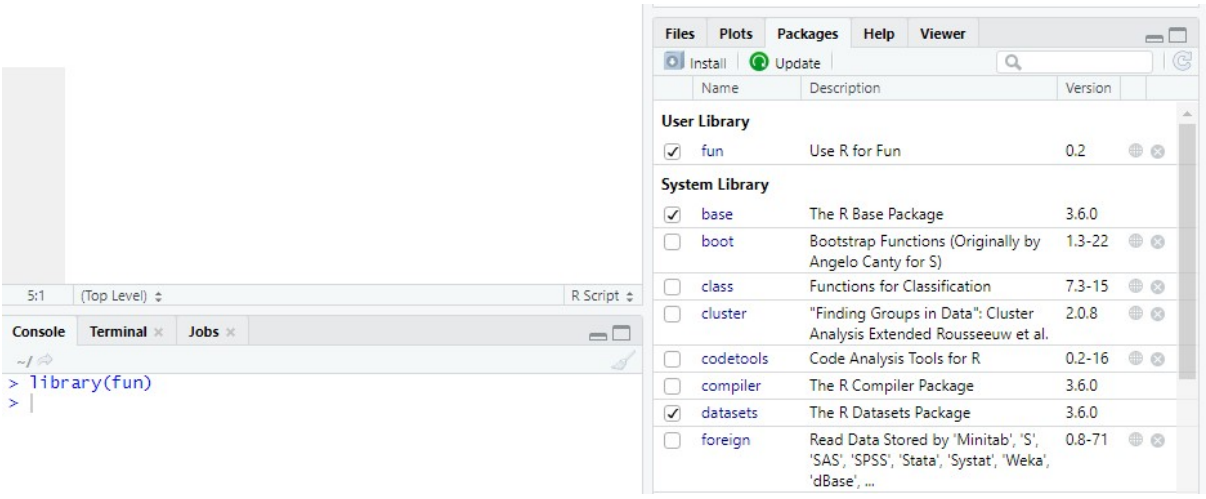

Figura 1.22: Paquete ya cargado

Finalmente, con esto tendremos ya instalado y cargado nuestro paquete, y podremos utilizar las funciones que tiene instaladas.

Capítulo 2

Matemáticas básicas

2.1. Operaciones y funciones reales básicas

Es importante recordar que podemos utilizar R como una calculadora, en ella podemos sumar resta y multiplicar. También es importante saber que los decimales se separan por puntos, no por comas. Una vez dicho esto, podemos realizar una suma muy simple en la ventana de comandos, para ello solo tenemos que poner la suma y darle a Enter y nos saldrá el resultado en la misma ventana de comandos.

Figura 2.1: Suma básica

Vista esta operación básica, vamos a poner en una tabla las operaciones con sus comandos:

Cuadro 2.1: Tabla de operaciones básicas con comandos

Operación	*Suma*	*Resta*	*Multiplicación*	*División*	*Potencia*	*Cociente entero*	*Resto*
Comando	+	-	*	/	^	%/%	%%

Para los paréntesis tenemos la misma prioridad que en las operaciones básicas vistas en otros cursos como en el caso de Octave. No es lo mismo una operación realizada con paréntesis que sin él, vamos a poner un ejemplo sencillo donde el paréntesis varía mucho el resultado de la operación:

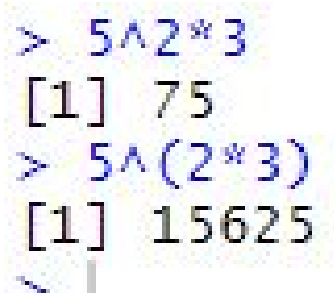

Figura 2.2: Operación con y sin paréntesis

Por otro el número pi se indica con el comando pi y se opera como un número más. Seguidamente, vamos a ver las funciones numéricas más comunes con su respectivo comando:

Cuadro 2.2: Funciones básicas

Función	**Comando**	**Función**	**Comando**
$\sqrt{x}$	sqrt	e^x	exp
$\ln(x)$	log	$\log_{10}(x)$	log10
$\log_a(x)$	log (,a)	$\sin(x)$	sin
$\cos(x)$	cos	$\tan(x)$	tan
$\arcsin(x)$	asin	$\arccos(x)$	acos
$\arctan(x)$	atan	$\lvert x \rvert$	abs
$n!$	factorial	$\binom{n}{m}$	choose

Vamos a ver algunos ejemplos de estas operaciones:

Listing 2.1: Código operaciones básicas

```
> 2+3
[1] 5
> 5^2*3
[1] 75
> 5^(2*3)
[1] 15625
> sqrt(2)
[1] 1.414214
> exp(2)
[1] 7.389056
> log10(100)
[1] 2
> log(100)
[1] 4.60517
> log(100,pi)
[1] 4.022932
> exp(1)
[1] 2.718282
```

También es muy importante tener en cuenta de que los argumentos de R en las funciones trigonométricas han de estar en radianes y los resultados de las funciones trigonométricas inversas también se dan en radianes. Por lo que, tendremos que tener en cuenta la relación entre grados y radiantes según lo que estemos operando.

Relación entre radianes y grados:

$$x \quad \text{grados} = \frac{x \cdot \pi}{180}\text{radianes}$$

$$x \quad \text{radianes} = \frac{180x}{\pi}\text{grados}$$

Finalmente, vamos a ver un ejemplo de cómo cambia realizar un coseno de 60 radianes respecto de 60º.

Listing 2.2: Código de operaciones en grados y radianes

```
> cos(60)
[1] -0.952413
> cos(60*pi/180)
[1] 0.5
```

2.2. Cifras significativas y redondeo

R utiliza la notificación científica para expresar números muy grandes o muy pequeños mediante la base 10 como podemos ver en el siguiente ejemplo:

Listing 2.3: Notación científica por defecto de R

```
> 2^50
[1] 1.1259e+15
> 2^(-50)
[1] 8.881784e-16
```

Si queremos conocer más cifras significativas de un número utilizaremos la función print(x,n), donde n son las cifras significativas que queremos mostrar. Vamos a ver un ejemplo con esta misma función:

Listing 2.4: Código para cifras significativas

```
> sqrt(5)
[1] 2.236068
> print(sqrt(5), 14)
[1] 2.2360679774998
```

IMPORTANTE: R sólo trabaja con 16 cifras significativas. Pedir que una función haga más de esta nos puede llevar a errores.
Por otro lado, para redondear un número a n cifras decimales utilizaremos la función round(x,n). Para ver cómo funciona vamos a poner un ejemplo:

Listing 2.5: Código función round

```
> round(exp(3),4)
[1] 20.0855
> round(exp(3),2)
[1] 20.09
> round(exp(3))
[1] 20
```

Si no le indicamos a cuántas cifras queremos redondear, redondeará al número entero más cercano.
Por otro lado, tenemos la función floor(x) que redondea a un entero por defecto, la función ceiling(x) que redondea a un entero por exceso y con la función trunc(x) que trunca el número a su parte entera. Vamos a ver un ejemplo redondeado el número pi de cada una de estas funciones para ver cómo varían:

Listing 2.6: Código funciones redondeo

```
> pi
[1] 3.141593
> round(pi)
[1] 3
> floor(pi)
[1] 3
> ceiling(pi)
[1] 4
> trunc(pi)
[1] 3
```

2.3. Definición de variables y funciones

Una variable es un objeto que sirve para guardar datos, y para asignarle un valor podemos utilizar lo siguiente:

- variable = valor.
- variable <- valor.
- valor -> variable.

Primero vamos a definir una variable, la llamaremos a y que sea igual a la $\sqrt{5}$. Como podemos ver en el momento de realizarla, R no nos da el valor, pero si indicamos el nombre de la variable nos mostrará su valor.

Listing 2.7: Código de definición de variable

```
> a=sqrt(5)
> a
[1] 2.236068
```

Una vez que hemos definido la variable podemos realizar todo tipo de operaciones con ella. Estas variables pueden cambiar de valor a lo largo de la sesión si las cambiamos el número, por ejemplo, vamos a cambiar el valor a esta variable y vamos a realizar una operación sencilla con esta:

Listing 2.8: Código de cambio de valor de variable

```
> a=sqrt(5)
> a
[1] 2.236068
> a=20
> a
[1] 20
> a/5
[1] 4
```

Seguidamente, para definir una función utilizaremos la construcción nombre de la función= function(variable){definición}. Como este proceso es muy abstracto vamos a definir una función sencilla:

Listing 2.9: Código de función sencilla

```
> f=function(a){a^pi}
> f(2)
[1] 8.824978
> f(a)
[1] 12226.62
```

No solo podremos definir una función de un solo valor, podremos definir más de una variable en la misma función separándola entre comas, por ejemplo, vamos a añadir una función g con dos variables:

Listing 2.10: Código de función de dos variables

```
> g=function(a,b){(a-b)^pi}
> g(5,2)
[1] 31.54428
> g(0,1)
[1] NaN
```

Como podemos ver nos ha devuelto un valor NaN, lo que significa que no existe un valor entero.
También podemos definir la misma función de dos maneras distintas separando las definiciones entre punto y coma, para verlo vamos a definir una función h:

Listing 2.11: Código de función con dos definiciones

```
> h=function(a){b=sqrt(a); g(a,b)}
> h(5)
[1] 24.38367
```

Posteriormente, los nombres de las variables y las funciones pueden contener letras, números, símbolos, pero es muy importante que comiencen con una letra o un punto. También se puede borrar algo de la memoria mediante el comando rm(), con este comando podremos borrar alguna variable o función que no nos guste.

Listing 2.12: Código borrar

```
> rm(f)
```

Una vez que hemos hecho todo este proceso nuestro entorno debería quedarnos así:

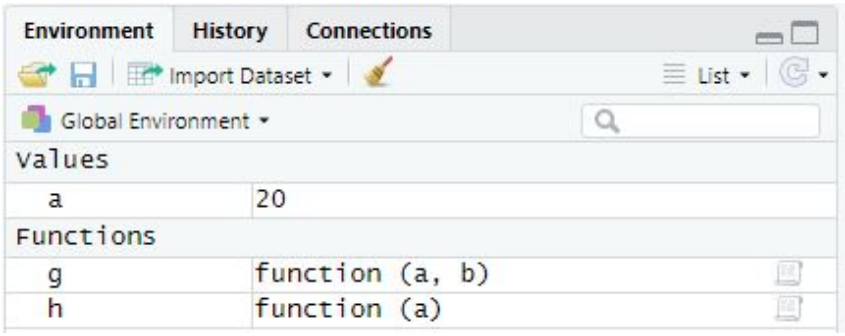

Figura 2.3: Entorno funciones

Y terminando, si queremos borrar todo el entorno sólo tendremos que pulsar el icono de la escoba y nos lo borrará.

2.4. Números complejos

Los números complejos se pueden escribir de dos formas, para ello tendremos que tener en mente la forma de los números complejos $a + bi$:

- Si b es racional escribiremos a+bi.
- En otros casos escribiremos complex(real=a, imaginary=b). Y declareremos un número real como complejo con la función as.complex.

Ahora vamos a proceder a ver cómo lo tendríamos que definir en R:

Listing 2.13: Códig números complejos

```
> 3+2.5i
[1] 3+2.5i
> 3+sqrt(2)i
Error: unexpected symbol in "3+sqrt(2)i"
> complex(real=3, imaginary=sqrt(2))
[1] 3+1.414214i
> sqrt(-4)
[1] NaN
Warning message:
In sqrt(-4) : NaNs produced
```

```
> z=as.complex(-4)
> sqrt(z)
[1] 0+2i
```

Con este tipo de números podremos utilizar las mismas operaciones y funciones básicas que con los números reales. Vamos a ver unos ejemplos de operaciones con números complejos:

Listing 2.14: Código operaciones números complejos

```
> (2+3i)*(5+1i)
[1] 7+17i
> (2+3i)/(5+1i)
[1] 0.5+0.5i
> sqrt(2+3i)
[1] 1.674149+0.895977i
> sqrt(2+3i)^2
[1] 2+3i
```

Aparte de las funciones que tienen en común con los números reales, los números complejos tienen unas funciones específicas y son las siguientes:

$$z = a + bi$$

- Parte real e imaginar: Funciones Re e Im.
- Conjugado: Función Conj.
- Módulo: Función Mod.
- Argumento: Función Arg

Con estas funciones estamos representando lo siguiente:

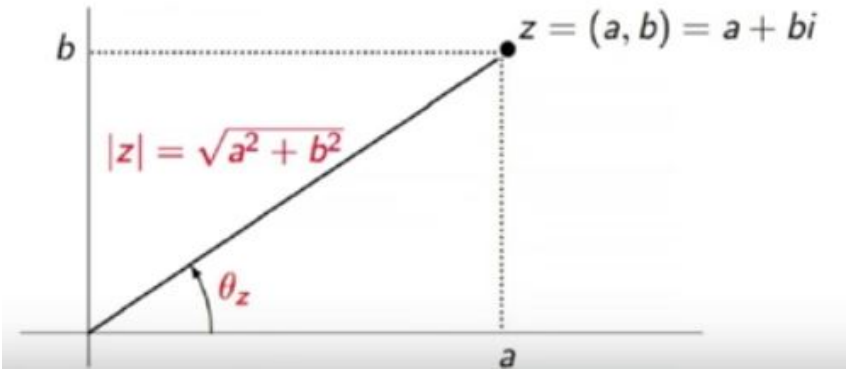

Figura 2.4: Funciones números complejos

Vamos a ver un ejemplo donde se calcule el conjugado, el módulo y el argumento de un número complejo:

Listing 2.15: Código del conjugado, módulo y argumento del número complejo

```
> z=2+3i
> Conj(z)
[1] 2-3i
> Mod(z)
[1] 3.605551
> Arg(z)
[1] 0.9827937
```

Es importante indicar que el argumento está en radianes, por lo que si queremos transformarlo a grados hay que seguir la transformación expuesta arriba.

Capítulo 3

Representación gráfica y lectura de datos

3.1. Data frames y plots

En este capítulo vamos a ver la representación estadística de una serie de puntos a través de una recta. Para ello, primero vamos a recoger los datos.

Listing 3.1: Código de recogida de datos en vectores

```
> edad=c(1,2,3,5,7,9,11,13)
> altura=c
   (76.11,86.45,95.27,109.18,122.03,133.73,143.73,156.41)
```

Como son muchos datos, vamos a crear una tabla de datos, que en R es un data frame. Vamos a ver su estructura:

Listing 3.2: Código data.frame

```
> datos1=data.frame(edad,altura)
> datos1
  edad  altura
1    1   76.11
2    2   86.45
3    3   95.27
4    5  109.18
5    7  122.03
6    9  133.73
7   11  143.73
8   13  156.41
```

Como podemos ver la primera columna corresponde con la edad y la segunda columna corresponde a la altura. Podremos utilizar el símbolo $ para acceder a los datos de una columna.

Listing 3.3: Código acceso datos columna edad

```
> datos1$edad
[1]  1  2  3  5  7  9 11 13
```

Ahora vamos a dibujar estos puntos, para ello vamos a utilizar el comando plot(x,y). Es importante que x e y sean vectores de la misma longitud.

Listing 3.4: Código dibujar gráficas

```
> plot(datos1$edad, datos1$altura)
> plot(datos1)
```

Una vez hemos escrito cualquiera de los dos códigos veremos la siguiente gráfica:

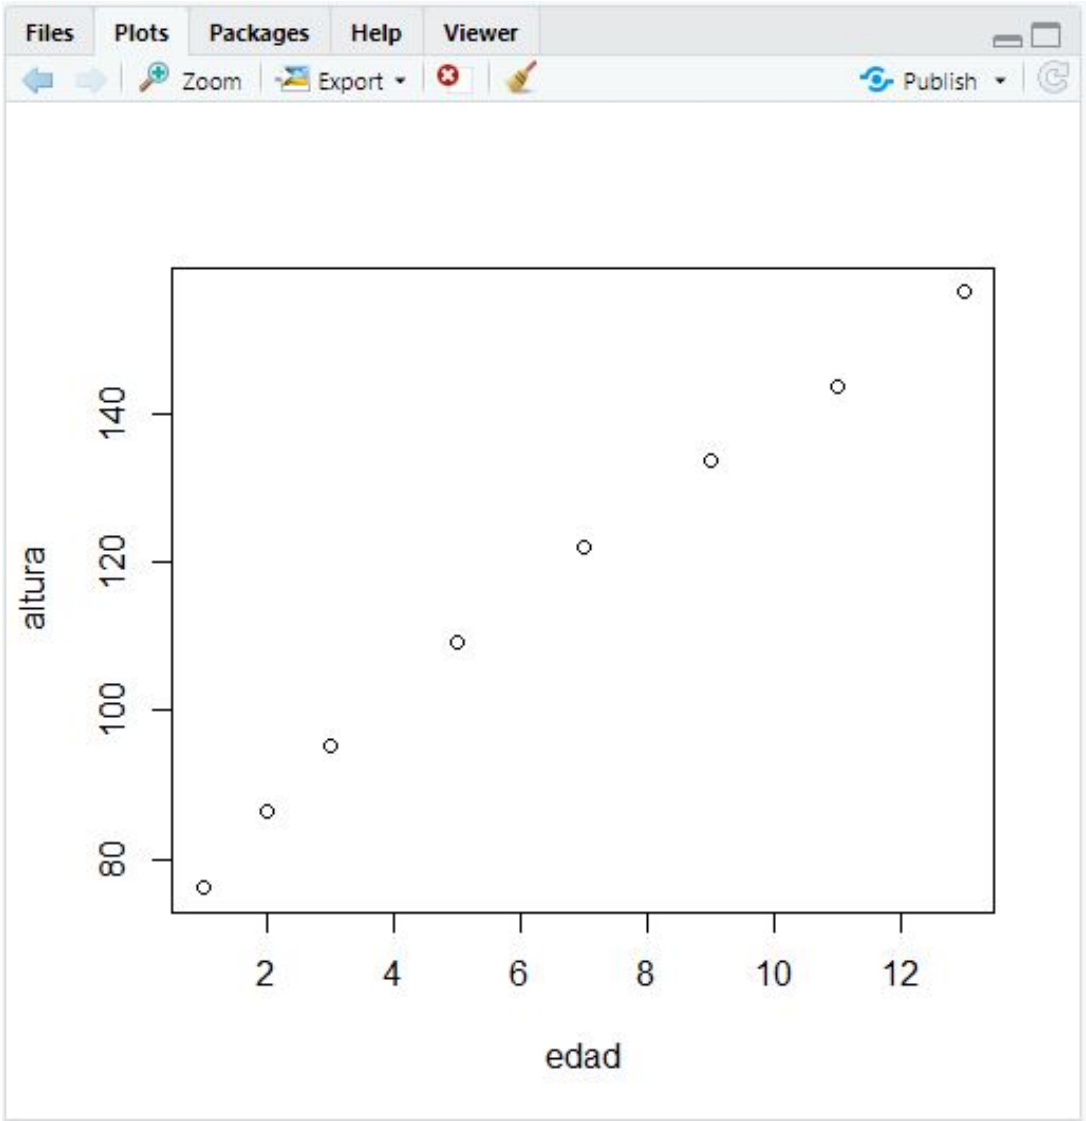

Figura 3.1: Representación gráfica

3.2. Regresión lineal

La recta de regresión es una recta que es la que mejor se adapta a los puntos. En este capítulo vamos a ver cómo se calcula y se realiza una recta de regresión.
Para calcular la recta de regresión utilizamos el comando lm(), que se utiliza para los métodos lineales. Para poder utilizarla haremos lm(y~x), la tilde significa en función de, por lo que en este caso estaríamos indicando que realice una recta de regresión de la variable y en función de la variable x. Para tenerlo más claro, vamos a hacer el método lineal del ejemplo anterior:

Listing 3.5: Código método lineal

```
> edad=c(1,2,3,5,7,9,11,13)
> altura=c
   (76.11,86.45,95.27,109.18,122.03,133.73,143.73,156.41)
> datos1=data.frame(edad,altura)
> plot(datos1)
> regr_edad_altura=lm(altura~edad, data=datos1)
> lm(altura~edad, data=datos1)

Call:
lm(formula = altura ~ edad, data = datos1)

Coefficients:
(Intercept)         edad
     73.968        6.493
```

En este caso nos está dando el valor de los coeficientes y con el intercept el valor de la ordenada en el origen. Si queremos más información sobre este resultado sólo tenemos que ejecutar el comando summary(variable) sobre la variable. En este caso nos daría los siguiente:

Listing 3.6: Código summary

```
> summary(regr_edad_altura)

Call:
lm(formula = altura ~ edad, data = datos1)

Residuals:
    Min      1Q  Median      3Q     Max
-4.351  -1.743   0.408   2.018   2.745

Coefficients:
             Estimate Std. Error t value
(Intercept)  73.9681     1.7979   41.14
edad          6.4934     0.2374   27.36
             Pr(>|t|)
(Intercept) 1.38e-08 ***
```

```
edad         1.58e-07 ***
---
Signif. codes:
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2.746 on 6 degrees of freedom
Multiple R-squared:  0.992,     Adjusted R-squared:  0.9907
F-statistic: 748.4 on 1 and 6 DF,  p-value: 1.577e-07
```

En Coefficients podemos ver los distintos valores que toman la ordenada en el origen y la pendiente, y el Multiple R-squared es el coeficiente de ordenación R^2.
Finalmente, vamos a dibujar la recta de regresión sobre la gráfica que ya tenemos. Para ello, vamos a utilizar el comando abline(variable) que dibuja rectas.

Listing 3.7: Código cálculo recta de regresión completo

```
> edad=c(1,2,3,5,7,9,11,13)
> altura=c
   (76.11,86.45,95.27,109.18,122.03,133.73,143.73,156.41)
> datos1=data.frame(edad,altura)
> plot(datos1)
> regr_edad_altura=lm(altura~edad, data=datos1)
> lm(altura~edad, data=datos1)
> abline(regr_edad_altura, col="red")
```

Con este código obtendremos la siguiente gráfica:

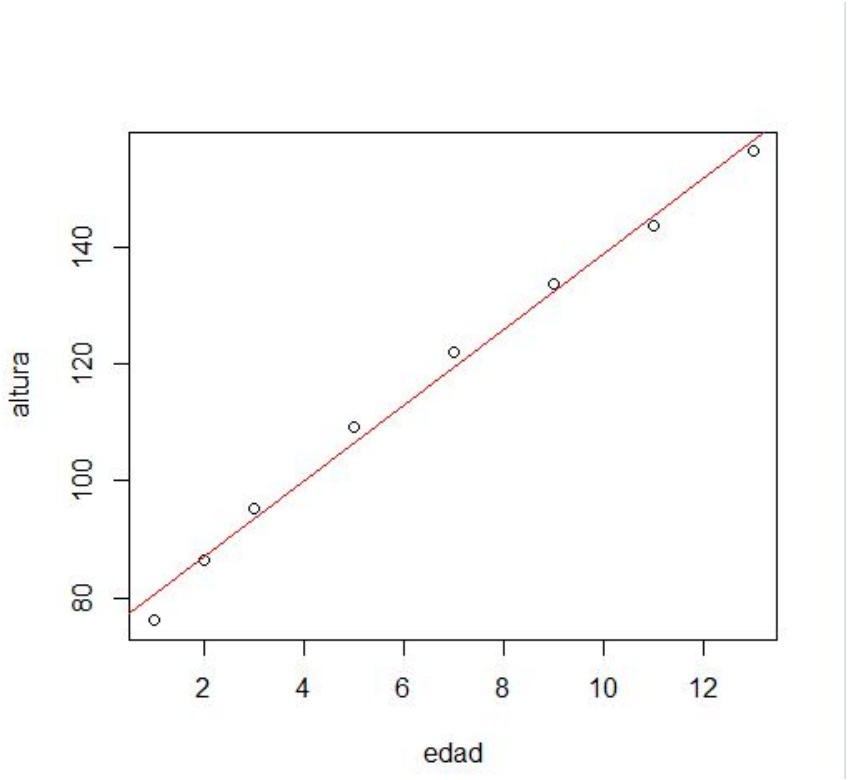

Figura 3.2: Recta regresión ejemplo

3.3. Formas básicas de lectura de datos externos

R nos permite compartir los datos vía internet, para que se pueda acceder a los mismos datos sin necesidad de cambiarlos de sitio y de una manera más cómoda. Estos datos los podremos importar a R vía Import Dataset en la pestaña del entorno. Haciendo clic sobre él nos da la opción de importarlo desde un fichero o desde una página web.

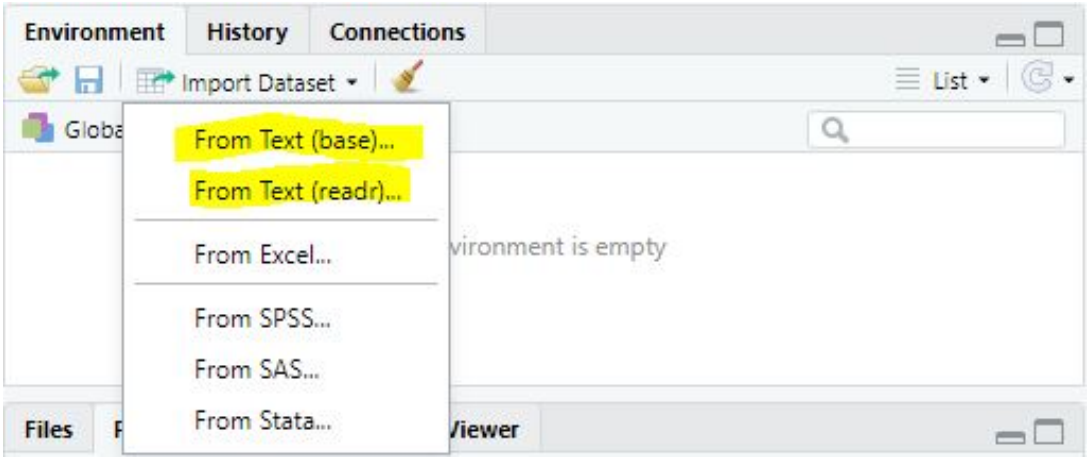

Figura 3.3: Importar datos

Ahora vamos a escoger subir los datos desde una web. La web escogida es http://aprender.uib.es/Rdir/pearson.txt, donde tendremos una serie de datos sobre padres e hijos.

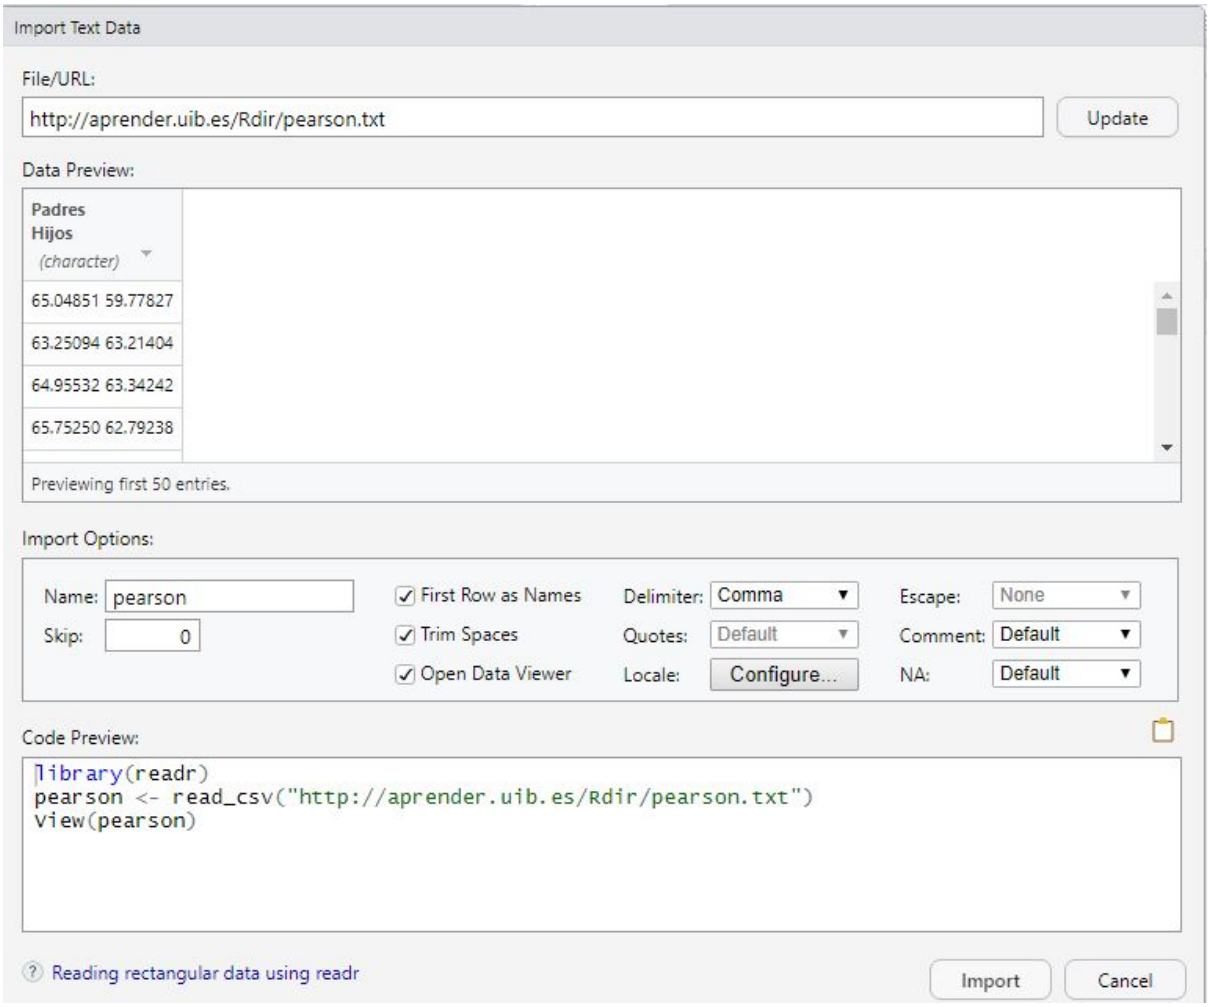

Figura 3.4: Importar datos web

En esta pestaña le indicamos que nos lo separe por un espacio en blanco y denominamos a nuestros datos como df_pearson. Y veremos nuestros datos así:

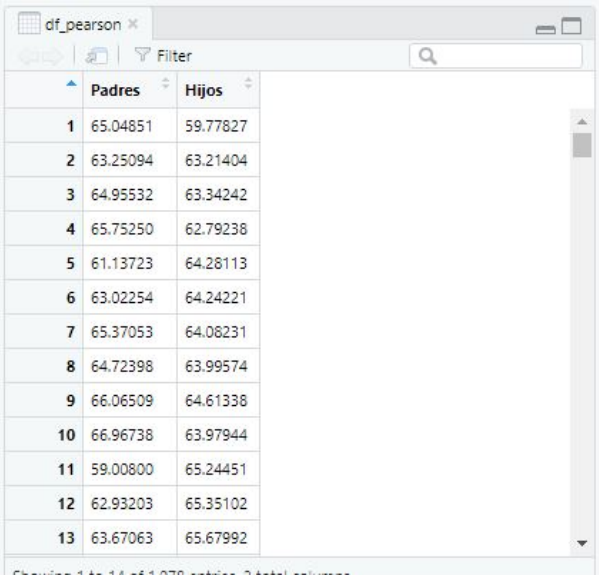

	Padres	Hijos
1	65.04851	59.77827
2	63.25094	63.21404
3	64.95532	63.34242
4	65.75250	62.79238
5	61.13723	64.28113
6	63.02254	64.24221
7	65.37053	64.08231
8	64.72398	63.99574
9	66.06509	64.61338
10	66.96738	63.97944
11	59.00800	65.24451
12	62.93203	65.35102
13	63.67063	65.67992

Figura 3.5: Datos ya importados

Otra manera de importar los datos es mediante el comando read.table(nombre del fichero o URL, header=FALSE, sep=, dec="."). Primero colocamos el nombre de fichero o la dirección, lo segundo es el encabezado que en este caso no tiene, lo tercero es la separación que son los espacios en blanco y lo último los decimales los separamos por un punto. Vamos a importar los mismos datos con este método:

Listing 3.8: Código importar datos

```
> df_pearson2=read.table("http://aprender.uib.es/Rdir/pearson.
    txt", header = TRUE)
> View(df_pearson2)
```

Finalmente, vamos a hacer una recta de regresión con estos nuevos datos. Para ello, vamos a utilizar este nuevo código:

Listing 3.9: Código recta regresión

```
> plot(df_pearson)
> regHijosPadres=lm(Hijos~Padres, data=df_pearson)
> abline(regHijosPadres, col="red")
> summary(regHijosPadres)

Call:
lm(formula = Hijos ~ Padres, data = df_pearson)

Residuals:
     Min       1Q   Median       3Q      Max
-8.8772  -1.5144  -0.0079   1.6285   8.9685

Coefficients:
             Estimate Std. Error t value
(Intercept) 33.88660    1.83235   18.49
Padres       0.51409    0.02705   19.01
             Pr(>|t|)
(Intercept)   <2e-16 ***
Padres        <2e-16 ***
---
Signif. codes:
0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 2.437 on 1076 degrees of freedom
Multiple R-squared:  0.2513,    Adjusted R-squared:  0.2506
F-statistic: 361.2 on 1 and 1076 DF,  p-value: < 2.2e-16
```

Y este código nos dará la siguiente gráfica de regresión:

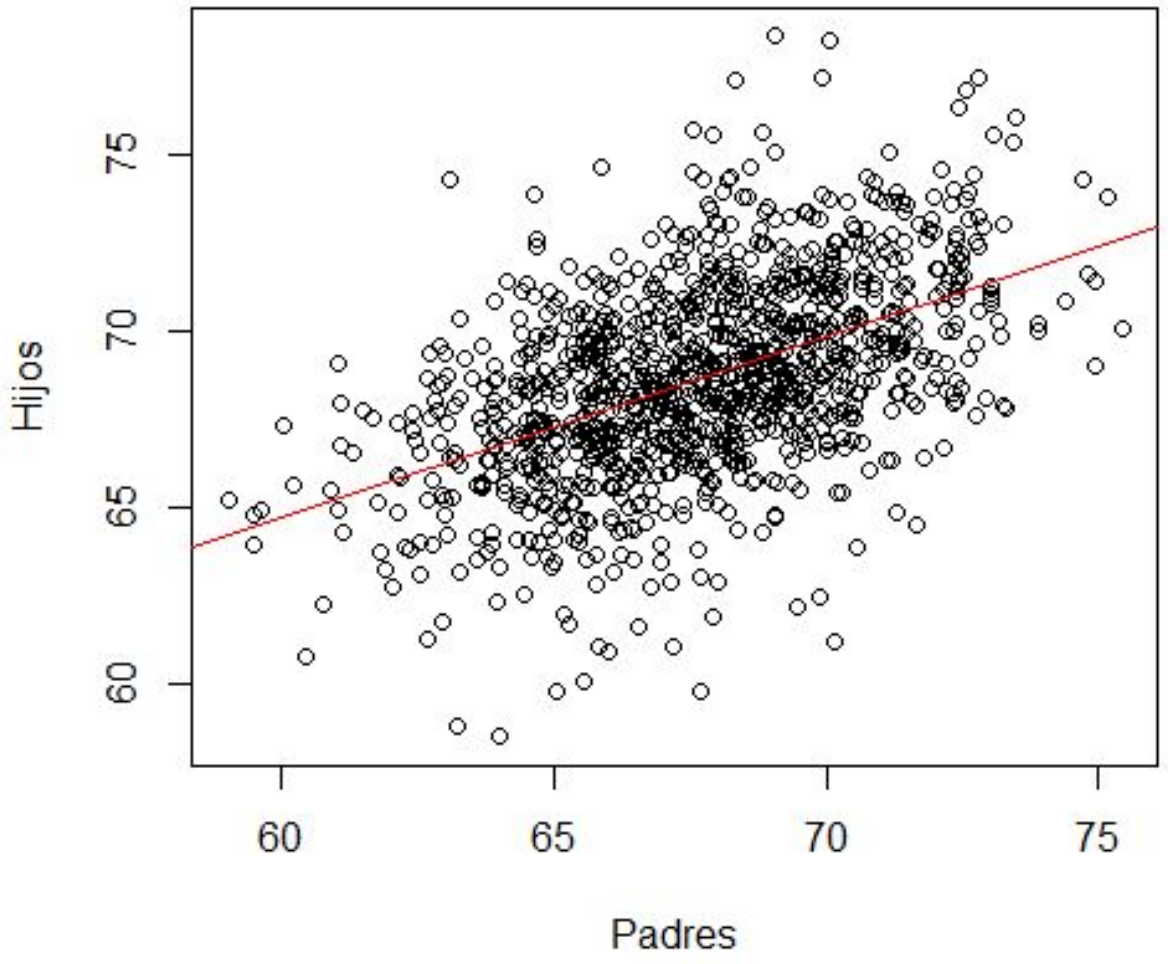

Figura 3.6: Regresión nueva

3.4. Rectas de regresión y transformaciones logarítmicas

En este capítulo vamos a ver cómo representar funciones logarítmicas o exponenciales. Para ello, primero vamos a ver cómo transformar una función exponencial en una lineal.

$$y = a \cdot 10^{bx}$$
$$\log y = \log\left(a \cdot 10^{bx}\right) = \log a + bx \log 10 = \log a + bx$$

Seguidamente, vamos a ver cómo se transforma una función exponencial en una lineal.

$$y = a \cdot x^{b}$$
$$\log y = \log\left(a \cdot x^{b}\right) = \log a + b \cdot \log x$$

Vamos a poner un ejemplo de una función logarítmica que representa la relación entre la inhibición y la serotonina. Primero vamos a ver su código:

Listing 3.10: Código función logarítmica

```
> inhibicion=c(19,36,60,84)
> serotonina=c(1.2,3.6,12,33)
> df_IS=data.frame(inhibicion,serotonina)
> plot(df_IS)
```

Este código nos dará como resultado una representación logarítmica que es la siguiente:

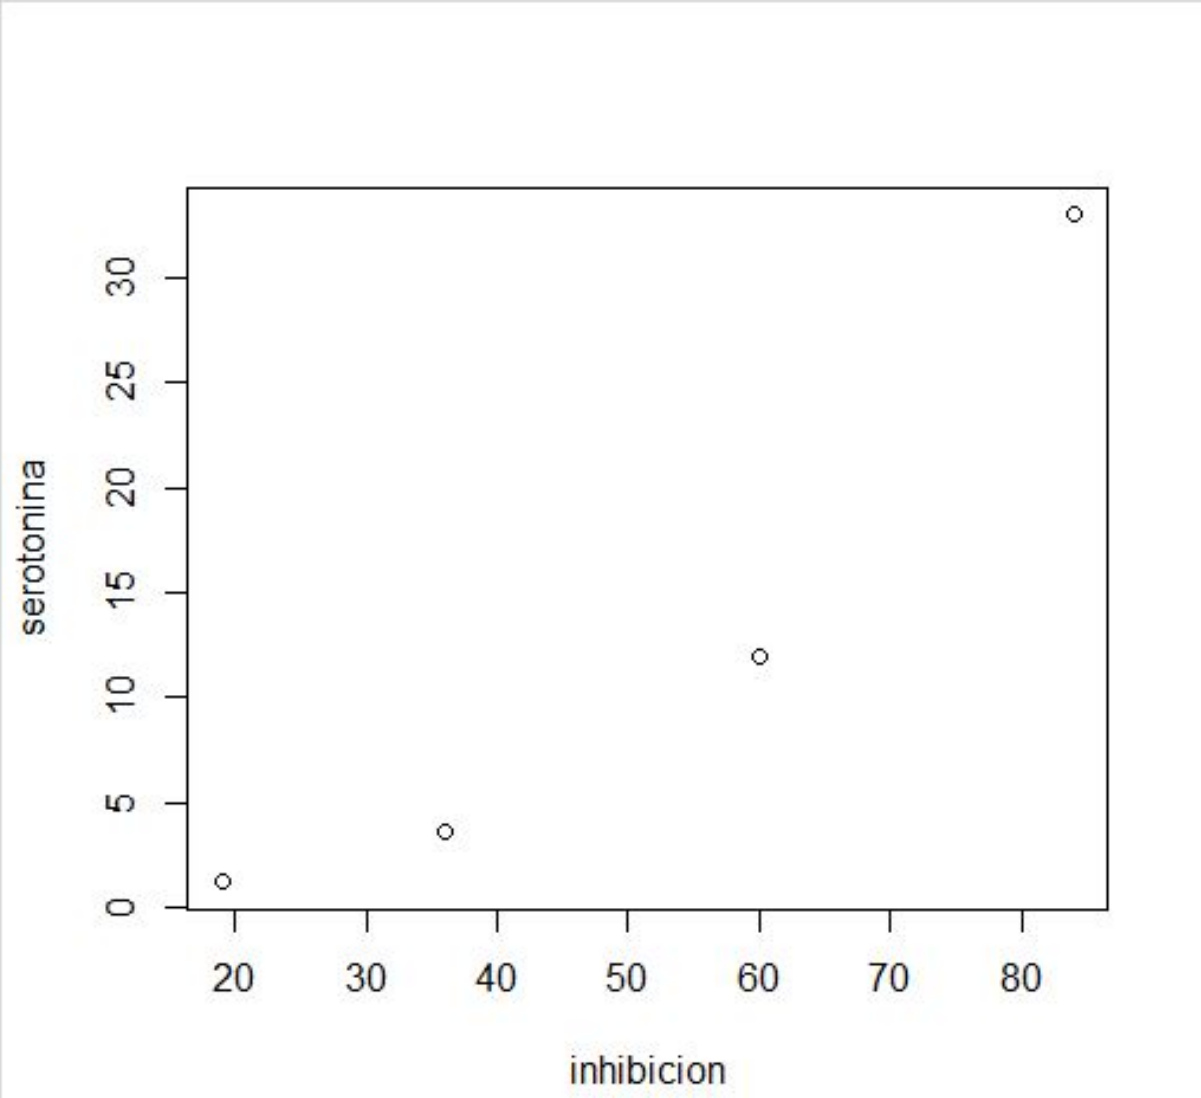

Figura 3.7: Gráfica función logarítmica

Pero si hacemos el logaritmo en base 10 de la serotonina nos dará una gráfica más linea.

Listing 3.11: Código representación más lineal

```
> plot(inhibicion,log10(serotonina))
```

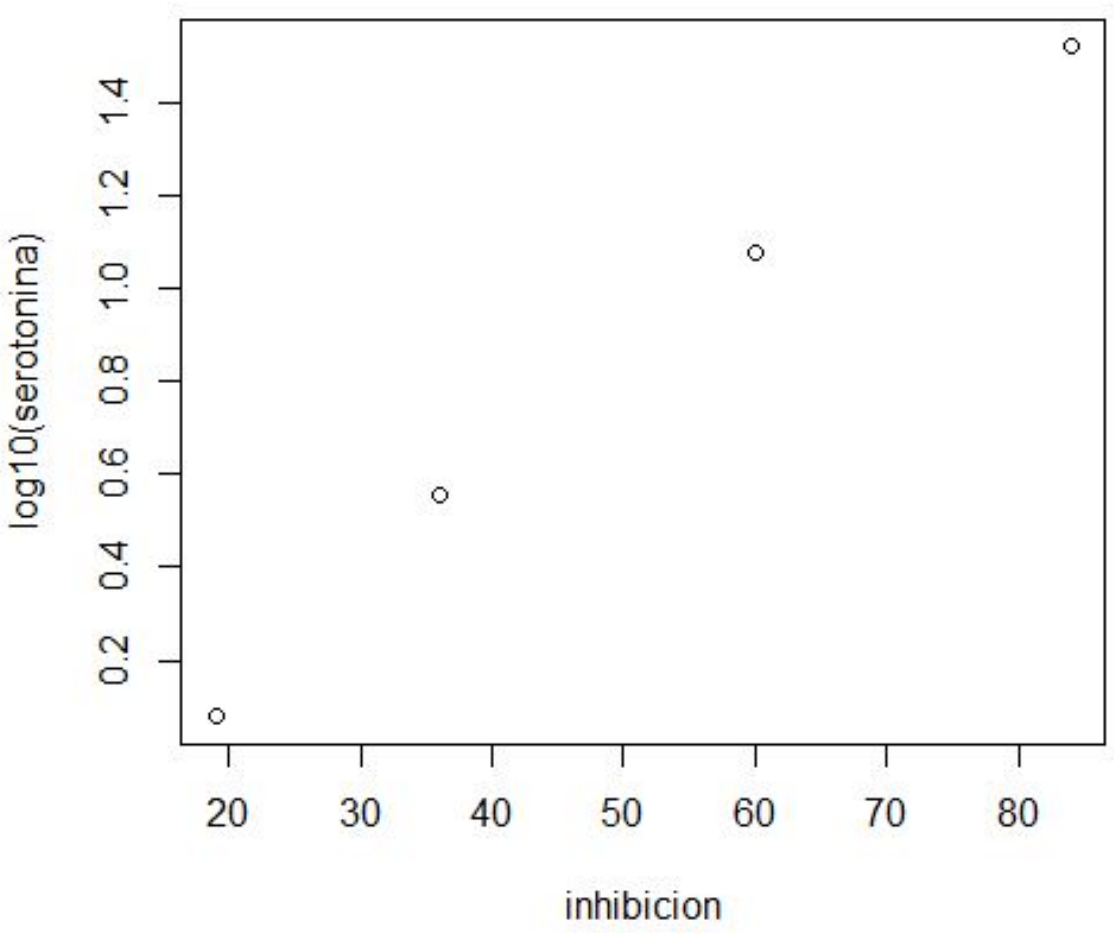

Figura 3.8: Representación más lineal

Esta gráfica la podemos hacer de otra manera, en el mismo plot sólo tendremos que indicar cual es la parte logarítmica de la función.

Listing 3.12: Código representación más lineal

```
1 > plot(df_IS, log="y")
```

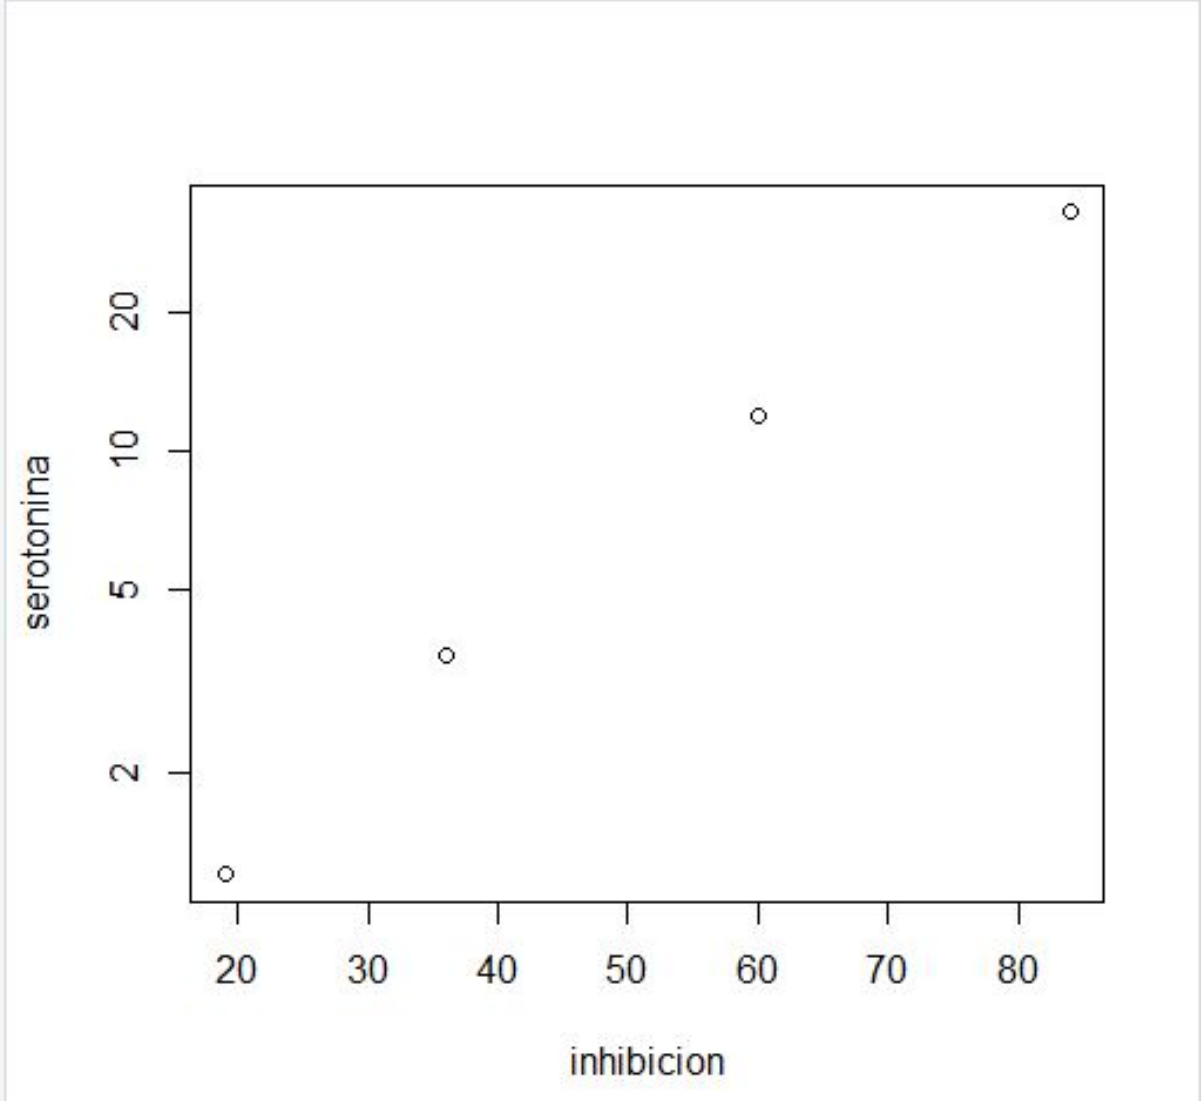

Figura 3.9: Representación semilogarítmica

Con el código anterior obtendremos una gráfica en escala semilogarítmica.
Como hemos obtenido estos resultados, que son más lineales, podremos realizar una regresión lineal de ellos. Vamos a proceder con el siguiente código:

Listing 3.13: Código de regresión lineal

```
> inhibicion=c(19,36,60,84)
> serotonina=c(1.2,3.6,12,33)
> df_IS=data.frame(inhibicion,serotonina)
> plot(df_IS)
> plot(inhibicion,log10(serotonina))
> plot(df_IS, log="y")
> regr_inh_logSer=lm(log10(serotonina)~inhibicion, data=df_IS)
> summary(regr_inh_logSer)

Call:
lm(formula = log10(serotonina) ~ inhibicion, data = df_IS)
```

```
12
13 Residuals:
14       1        2        3        4
15 -0.05381  0.04997  0.04578 -0.04195
16
17 Coefficients:
18             Estimate Std. Error t value
19 (Intercept) -0.284272   0.076811  -3.701
20 inhibicion   0.021961   0.001384  15.863
21             Pr(>|t|)
22 (Intercept)  0.06588 .
23 inhibicion   0.00395 **
24 ---
25 Signif. codes:
26 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
27
28 Residual standard error: 0.068 on 2 degrees of freedom
29 Multiple R-squared:  0.9921,    Adjusted R-squared:  0.9882
30 F-statistic: 251.6 on 1 and 2 DF,  p-value: 0.00395
```

Ahora vamos a reconvertir estos parámetros.

$$\log a = -0{,}284272 \rightarrow a = 10^{-0{,}284272} = 0{,}5196708$$

$$y = 0{,}5197 \cdot 10^{0{,}02196 \cdot x}$$

Esta reconversión la pasaremos a la curva para ver si se adaptan bien los datos de la regresión lineal. El código sería el siguiente:

Listing 3.14: Código curva

```
1 > plot(df_IS)
2 > curve(0.5196704*(10^0.021961)^x, add=TRUE, col="blue")
```

Que nos dará la siguiente gráfica:

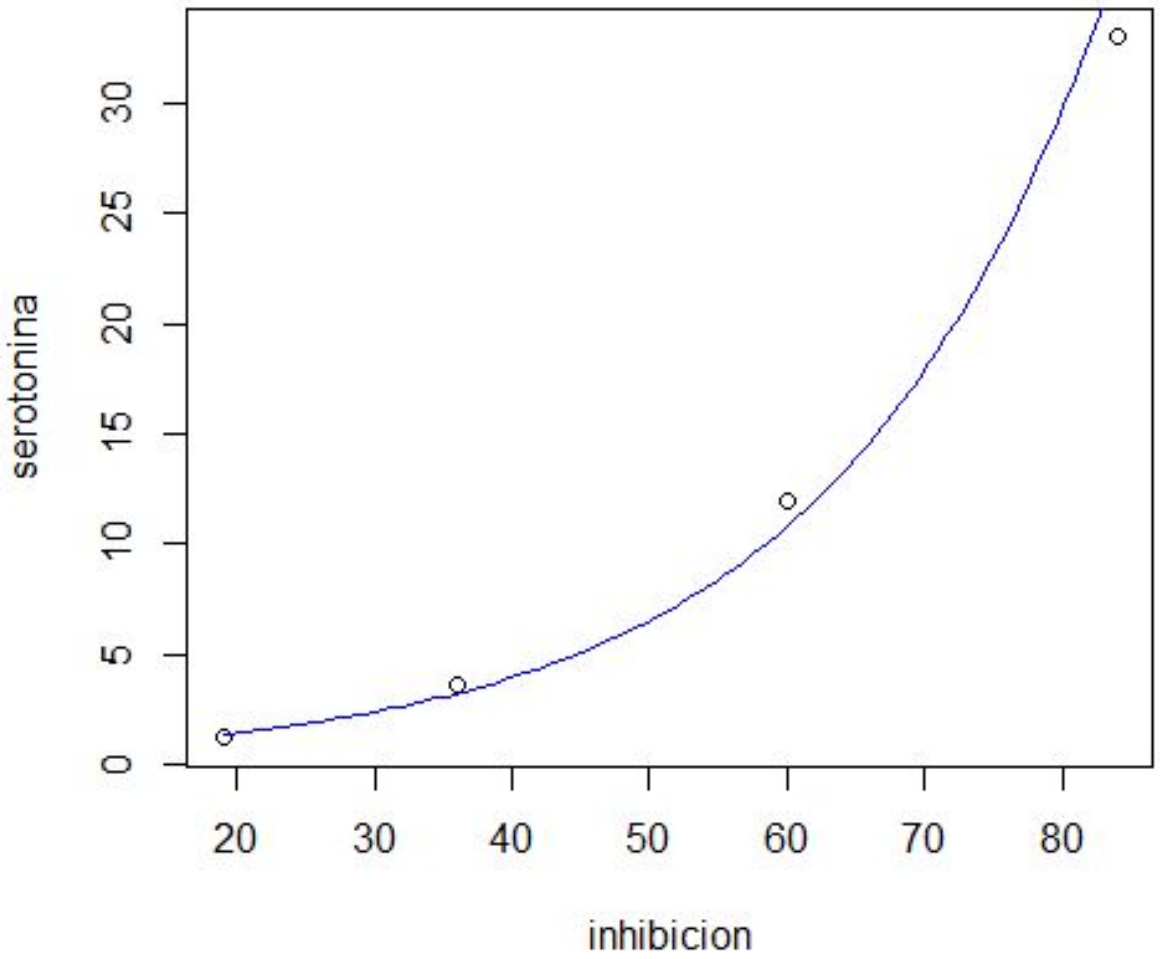

Figura 3.10: Representación de la curva

Seguidamente, vamos a ver cómo se realiza una función exponencial.

Listing 3.15: Código función exponencial

```
> tiempo=1:12
> SIDA_acum=c(97,709,2698,6928,15242,29944,52902,83903,120612,
161711,206247,257085)
> df_SIDA=data.frame(tiempo,SIDA_acum)
> plot(df_SIDA)
```

Este código nos da como resultado la siguiente gráfica:

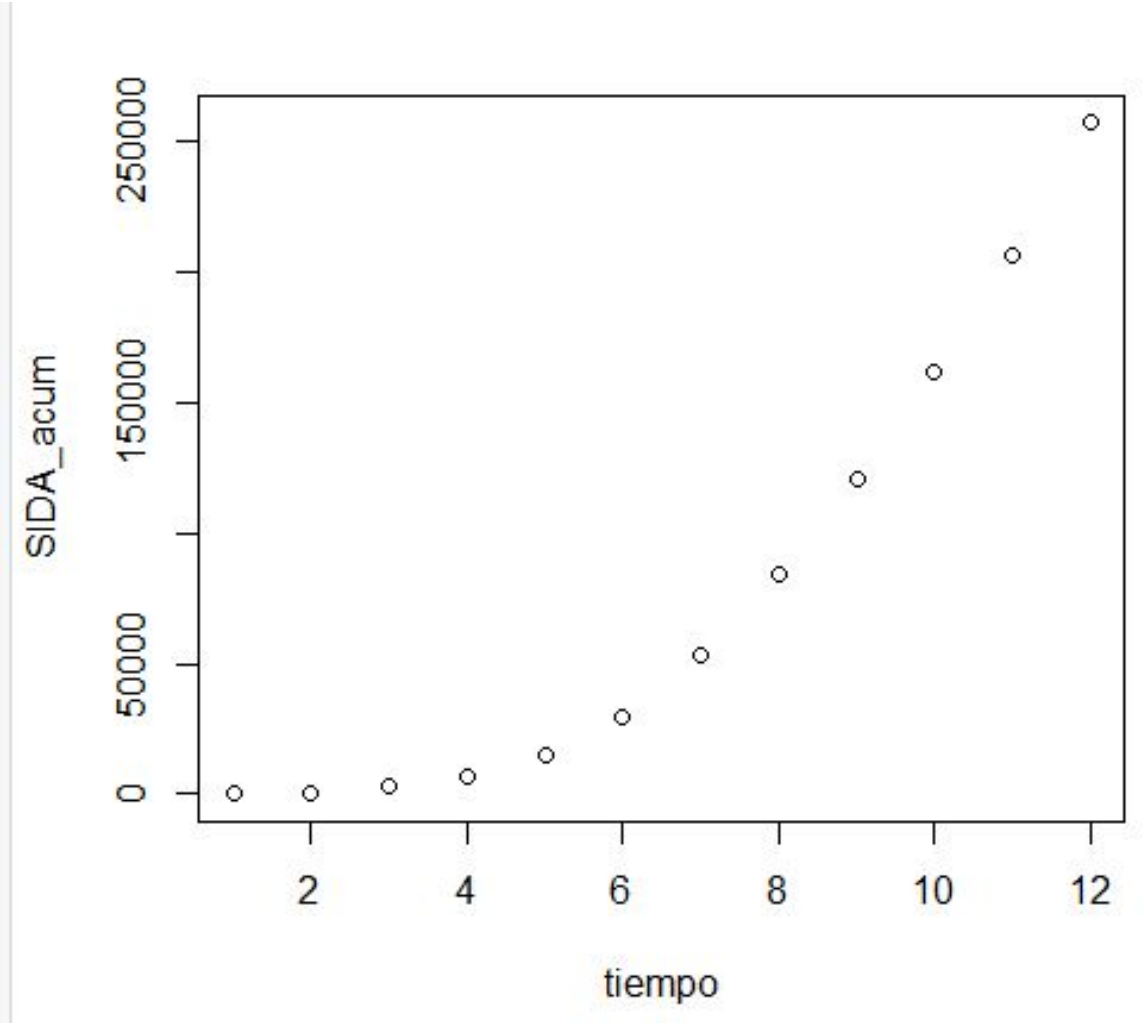

Figura 3.11: Función exponencial

Para hacerla más lineal, la tendremos que pasar dos veces por una logarítmica mediante este sencillo código:

Listing 3.16: Código recta más lineal

```
> plot(df_SIDA, log="xy")
```

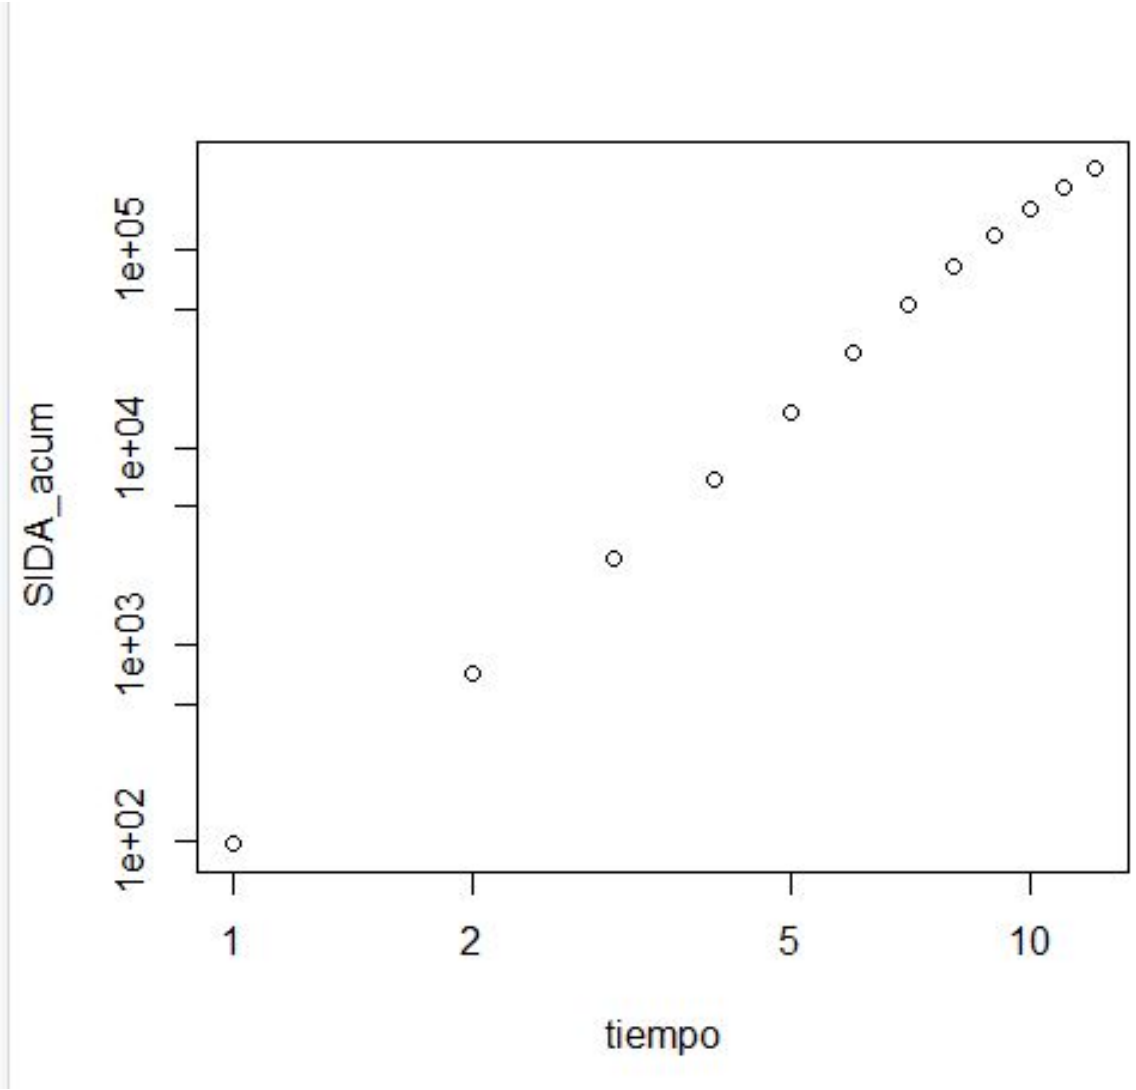

Figura 3.12: Representación más lineal

Con esta gráfica obtenida vamos a realizar la regresión lineal de la misma.

Listing 3.17: Código regresión lineal

```
> regr_logt_logSIDA=lm(log10(SIDA_acum)~log10(tiempo), data=df
    _SIDA)
> summary(regr_logt_logSIDA)

Call:
lm(formula = log10(SIDA_acum) ~ log10(tiempo), data = df_SIDA)

Residuals:
      Min        1Q    Median        3Q
-0.052459 -0.042597 -0.000831  0.039183
      Max
 0.069265
```

```
13
14 Coefficients:
15                Estimate Std. Error t value
16 (Intercept)     1.91751    0.03283   58.41
17 log10(tiempo)   3.27409    0.04162   78.66
18                Pr(>|t|)
19 (Intercept)    5.25e-14 ***
20 log10(tiempo)  2.69e-15 ***
21 ---
22 Signif. codes:
23 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
24
25 Residual standard error: 0.04531 on 10 degrees of freedom
26 Multiple R-squared:  0.9984,    Adjusted R-squared:  0.9982
27 F-statistic:  6188 on 1 and 10 DF,  p-value: 2.692e-15
```

Y como en la anterior función, vamos a reconvertir los parámetros.

$$\log a = 1{,}917507 \rightarrow a = 10^{1{,}917507} = 82{,}7003$$

$$y = 82{,}7003 \cdot x^{3{,}27409}$$

Listing 3.18: Código curva tras reconversión de parámetros

```
1 > plot(df_SIDA)
2 > curve(10^1.91751*x^3.27409, add="TRUE", col="green")
```

Y este código nos dará como resultado la siguiente gráfica:

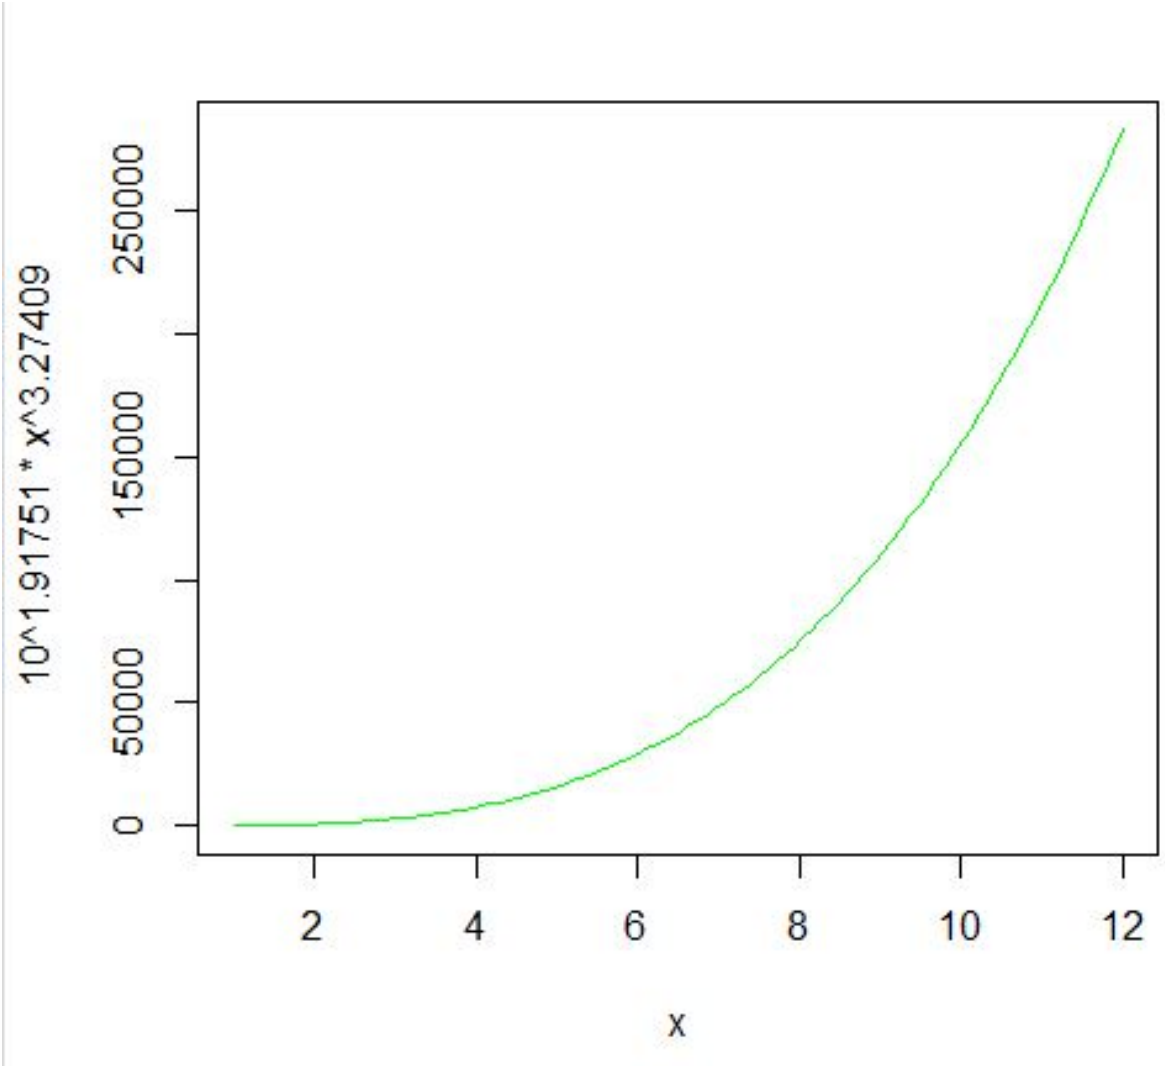

Figura 3.13: Curva tras reconversión parámetros

Capítulo 4

Vectores, entradas vacías, factores y listas generalizadas

4.1. Vectores

4.1.1. Construcción de vectores

Para R un **vector** es una lista ordenada de datos **de un mismo tipo**. Dispone de una serie de funciones para definirlos:

- c: Sirve para concatenar datos.
- scan: Permite leer o importar datos.
- rep, seq: Vectores específicos.

Función c

Se aplica a los datos que tiene que formar el vector, ordenados y seperados por comas. A continuación vamos a mostrar un ejemplo de vector:

Listing 4.1: Código función c

```
> x=c(1,2,3,4)
> x
[1] 1 2 3 4
> ABC=c("a","b","c")
> ABC
[1] "a" "b" "c"
```

Como podemos ver, para las palabras hay que entrecomillarlas, sino la función no es capaz de encontrarlas.
Esta función también sirve para concatenar vectores o añadir valores finales a un vector. Por ejemplo, podemos concatenar los dos vectores anteriores y añadir un 200 al final:

Listing 4.2: Código de funciones concatenadas con c

```
> c(x,ABC,200)
```

```
[1] "1"   "2"   "3"   "4"   "a"   "b"   "c"
[8] "200"
```

Se observa que los números pueden ser palabras, pero las palabras no pueden ser números por lo que les considera a todos palabras.

Función rep

Esta función sirve para construir vectores repitiendo datos o vectores. Para definir un vector constante basta con utilizar la función rep(x,n) donde n es la cantidad de veces que queremos repetirlo. Pero si queremos aplicarla a vectores:

- rep(vector, times=n): Repite n veces el vector en bloque.
- rep(vector, each=n): Repite n veces cada entrada del vector.

A continuación vamos a ver varios ejemplos con cada uno de ellos:

Listing 4.3: Código vectores función sep

```
> rep("a",100)
  [1] "a" "a" "a" "a" "a" "a" "a" "a" "a" "a"
 [11] "a" "a" "a" "a" "a" "a" "a" "a" "a" "a"
 [21] "a" "a" "a" "a" "a" "a" "a" "a" "a" "a"
 [31] "a" "a" "a" "a" "a" "a" "a" "a" "a" "a"
 [41] "a" "a" "a" "a" "a" "a" "a" "a" "a" "a"
 [51] "a" "a" "a" "a" "a" "a" "a" "a" "a" "a"
 [61] "a" "a" "a" "a" "a" "a" "a" "a" "a" "a"
 [71] "a" "a" "a" "a" "a" "a" "a" "a" "a" "a"
 [81] "a" "a" "a" "a" "a" "a" "a" "a" "a" "a"
 [91] "a" "a" "a" "a" "a" "a" "a" "a" "a" "a"
> rep(x, times=100)
  [1] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
 [21] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
 [41] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
 [61] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
 [81] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[101] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[121] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[141] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[161] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[181] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[201] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[221] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[241] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[261] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[281] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[301] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
[321] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
```

```
 [341] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
 [361] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
 [381] 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4 1 2 3 4
> rep(x, each=100)
   [1] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
  [21] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
  [41] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
  [61] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
  [81] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
 [101] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
 [121] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
 [141] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
 [161] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
 [181] 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
 [201] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
 [221] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
 [241] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
 [261] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
 [281] 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3
 [301] 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
 [321] 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
 [341] 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
 [361] 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
 [381] 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4 4
> rep(c(1,2,3,4), times=c(5,10,15,20))
 [1] 1 1 1 1 1 2 2 2 2 2 2 2 2 2 2 3 3 3 3 3 3
[22] 3 3 3 3 3 3 3 3 3 4 4 4 4 4 4 4 4 4 4 4 4
[43] 4 4 4 4 4 4 4 4
```

Como se puede ver en la última función podemos combinarla con la función c para concatenar la repetición de los distintos datos y además es importante no olvidarse de entrecomillar el texto.

Función seq

Permite construir progresiones aritméticas. Sus usos básicos son los siguientes:

- seq(a,b, by=r): de a b con paso r.
- seq(a, by=r, length.out=n): a partir de a, de longitud n con paso r.

Se pueden encontrar otros usos en la ayuda de la función. Ahora vamos a mostrar un ejemplo de cada uno de los usos:

Listing 4.4: Código función seq

```
> seq(0,120, by=5)
 [1]   0   5  10  15  20  25  30  35  40  45
[11]  50  55  60  65  70  75  80  85  90  95
```

```
[21] 100 105 110 115 120
> seq(0,123, by=5)
 [1]   0   5  10  15  20  25  30  35  40  45
[11]  50  55  60  65  70  75  80  85  90  95
[21] 100 105 110 115 120
> seq(100,17, by=-5)
 [1] 100  95  90  85  80  75  70  65  60  55
[11]  50  45  40  35  30  25  20
> 0:20
 [1]  0  1  2  3  4  5  6  7  8  9 10 11 12 13
[15] 14 15 16 17 18 19 20
> 20:0
 [1] 20 19 18 17 16 15 14 13 12 11 10  9  8  7
[15]  6  5  4  3  2  1  0
> seq(0,by=5,length.out=20)
 [1]  0  5 10 15 20 25 30 35 40 45 50 55 60 65
[15] 70 75 80 85 90 95
```

Función scan

Esta función nos permite:

- scan(): Permite entrar en consola la lista de datos.
- scan(fichero): Define un vector a partir del fichero.

Vamos a ver un ejemplo de cómo realizar un vector con la función. Es muy importante copiar los datos cuando nos aparezca un uno darle al enter y volver a darle al enter cuando haya terminado de leerlos.

Listing 4.5: Código función scan

```
> X=scan()
1: 4 10 4 9 8
6: 6 4 1 6 6
11: 9 10 4 3 7
16: 2 8 6 10 4
21: 6 10 4 3 4
26: 10 8 3 2 8
31: 9 9 6 3 4
36: 3 10 5 9 6
41:
Read 40 items
> X
 [1]  4 10  4  9  8  6  4  1  6  6  9 10  4  3
[15]  7  2  8  6 10  4  6 10  4  3  4 10  8  3
[29]  2  8  9  9  6  3  4  3 10  5  9  6
> Y
```

```
 [1]  4 10  4  9  8  6  4  1  6  6  9 10  4  3
[15]  7  2  8  6 10  4  6 10  4  3  4 10  8  3
[29]  2  8  9  9  6  3  4  3 10  5  9  6  5  9
[43]  7  5  7  2  8  6  8  4  9  7  4  9  3  3
[57]  8  8  7  6
> Z=scan("http://aprender.uib.es/Rdir/datostest9.txt")
Read 1000 items
```

Como podemos observar, se pueden extraer los vectores de un documento en el directorio o de una página web.
Además también admite algunos parámetros que son los siguientes:

- sep: Específica el signo de separación de entradas.
- dec: Especifica el separador decimal.
- what: Específica el tipo de datos.
- encoding: Especifica la codificación de alfabeto.

Listing 4.6: Código separación scan

```
> scan()
1: 1,2,3,4,5
1:
Error in scan() : scan() expected 'a real', got '1,2,3,4,5'
> scan(sep=",")
1: 1,2,3,4,5
6:
Read 5 items
[1] 1 2 3 4 5
> scan()
1: Sara Lucia David Rocio
Error in scan() : scan() expected 'a real', got 'Sara'
> scan(what="character")
1: Sara Lucia David Rocio
5:
Read 4 items
[1] "Sara"  "Lucia" "David" "Rocio"
```

4.1.2. Operaciones con vectores

R permite aplicar una función a todas las entradas de un vector de golpe:

- Aplicar la función al vector: función(vector).
- Si no funciona: sapply(vector, FUN=función).

A continuación vamos a mostrar algunos ejemplos de progresión aritmética:

Listing 4.7: Código progresión aritmética

```
> x=1:10
> x
 [1]  1  2  3  4  5  6  7  8  9 10
> x^2+5
 [1]   6   9  14  21  30  41  54  69  86 105
> sqrt(x)
 [1] 1.000000 1.414214 1.732051 2.000000
 [5] 2.236068 2.449490 2.645751 2.828427
 [9] 3.000000 3.162278
> 3+5*(0:19)
 [1]  3  8 13 18 23 28 33 38 43 48 53 58 63 68
[15] 73 78 83 88 93 98
> sum(x)
[1] 55
```

Pero no todas pueden utilizar la primera función, ya que la función suma se aplica a cada una de sus entradas.

Listing 4.8: Código definición función

```
> f=function(n){sum(1:n)}
> f(1)
[1] 1
> f(2)
[1] 3
```

Esta función no se puede aplicar a los vectores pero si utilizamos sapply se podrá operar sin problemas.

Listing 4.9: Código función sapply

```
> sapply(1:10, FUN=f)
 [1]  1  3  6 10 15 21 28 36 45 55
```

Además de poder realizar las funciones, podemos multiplicar cada entrada como vamos a ver en el siguiente ejemplo:

Listing 4.10: Código multiplicación entradas

```
> y=log(x)
> x*y
 [1]  0.000000  1.386294  3.295837  5.545177
 [5]  8.047190 10.750557 13.621371 16.635532
 [9] 19.775021 23.025851
```

También podemos encontrar funciones específicas como:

- length: Longitud.

- max y min: Máximo y mínimo.
- sum: Suma de las entradas.
- prod: Producto de las entradas.
- mean: Media aritmética de las entradas.
- cumsum: Vector sumas acumuladas de las entradas.
- sort: Ordena las entradas en orden creciente; el parámetro dec=TRUE indica que el orden sea decreciente.
- rev: Invierte el orden de las entradas.

Vamos a poner un ejemplo de cada una de estas funciones:

Listing 4.11: Código funciones específicas

```
> n=1:20
> x=3^n-10*2^n
> x
 [1]         -17         -31         -53
 [4]         -79         -77          89
 [7]         907        4001       14563
[10]       48809      156667      490481
[13]     1512403     4619129    14021227
[16]    42391361   127829443   384799049
[19] 1157018587  3476298641
> length(x)
[1] 20
> max(x)
[1] 3476298641
> min(x)
[1] -79
> sum(x)
[1] 5209205100
> prod(x)
[1] -2.46226e+99
> mean(x)
[1] 260460255
> sum(x)/length(x)
[1] 260460255
> sqrt(sum(x^2))
[1] 3686430854
> sort(x)
 [1]         -79         -77         -53
 [4]         -31         -17          89
 [7]         907        4001       14563
[10]       48809      156667      490481
[13]     1512403     4619129    14021227
```

```
[16]   42391361  127829443  384799049
[19] 1157018587 3476298641
> rev(x)
 [1] 3476298641 1157018587  384799049
 [4]  127829443   42391361   14021227
 [7]    4619129    1512403     490481
[10]     156667      48809      14563
[13]       4001        907         89
[16]        -77        -79        -53
[19]        -31        -17
> rev(sort(x))
 [1] 3476298641 1157018587  384799049
 [4]  127829443   42391361   14021227
 [7]    4619129    1512403     490481
[10]     156667      48809      14563
[13]       4001        907         89
[16]        -17        -31        -53
[19]        -77        -79
> cumsum(x)
 [1]        -17        -48       -101
 [4]       -180       -257       -168
 [7]        739       4740      19303
[10]      68112     224779     715260
[13]    2227663    6846792   20868019
[16]   63259380  191088823  575887872
[19] 1732906459 5209205100
```

La función cumsum es muy útil para calcular frecuencias acumuladas en estadística.

4.1.3. Entradas y trozos de vectores

Para las entradas de los vectores tendremos en cuenta de que i es un índice e, V es un vector y que es un vector de índices:

- V[i]: Entrada i-ésima del vector V.
- V[y]: Entradas del vector V de índices en y.
- V[-y]: El complementario de V[y].

Ahora vamos a proceder a ver un ejemplo de entrada de un vector:

Listing 4.12: Código entrada vector

```
> x=2+3*(1:50)
> x
 [1]   5   8  11  14  17  20  23  26  29  32
[11]  35  38  41  44  47  50  53  56  59  62
[21]  65  68  71  74  77  80  83  86  89  92
```

```
 [31]  95  98 101 104 107 110 113 116 119 122
 [41] 125 128 131 134 137 140 143 146 149 152
> x[3]
[1] 11
> x[length(x)]
[1] 152
> x[c(1,3,10)]
[1]  5 11 32
> x[10:20]
 [1] 32 35 38 41 44 47 50 53 56 59 62
> x[-(10:20)]
 [1]   5   8  11  14  17  20  23  26  29  65
[11]  68  71  74  77  80  83  86  89  92  95
[21]  98 101 104 107 110 113 116 119 122 125
[31] 128 131 134 137 140 143 146 149 152
> x[10:20]=0
> x
 [1]   5   8  11  14  17  20  23  26  29   0
[11]   0   0   0   0   0   0   0   0   0   0
[21]  65  68  71  74  77  80  83  86  89  92
[31]  95  98 101 104 107 110 113 116 119 122
[41] 125 128 131 134 137 140 143 146 149 152
```

Hay otras posibilidades de indicar la entrada de un vector:

- V[condición]: Entradas del vector V que satisfacen la condición.
- which(condición): Índices de las entradas del vector V que satisfacen la condición.

Además de estas posibilidades encontraremos los siguientes signos lógicos para construir estas condiciones:

Cuadro 4.1: Signos lógicos

Operador	$=$	$\neq$	$<$	$>$	$\leq$	$\geq$	Negación	Conjunción	Disyunción
Signo	==	!=	<	>	<=	>=	!	&	|

Finalmente, procederemos a realizar un ejemplo de cada una de estas nuevas condiciones:

Listing 4.13: Código condicionales

```
> x[x>=20]
 [1]  20  23  26  29  65  68  71  74  77  80
[11]  83  86  89  92  95  98 101 104 107 110
[21] 113 116 119 122 125 128 131 134 137 140
[31] 143 146 149 152
> x[x%%5==0]
 [1] 0 0 0 0 0 0 0 0 0 0 0
 > which(x%%5==0)
```

```
 [1] 10 11 12 13 14 15 16 17 18 19 20
> x[x%%5==0 & x>=20]
numeric(0)
```

4.2. Entradas vacías de un vector

En este capítulo vamos a ver el manejo de vectores con datos desconocidos.
R indica las entradas no definidas o vacías con NA. Vamos a proceder a dar un ejemplo de un vector de entrada vacía:

Listing 4.14: Código vector con entradas vacías

```
> x=1:10
> x
 [1]  1  2  3  4  5  6  7  8  9 10
> x[13]=13
> x
 [1]  1  2  3  4  5  6  7  8  9 10 NA NA 13
> sum(x)
[1] NA
```

Hay dos soluciones a este problema:

- is.na(V): Condición "entradas V no definidas".
- Entradas definidas de V: V[!is.na(V)] o na.omit(V).

Seguidamente, vamos a realizar un ejemplo que solucione el ejemplo anterior con estas dos nuevas funciones:

Listing 4.15: Código nuevo vector sin entradas vacías

```
> which(is.na(x))
[1] 11 12
> y=x[!is.na(x)]
> y
 [1]  1  2  3  4  5  6  7  8  9 10 13
> sum(y)
[1] 68
> sum(na.omit(x))
[1] 68
```

Por otro lado, podremos borrar los datos a mano, para ello tenemos la función na.rm=TRUE que se puede aplicar a una función a un vector sin tener en cuenta los NA. Vamos a proceder a realizar una suma con el vector anterior:

Listing 4.16: Código borrar datos a mano

```
> sum(x,na.rm = TRUE)
[1] 68
> mean(x)
[1] NA
> mean(x,na.rm = TRUE)
[1] 6.181818
```

Finalmente, no todas las funciones no admiten este parámetro. A continuación vamos a mostrar algún ejemplo de ellas:

Listing 4.17: Código funciones no admiten parámetro

```
> cumsum(x, na.rm=TRUE)
Error in cumsum(x, na.rm = TRUE) :
  2 arguments passed to 'cumsum' which requires 1
> cumsum(na.omit(x))
 [1]  1  3  6 10 15 21 28 36 45 55 68
```

4.3. Factores

Un factor es un vector con una estructura adecuada para analizar datos. Podemos definir un factor de dos maneras a partir de un vector:

- as.factor(vector): Convierte el vector en un factor.

Vamos a poner un ejemplo con esta función para observar las diferencias entre un factor y un vector:

Listing 4.18: Código diferencias factor de vector

```
> zonas=c(1,3,2,2,2,2,1,4,3,2,4,4,2,4,2,1,4)
> zonas
 [1] 1 3 2 2 2 2 1 4 3 2 4 4 2 4 2 1 4
> zonas.f=as.factor(zonas)
> zonas.f
 [1] 1 3 2 2 2 2 1 4 3 2 4 4 2 4 2 1 4
Levels: 1 2 3 4
> sum(zonas)
[1] 43
> sum(zonas.f)
Error in Summary.factor(c(1L, 3L, 2L, 2L, 2L, 2L, 1L, 4L, 3L,
   2L, 4L,  :"
  sum not meaningful for factors
```

Como podemos observar, el factor tiene un parámetro denominado Levels que permite considerar los elementos del factor como copia de estos niveles y otra diferencia es que no podemos aplicar las funciones del vector al factor.

- factor(vector): Crea un factor a partir del vector. Esta función tiene los siguientes parámetros básicos:
  - levels: Especifica los niveles.
  - labels: Cambia los nombres de los niveles.
- levels(factor): Vector de niveles del factor, permite modificarlos.

Vamos a realizar un ejemplo con estas nuevas funciones de creación de factores:

Listing 4.19: Código de definición de factores

```
> zonas.f2=factor(zonas, levels=c(1,2,3,4,5), labels = c("a",
    "e", "i", "o", "u"))
> zonas.f2
 [1] a i e e e e a o i e o o e o e a o
Levels: a e i o u
> levels(zonas.f2)
[1] "a" "e" "i" "o" "u"
> levels(zonas.f2)=c("A", "B", "C", "D", "E")
> zonas.f2
 [1] A C B B B B A D C B D D B D B A D
Levels: A B C D E
```

Finalmente, habrá ocasiones en las que nos interese que los niveles tengan un orden concreto y que nos permitirá contar los individuos de cada nivel, en esta caso utilizaremos la función ordered(vector) que crea un factor ordenado a partir del vector. Es importante que especifiquemos el orden de los niveles. Vamos a poner un ejemplo de un factor ordenado:

Listing 4.20: Código factor ordenado por niveles

```
> zonas.fo=ordered(zonas, levels=c(1,3,4,2), labels=c("S", "C-
    S", "C-N", "N"))
> zonas.fo
 [1] S    C-S N    N    N    S    C-N C-S N
[11] C-N C-N N    C-N N    S    C-N
Levels: S < C-S < C-N < N
```

4.4. Listas generalizadas

Como hemos dicho en capítulos anteriores, R necesita que todos los datos sean de un mismo tipo. Pero, a veces, necesitamos utilizar vectores de datos heterogéneos. En este capítulo vamos a ver como manejar estos vectores, que en R se llaman list.
Seguidamente, vamos a recordar los vectores homogéneos utilizados en capítulos anteriores:

Listing 4.21: Código vectores homogéneos

```
> edad=c(1,2,3,5,7,9,11,13)
> altura=c
   (76.11,86.45,95.27,109.18,122.03,133.73,143.73,156.41)
> summary(lm(altura~edad))

Call:
lm(formula = altura ~ edad)

Residuals:
    Min      1Q  Median      3Q     Max
-4.351  -1.743   0.408   2.018   2.745

Coefficients:
            Estimate Std. Error t value
(Intercept)  73.9681     1.7979   41.14
edad          6.4934     0.2374   27.36
            Pr(>|t|)
(Intercept) 1.38e-08 ***
edad        1.58e-07 ***
---
Signif. codes:
0 '***' 0.001 '**' 0.01 '*' 0.05 '. 0.1 ' ' 1

Residual standard error: 2.746 on 6 degrees of freedom
Multiple R-squared:  0.992,     Adjusted R-squared:  0.9907
F-statistic: 748.4 on 1 and 6 DF,  p-value: 1.577e-07
> str(summary(lm(altura~edad)))
List of 11
 $ call          : language lm(formula = altura ~ edad)
 $ terms         :Classes 'terms', 'formula'  language altura ~
    edad
```

Hemos acortado el str para quedarnos con lo importante de la función. Esta función nos indica que hay una lista de 11 elementos.
Seguidamente, vamos a ver con qué funciones podemos definir nuestras lists:

- list(objeto1, objeto2,...): Crea list con los objetos.
- list(nombre1=objeto1, nombre2=objeto2,...): Crea list con los objetos, y les asigna los nombres internos.
- str(list): Estructura interna de la list.

Vamos a realizar un ejemplo con estas nuevas funciones:

Listing 4.22: Código creación nuevas listas

```
> datos=list(vec=edad,nombre.vec="edad", long=length(edad),
   media=mean(edad))
> datos
$vec
[1]  1  2  3  5  7  9 11 13

$nombre.vec
[1] "edad"

$long
[1] 8

$media
[1] 6.375
> str(datos)
List of 4
 $ vec        : num [1:8] 1 2 3 5 7 9 11 13
 $ nombre.vec: chr "edad"
 $ long       : int 8
 $ media      : num 6.38
```

Finalmente, vamos a ver cómo sacar un objeto de una list. Tenemos dos opciones:

- list$nombre: Objeto de la list correspondiente al nombre.
- list[[i]]: Objeto i-ésimo de la list.
- list[i]: List formada por el objeto i-ésimo de la list.

Las dos últimas funciones se pueden aplicar a vectores de índices. Vamos a ver cómo extraer los datos de nuestro ejemplo:

Listing 4.23: Código extracción objetos de la list

```
> datos$vec
[1]  1  2  3  5  7  9 11 13
> datos[[1]]
[1]  1  2  3  5  7  9 11 13
> datos$nombre.vec
[1] "edad"
> datos[[2]]
[1] "edad"
> nombre.vec
Error: object 'nombre.vec' not found
> datos[[1]]
[1]  1  2  3  5  7  9 11 13
> datos[1]
$vec
```

```
15 [1]  1  2  3  5  7  9 11 13
```

Capítulo 5

Matrices y vectores propios

5.1. Matrices

5.1.1. Construcción de matrices

Las matrices son tablas rectangulares de un mismo tipo, normalmente números. En este capítulo vamos a ver las dos maneras distintas que tiene R para construir matrices. Es importante que todas sus entradas sean del mismo tipo de datos. Podemos construir matrices con las siguientes funciones:

- matrix(vector,...): Construye una matriz con las entradas del vector. Tiene los siguientes parámetros básicos:
  - byrow: Indica si se organizan por filas (**TRUE**), o por columnas (**FALSE**).
  - nrow o ncol: Número de filas o de columnas.

Vamos a proceder a construir una matriz sencilla con esta función:

Listing 5.1: Código construcción matrices

```
> x=1:12
> matrix(x, nrow=3)
     [,1] [,2] [,3] [,4]
[1,]    1    4    7   10
[2,]    2    5    8   11
[3,]    3    6    9   12
> matrix(x, nrow=3, byrow = TRUE)
     [,1] [,2] [,3] [,4]
[1,]    1    2    3    4
[2,]    5    6    7    8
[3,]    9   10   11   12
> matrix(x, ncol=4, byrow = TRUE)
     [,1] [,2] [,3] [,4]
[1,]    1    2    3    4
[2,]    5    6    7    8
[3,]    9   10   11   12
> matrix(x, ncol=5, byrow = TRUE)
```

```
      [,1] [,2] [,3] [,4] [,5]
[1,]    1    2    3    4    5
[2,]    6    7    8    9   10
[3,]   11   12    1    2    3
Warning message:
In matrix(x, ncol = 5, byrow = TRUE) :
  data length [12] is not a sub-multiple or multiple of the
     number of columns [5]
> matrix(x, ncol=5,nrow = 5, byrow = TRUE)
      [,1] [,2] [,3] [,4] [,5]
[1,]    1    2    3    4    5
[2,]    6    7    8    9   10
[3,]   11   12    1    2    3
[4,]    4    5    6    7    8
[5,]    9   10   11   12    1
Warning message:
In matrix(x, ncol = 5, nrow = 5, byrow = TRUE) :
  data length [12] is not a sub-multiple or multiple of the
     number of rows [5]
> matrix(1, nrow = 3, ncol = 3)
      [,1] [,2] [,3]
[1,]    1    1    1
[2,]    1    1    1
[3,]    1    1    1
```

Esta función es útil para representar matrices constantes.
Otra manera de construir matrices es mediante la concatenación de vectores, y se realiza mediante las siguientes funciones:

- cbind: Concatena matrices y vectores por columnas.
- rbind: Concatena matrices y vectores por filas.

En ambos casos las dimensiones han de ser adecuadas. Vamos a proceder a ver un ejemplo con estas funciones:

Listing 5.2: Código concatenación vectores y matrices

```
> a=1:4
> b=c(1,3,5,7)
> c=rep(0,4)
> rbind(a,b,c)
  [,1] [,2] [,3] [,4]
a    1    2    3    4
b    1    3    5    7
c    0    0    0    0
> cbind(a,b,c)
     a b c
[1,] 1 1 0
```

```
[2,] 2 3 0
[3,] 3 5 0
[4,] 4 7 0
> A=diag(4)
> A
     [,1] [,2] [,3] [,4]
[1,]    1    0    0    0
[2,]    0    1    0    0
[3,]    0    0    1    0
[4,]    0    0    0    1
> rbind(A,a,b,c)
  [,1] [,2] [,3] [,4]
     1    0    0    0
     0    1    0    0
     0    0    1    0
     0    0    0    1
a    1    2    3    4
b    1    3    5    7
c    0    0    0    0
> cbind(a,A,b,c)
      a           b c
[1,] 1 1 0 0 0 1 0
[2,] 2 0 1 0 0 3 0
[3,] 3 0 0 1 0 5 0
[4,] 4 0 0 0 1 7 0
```

Como podemos observar, la función diag crea una matriz diagonal de 4x4.

5.1.2. Entradas y trozos de matrices

Es similar al capítulo de los vectores, pero tendremos que tener en cuenta las dos dimensiones de la matriz.
En general las entradas de la matriz se indican como en los vectores pero con una función bidimensional que es M[i,j], donde primero se presenta la fila y luego la columna. Vamos a ver un ejemplo sencillo de esta función:

Listing 5.3: Código entrada matriz

```
> A=matrix(1:30,nrow = 5)
> A
     [,1] [,2] [,3] [,4] [,5] [,6]
[1,]    1    6   11   16   21   26
[2,]    2    7   12   17   22   27
[3,]    3    8   13   18   23   28
[4,]    4    9   14   19   24   29
```

```
[5,]    5   10   15   20   25   30
> A[2,3]
[1] 12
```

Podremos distinguir entre filas y columnas a través de las siguientes funciones:

- M[i,]: Fila.
- M[,j]: Columna.

Usando vectores de índices en vez de índices, se obtienen submatrices determinadas por las filas y columnas indicadas. Vamos a ver un ejemplo con estas distinciones a partir del ejemplo anterior:

Listing 5.4: Código distinción filas y columnas

```
> A[2,3]
[1] 12
> A[3,]
[1]  3  8 13 18 23 28
> A[,3]
[1] 11 12 13 14 15
> A[,1:2]
     [,1] [,2]
[1,]    1    6
[2,]    2    7
[3,]    3    8
[4,]    4    9
[5,]    5   10
> A[c(1,3,5),c(2,4,6)]
     [,1] [,2] [,3]
[1,]    6   16   26
[2,]    8   18   28
[3,]   10   20   30
```

Finalmente, tenemos la función diag que nos da la matriz diagonal. Vamos a ver otro ejemplo de matriz diagonal con la matriz ejemplo anterior:

Listing 5.5: Código matriz diagonal

```
> diag(A)
[1]  1  7 13 19 25
```

5.1.3. Funciones para matrices

En este capítulo vamos a ver las funciones básicas con matrices. Primero vamos a ver las funciones relacionadas con las dimensiones de las matrices:

- nrow: Número de filas.

- ncol: Número de columnas.
- dim: Vector con ambas dimensiones.

Vamos a realizar un ejemplo con estas funciones básicas:

Listing 5.6: Código funciones básicas dimensiones

```
> A=matrix(1:30,nrow = 5)
> A
     [,1] [,2] [,3] [,4] [,5] [,6]
[1,]    1    6   11   16   21   26
[2,]    2    7   12   17   22   27
[3,]    3    8   13   18   23   28
[4,]    4    9   14   19   24   29
[5,]    5   10   15   20   25   30
> nrow(A)
[1] 5
> ncol(A)
[1] 6
> dim(A)
[1] 5 6
```

Podremos utilizar algunas funciones que se utilizan para vectores como sum, prod, mean,..., también podemos aplicar las funciones a las filas o columnas de la matriz. Como por ejemplo, podremos aplicar las siguientes funciones:

- colSums: Vector de sumas de columnas.
- rowSums: Vector de sumas de filas.
- colMeans: Vector de medias de columnas.
- rowMeans: Vector de medias de filas.

Vamos a aplicar estas funciones al ejemplo anterior:

Listing 5.7: Código funciones básicas comunes vectores

```
> mean(A)
[1] 15.5
> rowSums(A)
[1]  81  87  93  99 105
> colMeans(A)
[1]  3  8 13 18 23 28
```

Finalmente, también podremos aplicar la función apply(matriz, FUN=función, MARGIN=...), que aplica la función a la matriz:

- MARGIN=1: Fila a fila.
- MARGIN=2: Columna a columna.

- MARGIN=c(1,2): Entrada a entrada.

Esta función también puede ser utilizada como función(matriz) para que lo aplique a todas las entradas de la matriz. Vamos a continuar con ejemplos de esta función aplicados a la matriz ejemplo A:

Listing 5.8: Código función elemento a elemento

```
> apply(A, FUN=prod,MARGIN=1)
[1]   576576  1696464  3616704  6664896
[5] 11250000
> f=function(x){sqrt(sum(x^2))}
> apply(A, FUN=f, MARGIN = 2)
[1]  7.416198 18.165902 29.240383 40.373258
[5] 51.526692 62.689712
> log(A)
          [,1]     [,2]     [,3]     [,4]
[1,] 0.0000000 1.791759 2.397895 2.772589
[2,] 0.6931472 1.945910 2.484907 2.833213
[3,] 1.0986123 2.079442 2.564949 2.890372
[4,] 1.3862944 2.197225 2.639057 2.944439
[5,] 1.6094379 2.302585 2.708050 2.995732
          [,5]     [,6]
[1,] 3.044522 3.258097
[2,] 3.091042 3.295837
[3,] 3.135494 3.332205
[4,] 3.178054 3.367296
[5,] 3.218876 3.401197
> apply(A, FUN=log,MARGIN=c(1,2) )
          [,1]     [,2]     [,3]     [,4]
[1,] 0.0000000 1.791759 2.397895 2.772589
[2,] 0.6931472 1.945910 2.484907 2.833213
[3,] 1.0986123 2.079442 2.564949 2.890372
[4,] 1.3862944 2.197225 2.639057 2.944439
[5,] 1.6094379 2.302585 2.708050 2.995732
          [,5]     [,6]
[1,] 3.044522 3.258097
[2,] 3.091042 3.295837
[3,] 3.135494 3.332205
[4,] 3.178054 3.367296
[5,] 3.218876 3.401197
```

5.1.4. Álgebra matricial

En este capítulo vamos a ver las operaciones algebraicas con matrices, que son las siguientes:

- Suma: +.

- Producto por escalar: *.
- Producto: %*%.
- Transpuesta: t.
- Determinante: det.
- Inversa: solve.
- Potencia: Instalar antes el paquete expm y se realiza con la función %^%.
- Rango: qr(...)$rank.

Vamos a ver algunos ejemplos de estas operaciones algebraicas con matrices:

Listing 5.9: Código operaciones algebraicas con matrices

```
> A=matrix(1:4, nrow=2)
> B=matrix(1,nrow = 2,ncol = 2)
> C=matrix(1:6,nrow = 2)
> A
     [,1] [,2]
[1,]    1    3
[2,]    2    4
> B
     [,1] [,2]
[1,]    1    1
[2,]    1    1
> C
     [,1] [,2] [,3]
[1,]    1    3    5
[2,]    2    4    6
> A+B
     [,1] [,2]
[1,]    2    4
[2,]    3    5
> A+C
Error in A + C : non-conformable arrays
> 5*A
     [,1] [,2]
[1,]    5   15
[2,]   10   20
> A%*%B
     [,1] [,2]
[1,]    4    4
[2,]    6    6
> A*B
     [,1] [,2]
[1,]    1    3
[2,]    2    4
```

```
> t(C)
     [,1] [,2]
[1,]    1    2
[2,]    3    4
[3,]    5    6
> det(A)
[1] -2
> det(C)
Error in determinant.matrix(x, logarithm, ...) :
  'x' must be a square matrix
> solve(A)
     [,1] [,2]
[1,]   -2  1.5
[2,]    1 -0.5
> solve(B)
Error in solve.default(B) :
  Lapack routine dgesv: system is exactly singular: U[2,2] = 0
> qr(B)$rank
[1] 1
> B%^%20
       [,1]   [,2]
[1,] 524288 524288
[2,] 524288 524288
> B^20
     [,1] [,2]
[1,]    1    1
[2,]    1    1
```

Podremos resolver sistemas de ecuaciones si tenemos en cuenta que A es una matriz cuadrada de $n \times n$ y b es un vector de longitud n, para ello vamos a utilizar la siguiente función:

- solve(A,b): $A^{-1} \cdot b$.

Este sistema se utiliza para resolver sistemas compatibles determinados. Vamos a poner un sistema compatible determinado de ejemplo con su resolución y su solución en R:

$$\left.\begin{array}{l} x+3y=1 \\ 2x+4y=3 \end{array}\right\} \rightarrow \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix} \cdot \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 1 \\ 3 \end{pmatrix}$$

$$\begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 1 & 3 \\ 2 & 4 \end{pmatrix}^{-1} \cdot \begin{pmatrix} 1 \\ 3 \end{pmatrix}$$

Listing 5.10: Código solución sistema compatible determinado

```
> solve(A,c(1,3))
[1]  2.5 -0.5
```

$$\begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} 2{,}5 \\ -0{,}5 \end{pmatrix}$$

5.2. Cálculo de valores y vectores propios

En este capítulo vamos a ver cómo calcular los valores y vectores propios de una matriz y cómo descomponer los datos de una matriz diagonalizable.

Primero vamos a definir cuando un vector es propio. Un vector $v = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \neq 0$ es un vector propio de la matriz

$$A = \begin{pmatrix} a_1 & \cdots & a_{1n} \\ \vdots & \vdots & \vdots \\ a_n & \cdots & a_{bn} \end{pmatrix}$$

cuando existe $\lambda \in C$ tal que $A \cdot v = \lambda \cdot v$.
Entonces, λ es un valor propio de A, y v es un vector propio de A de valor propio λ.
Vamos a proceder a realizar un ejemplo de vector propio:

$$A = \begin{pmatrix} 4 & -6 & 6 \\ 3 & -5 & 8 \\ 2 & -4 & 7 \end{pmatrix}$$

$v = \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix}$ es vector propio de A de valor propio 3, porque:

$$\begin{pmatrix} 4 & -6 & 6 \\ 3 & -5 & 8 \\ 2 & -4 & 7 \end{pmatrix} \cdot \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 0 \\ 3 \\ 3 \end{pmatrix} = 3 \cdot \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix}$$

En cambio $w = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$ no es vector propio de A, porque:

$$\begin{pmatrix} 4 & -6 & 6 \\ 3 & -5 & 8 \\ 2 & -4 & 7 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 4 \\ 6 \\ 5 \end{pmatrix} \neq \begin{pmatrix} \lambda \\ \lambda \\ \lambda \end{pmatrix} = \lambda \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$$

Los valores y vectores propios de una matriz A se calculan con la función eigen(A), cuyo resultado da una list con dos objetos:

- values: Vector de valores propios.
- vectors: Matriz de columnas vectores propios, en el mismo orden.

Vamos a ver un ejemplo con esta función:

Listing 5.11: Código función valores y vectores propios

```
> A=matrix(c(4,-6,6,3,-5,8,2,-4,7),nrow=3,byrow=TRUE)
> B=matrix(c(4,5,3,-4,13,3,-4,5,11),nrow=3,byrow=TRUE)
> C=matrix(c(0,3,4,4,-4,-8,-4,8,12),nrow = 3,byrow = TRUE)
> A
```

```
     [,1] [,2] [,3]
[1,]    4   -6    6
[2,]    3   -5    8
[3,]    2   -4    7
> eigen(A)
eigen() decomposition
$values
[1] 3 2 1

$vectors
              [,1]       [,2]          [,3]
[1,] 9.186681e-16 -0.8017837 -8.944272e-01
[2,] 7.071068e-01  0.2672612 -4.472136e-01
[3,] 7.071068e-01  0.5345225  1.297573e-15

> eigen(A)$values
[1] 3 2 1
> eigen(A)$vectors
              [,1]       [,2]          [,3]
[1,] 9.186681e-16 -0.8017837 -8.944272e-01
[2,] 7.071068e-01  0.2672612 -4.472136e-01
[3,] 7.071068e-01  0.5345225  1.297573e-15
> B
     [,1] [,2] [,3]
[1,]    4    5    3
[2,]   -4   13    3
[3,]   -4    5   11
> eigen(B)
eigen() decomposition
$values
[1] 12  8  8

$vectors
          [,1]       [,2]       [,3]
[1,] 0.5773503 -0.8164966 -0.3064116
[2,] 0.5773503 -0.4082483 -0.6579007
[3,] 0.5773503 -0.4082483  0.6879524
```

Si A es diagonalizable, del resultado eigen(A) se obtiene una descomposición canónica:

$$A = P \cdot D \cdot P^{-1}$$

D: Matriz diagonal con diagonal principal eigen(A)$values cuya función es diag(eigen(A)$values).
P: La matriz eigen(A)$vectors.
Vamos a ver cómo aplicar esta descomposición canónica con un ejemplo:

Listing 5.12: Código descomposición canónica

```
> A
     [,1] [,2] [,3]
[1,]    4   -6    6
[2,]    3   -5    8
[3,]    2   -4    7
> DA=diag(eigen(A)$values)
> PA=eigen(A)$vectors
> PA%*%DA%*%solve(PA)
     [,1] [,2] [,3]
[1,]    4   -6    6
[2,]    3   -5    8
[3,]    2   -4    7
> DB=diag(eigen(B)$values)
> PB=eigen(B)$vectors
> PB%*%DB%*%solve(PB)
     [,1] [,2] [,3]
[1,]    4    5    3
[2,]   -4   13    3
[3,]   -4    5   11
> B
     [,1] [,2] [,3]
[1,]    4    5    3
[2,]   -4   13    3
[3,]   -4    5   11
> C
     [,1] [,2] [,3]
[1,]    0    3    4
[2,]    4   -4   -8
[3,]   -4    8   12
> eigen(C)
eigen() decomposition
$values
[1] 4+0i 2+0i 2-0i

$vectors
                  [,1]           [,2]
[1,]  0.2981424+0i -0.3333333+0i
[2,] -0.5962848+0i  0.6666667+0i
[3,]  0.7453560+0i -0.6666667+0i
                  [,3]
[1,] -0.3333333-0i
[2,]  0.6666667+0i
[3,] -0.6666667-0i
```

Capítulo 6

Data frame

6.1. Introducción

En este capítulo vamos a ver el uso, manejo y características de los data frame.
Un data frame es una tabla de doble entrada formada por variables en las columnas y observaciones de estas en las filas. Tienen el mismo aspecto que una matriz,pero pueden contener diferentes datos. Pero los datos de una misma columna deben ser de un mismo tipo.

Cuadro 6.1: Estructura general data frame

	Variable 1	**Variable 2**	**...**	**Variable m**
Obs. 1				
Obs. 2				
...				
Obs. n				

Las columnas son factores o vectores, ya que son de un mismo tipo, mientras que las filas son lists.
Vamos a considerar los siguientes tipos de datos:

- **Atributo o cualitativos**: Son los que expresan una cualidad del individuo. En R los guardaremos en vectores en factores.
- **Ordinales**: Similares a los anteriores pero se pueden ordenar de forma natural. En R los guardaremos en factores ordenados.
- **Cuantitativos**: Son datos numerales que se refieren a medidas. En R los guardaremos en vectores de números.

6.2. Estructura

En este capítulo vamos a ver las distintas funciones utilizadas para obtener información sobre los data frame.
Una tabla de las más conocidas de R es la data frame iris. Contiene la longitud y la anchura de los pétalos y sépalos y la especie de 150 flores iris. Para más información sobre estos datos podemos leer la entrada de la wikipedia https://es.wikipedia.org/wiki/

Iris_flor_conjunto_de_datos, y si se quiere más información específica podéis acceder a la ayuda.
Vamos a proceder con un ejemplo cómo empezar a ver cómo se forma un data frame:

Listing 6.1: Código visualización data frame

```
> d.f=iris
> data("iris")
> View(iris)
```

Con la función data() volvemos a la data frame original, con la función View() podremos ver nuestras variables en el editor de la siguiente forma:

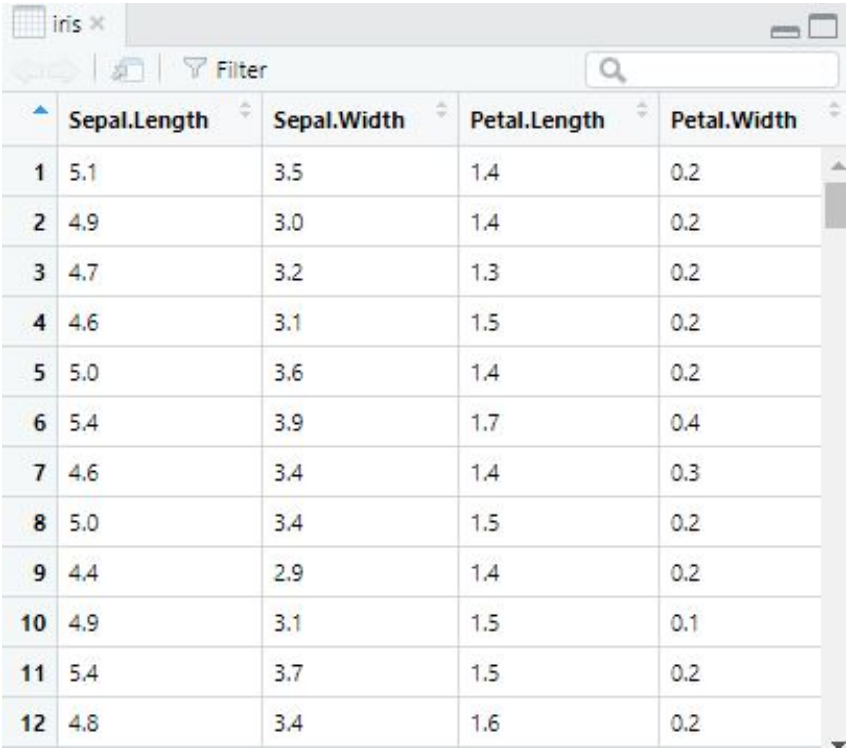

iris

Filter

	Sepal.Length	Sepal.Width	Petal.Length	Petal.Width
1	5.1	3.5	1.4	0.2
2	4.9	3.0	1.4	0.2
3	4.7	3.2	1.3	0.2
4	4.6	3.1	1.5	0.2
5	5.0	3.6	1.4	0.2
6	5.4	3.9	1.7	0.4
7	4.6	3.4	1.4	0.3
8	5.0	3.4	1.5	0.2
9	4.4	2.9	1.4	0.2
10	4.9	3.1	1.5	0.1
11	5.4	3.7	1.5	0.2
12	4.8	3.4	1.6	0.2

Figura 6.1: Data frame iris

Además de estas funciones podremos utilizar las siguientes para referirnos a su estructura interna:

- head: Muestra las primeras n filas del data frame.
- tail: Muestra las n últimas filas del data frame.
  Tanto head como tail tienen por defecto $n = 6$.
- str: Da la estructura global de un objeto de datos.

Vamos a seguir con el ejemplo anterior mostrando las primeras y las últimas filas:

Listing 6.2: Código mostrar primeras y últimas filas

```
> head(d.f)
```

```
  Sepal.Length Sepal.Width Petal.Length
1          5.1         3.5          1.4
2          4.9         3.0          1.4
3          4.7         3.2          1.3
4          4.6         3.1          1.5
5          5.0         3.6          1.4
6          5.4         3.9          1.7
  Petal.Width Species
1         0.2  setosa
2         0.2  setosa
3         0.2  setosa
4         0.2  setosa
5         0.2  setosa
6         0.4  setosa
> tail(d.f)
    Sepal.Length Sepal.Width Petal.Length
145          6.7         3.3          5.7
146          6.7         3.0          5.2
147          6.3         2.5          5.0
148          6.5         3.0          5.2
149          6.2         3.4          5.4
150          5.9         3.0          5.1
    Petal.Width   Species
145         2.5 virginica
146         2.3 virginica
147         1.9 virginica
148         2.0 virginica
149         2.3 virginica
150         1.8 virginica
> head(d.f,5)
  Sepal.Length Sepal.Width Petal.Length
1          5.1         3.5          1.4
2          4.9         3.0          1.4
3          4.7         3.2          1.3
4          4.6         3.1          1.5
5          5.0         3.6          1.4
  Petal.Width Species
1         0.2  setosa
2         0.2  setosa
3         0.2  setosa
4         0.2  setosa
5         0.2  setosa
> str(d.f)
'data.frame':   150 obs. of  5 variables:
 $ Sepal.Length: num  5.1 4.9 4.7 4.6 5 5.4 4.6 5 4.4 4.9 ...
 $ Sepal.Width : num  3.5 3 3.2 3.1 3.6 3.9 3.4 3.4 2.9 3.1
    ...
```

```
48  $ Petal.Length: num  1.4 1.4 1.3 1.5 1.4 1.7 1.4 1.5 1.4
      1.5...
49  $ Petal.Width : num  0.2 0.2 0.2 0.2 0.2 0.4 0.3 0.2 0.2 0.1
      ...
50  $ Species     : Factor w/ 3 levels "setosa","versicolor",..:
      1 1 1 1 1 1 1 1 1 1 ...
```

Seguidamente, vamos a ver cómo obtener sus dimensiones, los nombres de sus variables e identificadores de sus filas.
Vamos a ver cómo obtener los nombres, los identificadores y las dimensiones:

- names: Para obtener un vector con los nombres de la columna de un data frame.
- rownames: Para obtener un vector con los identificadores de las filas de un data frame.
- dimnames: Para obtener una list formada por el vector de los identificadores de las filas y el vector de los nombres de las columnas de un data frame.

Permiten modificar estos vectores:

- dim: Para obtener un vector con el número de filas y el número de columnas.

Ahora vamos a aplicar estas nuevas funciones al ejemplo anterior:

Listing 6.3: Código dimensiones data frame

```
1  > names(d.f)
2  [1] "Sepal.Length" "Sepal.Width"
3  [3] "Petal.Length" "Petal.Width"
4  [5] "Species"
5  > rownames(d.f)
6    [1] "1"   "2"   "3"   "4"   "5"   "6"
7    [7] "7"   "8"   "9"   "10"  "11"  "12"
8   [13] "13"  "14"  "15"  "16"  "17"  "18"
9   [19] "19"  "20"  "21"  "22"  "23"  "24"
10  [25] "25"  "26"  "27"  "28"  "29"  "30"
11  [31] "31"  "32"  "33"  "34"  "35"  "36"
12  [37] "37"  "38"  "39"  "40"  "41"  "42"
13  [43] "43"  "44"  "45"  "46"  "47"  "48"
14  [49] "49"  "50"  "51"  "52"  "53"  "54"
15  [55] "55"  "56"  "57"  "58"  "59"  "60"
16  [61] "61"  "62"  "63"  "64"  "65"  "66"
17  [67] "67"  "68"  "69"  "70"  "71"  "72"
18  [73] "73"  "74"  "75"  "76"  "77"  "78"
19  [79] "79"  "80"  "81"  "82"  "83"  "84"
20  [85] "85"  "86"  "87"  "88"  "89"  "90"
21  [91] "91"  "92"  "93"  "94"  "95"  "96"
22  [97] "97"  "98"  "99"  "100" "101" "102"
23 [103] "103" "104" "105" "106" "107" "108"
```

```
[109] "109" "110" "111" "112" "113" "114"
[115] "115" "116" "117" "118" "119" "120"
[121] "121" "122" "123" "124" "125" "126"
[127] "127" "128" "129" "130" "131" "132"
[133] "133" "134" "135" "136" "137" "138"
[139] "139" "140" "141" "142" "143" "144"
[145] "145" "146" "147" "148" "149" "150"
> dimnames(d.f)
[[1]]
  [1] "1"   "2"   "3"   "4"   "5"   "6"
  [7] "7"   "8"   "9"   "10"  "11"  "12"
 [13] "13"  "14"  "15"  "16"  "17"  "18"
 [19] "19"  "20"  "21"  "22"  "23"  "24"
 [25] "25"  "26"  "27"  "28"  "29"  "30"
 [31] "31"  "32"  "33"  "34"  "35"  "36"
 [37] "37"  "38"  "39"  "40"  "41"  "42"
 [43] "43"  "44"  "45"  "46"  "47"  "48"
 [49] "49"  "50"  "51"  "52"  "53"  "54"
 [55] "55"  "56"  "57"  "58"  "59"  "60"
 [61] "61"  "62"  "63"  "64"  "65"  "66"
 [67] "67"  "68"  "69"  "70"  "71"  "72"
 [73] "73"  "74"  "75"  "76"  "77"  "78"
 [79] "79"  "80"  "81"  "82"  "83"  "84"
 [85] "85"  "86"  "87"  "88"  "89"  "90"
 [91] "91"  "92"  "93"  "94"  "95"  "96"
 [97] "97"  "98"  "99"  "100" "101" "102"
[103] "103" "104" "105" "106" "107" "108"
[109] "109" "110" "111" "112" "113" "114"
[115] "115" "116" "117" "118" "119" "120"
[121] "121" "122" "123" "124" "125" "126"
[127] "127" "128" "129" "130" "131" "132"
[133] "133" "134" "135" "136" "137" "138"
[139] "139" "140" "141" "142" "143" "144"
[145] "145" "146" "147" "148" "149" "150"

[[2]]
[1] "Sepal.Length" "Sepal.Width"
[3] "Petal.Length" "Petal.Width"
[5] "Species"

> dim(d.f)
[1] 150   5
> d.f$Sepal.Length[1:30]
 [1] 5.1 4.9 4.7 4.6 5.0 5.4 4.6 5.0 4.4 4.9 5.4 4.8
[13] 4.8 4.3 5.8 5.7 5.4 5.1 5.7 5.1 5.4 5.1 4.6 5.1
[25] 4.8 5.0 5.0 5.2 5.2 4.7
> d.f$Species[1:30]
```

```
 [1] setosa setosa setosa setosa setosa setosa setosa
 [8] setosa setosa setosa setosa setosa setosa setosa
[15] setosa setosa setosa setosa setosa setosa setosa
[22] setosa setosa setosa setosa setosa setosa setosa
[29] setosa setosa
Levels: setosa versicolor virginica
> Sepal.Length
Error: object 'Sepal.Length' not found
```

No se puede declarar las variables internas por sí solas, aunque si que se verán más adelante cómo hacerlo.
Los data frame comparten con las matrices la extracción de datos entre corchetes, vamos a ver un ejemplo de esto:

Listing 6.4: Código extracción datos data frame

```
> d.f[1:5,]
  Sepal.Length Sepal.Width Petal.Length Petal.Width
1          5.1         3.5          1.4         0.2
2          4.9         3.0          1.4         0.2
3          4.7         3.2          1.3         0.2
4          4.6         3.1          1.5         0.2
5          5.0         3.6          1.4         0.2
  Species
1  setosa
2  setosa
3  setosa
4  setosa
5  setosa
> d.f[1:5,1:3]
  Sepal.Length Sepal.Width Petal.Length
1          5.1         3.5          1.4
2          4.9         3.0          1.4
3          4.7         3.2          1.3
4          4.6         3.1          1.5
5          5.0         3.6          1.4
> d.f[d.f$Species=="virginica"& d.f$Sepal.Length>7,]
    Sepal.Length Sepal.Width Petal.Length Petal.Width
103          7.1         3.0          5.9         2.1
106          7.6         3.0          6.6         2.1
108          7.3         2.9          6.3         1.8
110          7.2         3.6          6.1         2.5
118          7.7         3.8          6.7         2.2
119          7.7         2.6          6.9         2.3
123          7.7         2.8          6.7         2.0
126          7.2         3.2          6.0         1.8
130          7.2         3.0          5.8         1.6
```

```
131          7.4         2.8          6.1         1.9
132          7.9         3.8          6.4         2.0
136          7.7         3.0          6.1         2.3
       Species
103 virginica
106 virginica
108 virginica
110 virginica
118 virginica
119 virginica
123 virginica
126 virginica
130 virginica
131 virginica
132 virginica
136 virginica
```

6.3. Importar y exportar data frame

En este capítulo vamos a ver cómo importar un data frame a través de un fichero externo y cómo exportarlos de R.
Primero vamos a ver cómo importar un data frame de un fichero externo, para ello vamos a utilizar la función read.table que permite definir un data frame a partir de una tabla de datos contenida en un fichero de texto simple externo. La función completa sería read.table("ubicación del fichero de texto"). En esta función podremos utilizar parámetros como:

- sep: Para especificar las separaciones entre columnas del fichero, por defecto son espacios en blanco.
- header: Si la tabla que importamos tiene una primera fila con los nombres de las columnas hay que especificar header=TRUE.

Vamos a realizar un ejemplo con dos data frame, en la primera parte se hará con los ficheros en nuestro directorio y en la segunda parte desde una dirección web:

Listing 6.5: Código importar data frame desde fichero y web

```
> NH1=read.table("NotasHermanos.txt", header=TRUE)
> head(NH1)
  Grado Hermanos Nota
1    BQ        1   93
2    BL        1   35
3    BL        1   55
4    BL        1   77
5    BL        2   81
6    BQ        0   86
```

```
> str(NH1)
'data.frame':   87 obs. of  3 variables:
 $ Grado    : Factor w/ 2 levels "BL","BQ": 2 1 1 1 1 2 2 1 1 1
      ...
 $ Hermanos: int  1 1 1 1 2 0 1 1 1 1 ...
 $ Nota     : int  93 35 55 77 81 86 97 40 16 31 ...
> NH2=read.table("NotasHermanos.txt", header=TRUE, sep=",")
> str(NH2)
'data.frame':   87 obs. of  1 variable:
 $ Grado.Hermanos.Nota: Factor w/ 71 levels "BL 0 20","BL 0 40
     ",..: 62 12 18 24 38 47 63 15 9 11 ...
> head(NH2)
  Grado.Hermanos.Nota
1                BQ 1 93
2                BL 1 35
3                BL 1 55
4                BL 1 77
5                BL 2 81
6                BQ 0 86
> NH3=read.table("http://aprender.uib.es/Rdir/NotaHermanos.txt
    ", header=TRUE)
> NH4=read.table("http://aprender.uib.es/Rdir/NotaHermanosc.
    txt", header=TRUE, sep=",")
> str(NH3)
'data.frame':   87 obs. of  3 variables:
 $ Grado    : Factor w/ 2 levels "BL","BQ": 2 1 1 1 1 2 2 1 1 1
      ...
 $ Hermanos: int  1 1 1 1 2 0 1 1 1 1 ...
 $ Nota     : int  93 35 55 77 81 86 97 40 16 31 ...
> head(NH3)
  Grado Hermanos Nota
1    BQ        1   93
2    BL        1   35
3    BL        1   55
4    BL        1   77
5    BL        2   81
6    BQ        0   86
> str(NH4)
'data.frame':   87 obs. of  3 variables:
 $ Grado    : Factor w/ 2 levels "BL","BQ": 2 1 1 1 1 2 2 1 1 1
      ...
 $ Hermanos: int  1 1 1 1 2 0 1 1 1 1 ...
 $ Nota     : int  93 35 55 77 81 86 97 40 16 31 ...
> head(NH4)
  Grado Hermanos Nota
```

```
51 1     BQ          1     93
52 2     BL          1     35
53 3     BL          1     55
54 4     BL          1     77
55 5     BL          2     81
56 6     BQ          0     86
```

Además, como hemos dicho en capítulos anteriores también podremos importar nuestros ficheros desde la zona de entornos a través de Import Dataset.
Finalmente, podremos exportar un data frame a un fichero externo a través de la función write.table("data frametitle=nombre del fichero"). Esta función tiene algunos parámetros como:

- sep: Para especificar las separaciones entre columnas del fichero, por defecto son espacios en blanco.
- dec: Para indicar el separador decimal.

6.4. Crear data frame

En este capítulo veremos como crear data frame sin necesidad de importar de un fichero externo.
Para ello vamos a utilizar la función data.frame aplicada a los vectores que serán las columnas. Esta función tiene los siguientes parámetros:

- row.names: Para especificar los identificadores de las filas.
- stringsAsFactors: Con stringsAsFactors=FALSE, imponemos que los vectores de palabra se mantengan como tales en el data frame, por defecto se crean factores.

Vamos a proceder a crear nuestro data frame con las siguientes variables:

- Sexo del estudiante.
- Edad (en años) del estudiante.
- Número de hermanos.

Listing 6.6: Código de creación data frame

```
1 > Sexo=c("Hombre","Hombre","Mujer", "Hombre", "Hombre", "
    Hombre", "Mujer" )
2 > Edad=c(17,18,20,18,18,18,19)
3 > Hermanos=c(2,0,0,1,1,1,0)
4 > df.1=data.frame(Sexo,Edad,Hermanos)
5 > dfbk.1=df.1
6 > str(df.1)
7 'data.frame':    7 obs. of  3 variables:
```

```
 $ Sexo     : Factor w/ 2 levels "Hombre","Mujer": 1 1 2 1 1 1
   2
 $ Edad     : num  17 18 20 18 18 18 19
 $ Hermanos: num  2 0 0 1 1 1 0
> df.2=data.frame(Sexo,Edad,Hermanos,stringsAsFactors = FALSE,
    row.names = c("E1","E2","E3","E4","E5","E6","E7"))
> df.2
       Sexo Edad Hermanos
E1 Hombre   17        2
E2 Hombre   18        0
E3  Mujer   20        0
E4 Hombre   18        1
E5 Hombre   18        1
E6 Hombre   18        1
E7  Mujer   19        0
> str(df.2)
'data.frame':   7 obs. of  3 variables:
 $ Sexo     : chr  "Hombre" "Hombre" "Mujer" "Hombre" ...
 $ Edad     : num  17 18 20 18 18 18 19
 $ Hermanos: num  2 0 0 1 1 1 0
> df.2[c("E1","E2"),]
       Sexo Edad Hermanos
E1 Hombre   17        2
E2 Hombre   18        0
```

Finalmente, podremos editar estos datos desde el editor de datos a través de la función fix(), que la veremos en el siguiente ejemplo:

Listing 6.7: Código función fix

```
> fix(df.2)
```

Una vez la hayamos puesto veremos lo siguiente:

	row.names	Sexo	Edad	Hermanos	var5	var6	var7
1	E1	Hombre	17	2			
2	E2	Hombre	18	0			
3	E3	Mujer	20	0			
4	E4	Hombre	18	1			
5	E5	Hombre	18	1			
6	E6	Hombre	18	1			
7	E7	Mujer	19	0			
8							
9							
10							
11							
12							
13							
14							
15							
16							
17							
18							
19							

Figura 6.2: Editor de datos

En esta ventana podremos añadir nuevas variables o modificar las que tenemos a nuestro dataframe.

6.5. Cómo modificar un data frame

En este capítulo veremos cómo modificar un data frame ya creado o importado. Podremos modificar el data frame a través de las siguientes funciones:

- Cambiar todos los nombres de las variables: names(data frame)=vector con los nombres de las variables.
- Modificar los identificadores de las filas: rownames(data frame)= vector con los nombres de las filas.
- Modificar los nombres de las filas y de las columnas simultáneamente: dimnames(data frame)= list (vector con los nombres de las filas, vector con los nombres de las columnas).

Vamos a aplicar estas modificaciones al ejemplo anterior:

Listing 6.8: Código modificadores data frame

```
1 > df.1
```

```
     Sexo Edad Hermanos
1  Hombre   17        2
2  Hombre   18        0
3   Mujer   20        0
4  Hombre   18        1
5  Hombre   18        1
6  Hombre   18        1
7   Mujer   19        0
> str(df.1)
'data.frame':   7 obs. of  3 variables:
 $ Sexo     : Factor w/ 2 levels "Hombre","Mujer": 1 1 2 1 1 1
   2
 $ Edad     : num  17 18 20 18 18 18 19
 $ Hermanos: num  2 0 0 1 1 1 0
> names(df.1)=c("S","E","H")
> str(df.1)
'data.frame':   7 obs. of  3 variables:
 $ S: Factor w/ 2 levels "Hombre","Mujer": 1 1 2 1 1 1 2
 $ E: num  17 18 20 18 18 18 19
 $ H: num  2 0 0 1 1 1 0
> names(df.1)[2]="Edad"
> names(df.1)[names(df.1)=="E"]="Edad"
> str(df.1)
'data.frame':   7 obs. of  3 variables:
 $ S   : Factor w/ 2 levels "Hombre","Mujer": 1 1 2 1 1 1 2
 $ Edad: num  17 18 20 18 18 18 19
 $ H   : num  2 0 0 1 1 1 0
> rownames(df.1)=paste("Alumno", 1:7, sep="_")
> df.1
               S Edad H
Alumno_1 Hombre   17 2
Alumno_2 Hombre   18 0
Alumno_3  Mujer   20 0
Alumno_4 Hombre   18 1
Alumno_5 Hombre   18 1
Alumno_6 Hombre   18 1
Alumno_7  Mujer   19 0
> dimnames(df.1)=list(c("I","II","III", "IV","V","VI", "VII"),
    c("V1","V2","V3"))
> df.1
         V1 V2 V3
I    Hombre 17  2
II   Hombre 18  0
III   Mujer 20  0
IV   Hombre 18  1
V    Hombre 18  1
VI   Hombre 18  1
```

```
47 VII   Mujer 19   0
48 > df.1[1,2]="Joven"
49 > str(df.1)
50 'data.frame':    7 obs. of  3 variables:
51  $ V1: Factor w/ 2 levels "Hombre","Mujer": 1 1 2 1 1 1 2
52  $ V2: chr  "Joven" "18" "20" "18" ...
53  $ V3: num  2 0 0 1 1 1 0
54 > df.1[1,2]=17
55 > str(df.1)
56 'data.frame':    7 obs. of  3 variables:
57  $ V1: Factor w/ 2 levels "Hombre","Mujer": 1 1 2 1 1 1 2
58  $ V2: chr  "17" "18" "20" "18" ...
59  $ V3: num  2 0 0 1 1 1 0
```

Como podemos ver en la última parte, una vez que cambiamos el tipo de variable, toda la columna se queda con el mismo tipo de variable. Para evitarlo, podemos modificar la columna entera con la función data frame$variable=nuevo valor ó cambiar el tipo de objeto con funciones tipo as.tipo_de_objeto, que son las siguientes:

- as.factor.
- as.character.
- as.integer.
- as.numeric.

Finalmente, vamos a transformar la variable de la columna 2 de palabra a valor numérico con el siguiente ejemplo:

Listing 6.9: Código modificar variable

```
1 > df.1$V2=as.numeric(df.1$V2)
2 > str(df.1)
3 'data.frame':    7 obs. of  3 variables:
4  $ V1: Factor w/ 2 levels "Hombre","Mujer": 1 1 2 1 1 1 2
5  $ V2: num  17 18 20 18 18 18 19
6  $ V3: num  2 0 0 1 1 1 0
```

6.6. Cómo añadir filas y columnas a un data frame

En este capítulo añadiremos nuevas observaciones y nuevas variables a nuestro data frame. Primero vamos a ver cómo añadir filas a nuestro data frame:

a). Crear un nuevo data frame con los mismos nombres de las variables.

b). Concatenar las filas usando rbind.

A continuación vamos a añadirle filas al ejercicio anterior:

Listing 6.10: Código añadir filas

```
> Sexo=c("Hombre","Hombre","Mujer", "Hombre", "Hombre", "
  Hombre", "Mujer" )
> Edad=c(17,18,20,18,18,18,19)
> Hermanos=c(2,0,0,1,1,1,0)
> df.1=data.frame(Sexo,Edad,Hermanos)
> dfbk.1=df.1
> df.1
    Sexo Edad Hermanos
1 Hombre   17        2
2 Hombre   18        0
3  Mujer   20        0
4 Hombre   18        1
5 Hombre   18        1
6 Hombre   18        1
7  Mujer   19        0
> str(df.1)
'data.frame':   7 obs. of  3 variables:
 $ Sexo    : Factor w/ 2 levels "Hombre","Mujer": 1 1 2 1 1 1
   2
 $ Edad    : num  17 18 20 18 18 18 19
 $ Hermanos: num  2 0 0 1 1 1 0
> nuevas.filas=data.frame(Sexo=c("Hombre","Hombre"), Edad=c
  (18,18),Hermanos=c(1,2))
> df.1=rbind(df.1,nuevas.filas)
> df.1
    Sexo Edad Hermanos
1 Hombre   17        2
2 Hombre   18        0
3  Mujer   20        0
4 Hombre   18        1
5 Hombre   18        1
6 Hombre   18        1
7  Mujer   19        0
8 Hombre   18        1
9 Hombre   18        2
```

Finalmente, vamos a ver cómo añadir columnas a nuestro data frame, para ello tendremos dos opciones:

- Especificar el valor de la columna: data frame$Nueva= nuevos valores.
- Usando la función cbind a una variable con la misma longitud de variables que el data frame.

Vamos a volver a aplicar esta modificación al ejemplo anterior:

Listing 6.11: Código modificador columnas

```
> df.1$Nueva=df.1$Edad*df.1$Hermanos
> df.1
     Sexo Edad Hermanos Nueva
1 Hombre   17         2     34
2 Hombre   18         0      0
3  Mujer   20         0      0
4 Hombre   18         1     18
5 Hombre   18         1     18
6 Hombre   18         1     18
7  Mujer   19         0      0
8 Hombre   18         1     18
9 Hombre   18         2     36
> df.1=cbind(df.1,Grado=rep("Biologia",9))
> df.1
     Sexo Edad Hermanos Nueva    Grado
1 Hombre   17         2     34 Biologia
2 Hombre   18         0      0 Biologia
3  Mujer   20         0      0 Biologia
4 Hombre   18         1     18 Biologia
5 Hombre   18         1     18 Biologia
6 Hombre   18         1     18 Biologia
7  Mujer   19         0      0 Biologia
8 Hombre   18         1     18 Biologia
9 Hombre   18         2     36 Biologia
```

6.7. Cómo seleccionar trozos de un data frame

En este capítulo vamos a ver cómo seleccionar datos de un data frame para crear nuevas subtablas. Como en el caso de las matrices, vamos a ver la selección de filas como de columnas.
Para seleccionar datos de un data frame haremos lo siguiente:

- Índices de las filas y columnas.
- Nombre de las filas y columnas.

Siempre dentro de corchetes.

Listing 6.12: Código selección de trozos

```
> dfbk.1
     Sexo Edad Hermanos
1 Hombre   17         2
2 Hombre   18         0
3  Mujer   20         0
4 Hombre   18         1
5 Hombre   18         1
6 Hombre   18         1
```

```
7   Mujer    19         0
> str(dfbk.1)
'data.frame':    7 obs. of  3 variables:
 $ Sexo     : Factor w/ 2 levels "Hombre","Mujer": 1 1 2 1 1 1
   2
 $ Edad     : num  17 18 20 18 18 18 19
 $ Hermanos: num  2 0 0 1 1 1 0
> dfbk.1[,c(1,2)]
     Sexo Edad
1 Hombre    17
2 Hombre    18
3   Mujer    20
4 Hombre    18
5 Hombre    18
6 Hombre    18
7   Mujer    19
> dfbk.1[,-3]
     Sexo Edad
1 Hombre    17
2 Hombre    18
3   Mujer    20
4 Hombre    18
5 Hombre    18
6 Hombre    18
7   Mujer    19
> dfbk.1[,c("Sexo","Edad")]
     Sexo Edad
1 Hombre    17
2 Hombre    18
3   Mujer    20
4 Hombre    18
5 Hombre    18
6 Hombre    18
7   Mujer    19
> df.2=dfbk.1[,c("Edad","Hermanos","Sexo")]
> df.2
  Edad Hermanos    Sexo
1    17         2 Hombre
2    18         0 Hombre
3    20         0   Mujer
4    18         1 Hombre
5    18         1 Hombre
6    18         1 Hombre
7    19         0   Mujer
> df.2[1:2,]
  Edad Hermanos    Sexo
1    17         2 Hombre
```

```
55 2    18          0 Hombre
56 > df.2[df.2$Edad<19,]
57   Edad Hermanos    Sexo
58 1    17          2 Hombre
59 2    18          0 Hombre
60 4    18          1 Hombre
61 5    18          1 Hombre
62 6    18          1 Hombre
63 > df.2[df.2$Hermanos<19 & df.2$Hermanos==1,]
64   Edad Hermanos    Sexo
65 4    18          1 Hombre
66 5    18          1 Hombre
67 6    18          1 Hombre
68 > df.18=df.2[df.2$Hermanos<19 & df.2$Hermanos==1,]
69 > str(df.18)
70 'data.frame':    3 obs. of  3 variables:
71  $ Edad     : num  18 18 18
72  $ Hermanos: num  1 1 1
73  $ Sexo     : Factor w/ 2 levels "Hombre","Mujer": 1 1 1
74 > df.18=droplevels(df.18)
75 > str(df.18)
76 'data.frame':    3 obs. of  3 variables:
77  $ Edad     : num  18 18 18
78  $ Hermanos: num  1 1 1
79  $ Sexo     : Factor w/ 1 level "Hombre": 1 1 1
```

Es importante decir, que en este ejemplo hemos elegido el data frame de backup, para no volver a tener que escribir el mismo ejemplo otra vez.
Por otro lado, si queremos ampliar las posibilidades para especificar las variables que queremos extraer deberemos instalar primero el paquete dplyr y de ahí utilizar la función select, que realiza lo siguiente:

- select(data frame, starst_with("x")): Extrae del data frame las variables cuyo nombre empieza con la palabra x.
- select(data frame, ends_with("x")): Extrae del data frame las variables cuyo nombre termina con la palabra x.
- select(data frame, contains("x")): Extrae del data frame las variables cuyo nombre contiene en algún sitio la palabra x.

Vamos a ver un ejemplo de uso de esta función:

Listing 6.13: Código de la función select

```
1 > detach("package:dplyr", unload = TRUE)
2 > library(dplyr)
3
4 Attaching package: ''dplyr
```

```
5
6 The following objects are masked from 'package:'stats:
7
8     filter, lag
9
10 The following objects are masked from 'package:'base:
11
12     intersect, setdiff, setequal, union
13
14 > iris_Petal=select(iris, starts_with("Petal"))
15 > head(iris_Petal)
16   Petal.Length Petal.Width
17 1          1.4         0.2
18 2          1.4         0.2
19 3          1.3         0.2
20 4          1.5         0.2
21 5          1.4         0.2
22 6          1.7         0.4
23 > iris_Lenght=select(iris ,ends_with("Length"))
24 > head(iris_Lenght)
25   Sepal.Length Petal.Length
26 1          5.1          1.4
27 2          4.9          1.4
28 3          4.7          1.3
29 4          4.6          1.5
30 5          5.0          1.4
31 6          5.4          1.7
```

Finalmente, además de estas funciones tendremos la función subset(data frame, condición, select=columnas) que extrae del data frame las filas que cumplen la condición y las columnas especificadas en el parámetro select. Para seleccionarlas:

- Todas las filas: No se especifica ninguna condición.
- Todas las columnas: No hace falta especificar el parámetro select.

A continuación vamos a realizar un ejemplo con esta función:

Listing 6.14: Código función subset

```
1 > iris.vir=subset(iris ,Species=="virginica")
2 > head(iris.vir)
3     Sepal.Length Sepal.Width Petal.Length Petal.Width
4 101          6.3         3.3          6.0         2.5
5 102          5.8         2.7          5.1         1.9
6 103          7.1         3.0          5.9         2.1
7 104          6.3         2.9          5.6         1.8
8 105          6.5         3.0          5.8         2.2
9 106          7.6         3.0          6.6         2.1
```

```
10          Species
11 101  virginica
12 102  virginica
13 103  virginica
14 104  virginica
15 105  virginica
16 106  virginica
```

6.8. Cómo aplicar una función a un data frame

En este capítulo vamos a ver cómo aplicar funciones a las variables de un data frame, a sus columnas y veremos algunos ejemplos de aplicación.
La mejor forma de aplicar una función a todas las columnas de un data frame es la función sapply(data frame, FUN=función, na.rm=TRUE). Por defecto, na.rm=FALSE pero es conveniente añadirlo para evitar obtener NA si en alguna posición del data frame hay NA.
Vamos a aplicar esta función en el data frame del iris:

Listing 6.15: Código función sapply

```
1 > str(iris)
2 'data.frame':   150 obs. of  5 variables:
3  $ Sepal.Length: num  5.1 4.9 4.7 4.6 5 5.4 4.6 5 4.4 4.9 ...
4  $ Sepal.Width : num  3.5 3 3.2 3.1 3.6 3.9 3.4 3.4 2.9 3.1
       ...
5  $ Petal.Length: num  1.4 1.4 1.3 1.5 1.4 1.7 1.4 1.5 1.4 1.5
       ...
6  $ Petal.Width : num  0.2 0.2 0.2 0.2 0.2 0.4 0.3 0.2 0.2 0.1
       ...
7  $ Species     : Factor w/ 3 levels "setosa","versicolor",..:
      1 1 1 1 1 1 1 1 1 1 ...
8 > sapply(iris[,1:4],FUN=mean)
9 Sepal.Length  Sepal.Width Petal.Length  Petal.Width
10     5.843333     3.057333     3.758000     1.199333
11 > sapply(iris[,1:4],FUN=sum)
12 Sepal.Length  Sepal.Width Petal.Length  Petal.Width
13        876.5        458.6        563.7        179.9
14 > f=function(x){sqrt(sum(x^2))}
15 > sapply(iris[,1:4],FUN=f)
16 Sepal.Length  Sepal.Width Petal.Length  Petal.Width
17     72.27621     37.82063     50.82037     17.38764
18 > D=data.frame(V1=c(1,2,NA,3),V2=c(2,5,2,NA))
19 > D
20   V1 V2
21 1  1  2
22 2  2  5
```

```
3 NA  2
4  3 NA
> sapply(D,FUN=mean)
V1 V2
NA NA
> sapply(D,FUN=mean,na.rm=TRUE)
V1 V2
```

Por otro lado, la función aggregate permite aplicar una función a variables de un data frame clasificadas por los niveles de un, o más de un factor. Para ello utilizaremos la función aggregate(variable~factor, data=data frame, FUN=función), que realiza lo siguiente:

- Para aplicar la función a más de una variable: cbind(variable1,variable2,...)~factor.
- Para separar las variables mediante más de un factor: variable~factor1+factor2+...

El resultado será un data frame.
Vamos a realizar un ejemplo realizando la media de cada una de las medias de las longitudes de los pétalos:

Listing 6.16: Código función aggregate

```
> aggregate(Petal.Length~Species, data=iris,FUN=mean, na.rm=
    TRUE)
     Species Petal.Length
1     setosa        1.462
2 versicolor        4.260
3  virginica        5.552
> aggregate(cbind(Petal.Length, Petal.Width)~Species, data=
    iris,FUN=mean, na.rm=TRUE)
     Species Petal.Length Petal.Width
1     setosa        1.462       0.246
2 versicolor        4.260       1.326
3  virginica        5.552       2.026
```

Seguidamente, vamos a realizar otro ejemplo con el paquete alr4 que contiene la tabla de datos **Rateprof**, con los resultados globales de la evaluación de un grupo de profesores universitarios por parte de sus estudiantes.
Algunas variables:

- **gender**: Sexo del profesor.
- **pepper**: Indica si las encuestas se le ha considerado mayoritariamente atractivo o no.
- **clarity**: Valora la claridad de exposición.
- **easiness**: Valora la accesibilidad del profesor.

Vamos a calcular la media de estas dos últimas variables poniéndolas al lado de atractivo.

Listing 6.17: Código ejemplo paquete alr4

```
> library(alr4)
> aggregate(cbind(clarity,easiness)~gender+pepper, data=
   Rateprof, FUN=mean)
  gender pepper  clarity easiness
1 female     no 3.341391 3.147606
2   male     no 3.451456 2.999056
3 female    yes 4.345082 3.599128
4   male    yes 4.371824 3.689741
```

6.9. Cómo añadir las variables de un data frame al entorno global

En este capítulo veremos como definir las variables de un data frame en un entorno global de R para poder acceder a ellas escribiendo únicamente su nombre.
Para referirnos a una variable de un data frame solemos escribir data frame$variable, pero tenemos dos funciones para acceder a ellas.
Por un lado la función attach que nos permite definir sus variables globales y referirnos a ellas únicamente con su nombre, para utilizarla usaríamos attach(data frame).
Por otro lado, tenemos la función detach que devuelve a la situación original, eliminando del entorno global las variables del data frame, para utilizarla usaríamos detach (data frame).
Como ejemplo, vamos añadir las variables de iris al entorno global de R:

Listing 6.18: Código añadir variables de un data frame al entorno global

```
> Petal.Lenght
Error: object 'Petal.Lenght' not found
> attach(iris)
> Petal.Length
  [1] 1.4 1.4 1.3 1.5 1.4 1.7 1.4 1.5 1.4 1.5 1.5 1.6
 [13] 1.4 1.1 1.2 1.5 1.3 1.4 1.7 1.5 1.7 1.5 1.0 1.7
 [25] 1.9 1.6 1.6 1.5 1.4 1.6 1.6 1.5 1.5 1.4 1.5 1.2
 [37] 1.3 1.4 1.3 1.5 1.3 1.3 1.3 1.6 1.9 1.4 1.6 1.4
 [49] 1.5 1.4 4.7 4.5 4.9 4.0 4.6 4.5 4.7 3.3 4.6 3.9
 [61] 3.5 4.2 4.0 4.7 3.6 4.4 4.5 4.1 4.5 3.9 4.8 4.0
 [73] 4.9 4.7 4.3 4.4 4.8 5.0 4.5 3.5 3.8 3.7 3.9 5.1
 [85] 4.5 4.5 4.7 4.4 4.1 4.0 4.4 4.6 4.0 3.3 4.2 4.2
 [97] 4.2 4.3 3.0 4.1 6.0 5.1 5.9 5.6 5.8 6.6 4.5 6.3
[109] 5.8 6.1 5.1 5.3 5.5 5.0 5.1 5.3 5.5 6.7 6.9 5.0
[121] 5.7 4.9 6.7 4.9 5.7 6.0 4.8 4.9 5.6 5.8 6.1 6.4
[133] 5.6 5.1 5.6 6.1 5.6 5.5 4.8 5.4 5.6 5.1 5.1 5.9
[145] 5.7 5.2 5.0 5.2 5.4 5.1
> Sepal.Width=rep(0,150)
> Sepal.Width
```

```
  [1] 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 [25] 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 [49] 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 [73] 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 [97] 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
[121] 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
[145] 0 0 0 0 0 0
> head(iris)
  Sepal.Length Sepal.Width Petal.Length Petal.Width
1          5.1         3.5          1.4         0.2
2          4.9         3.0          1.4         0.2
3          4.7         3.2          1.3         0.2
4          4.6         3.1          1.5         0.2
5          5.0         3.6          1.4         0.2
6          5.4         3.9          1.7         0.4
  Species
1  setosa
2  setosa
3  setosa
4  setosa
5  setosa
6  setosa
> detach(iris)
> Petal.Length
Error: object 'Petal.Length' not found
```

Capítulo 7

Función plot

En este capítulo veremos la función plot que se encarga de representar en un gráfico los distintos datos.
La función plot es una función genérica de R para dibujar gráficos sencillos en los ejes XY. Tiene los siguientes usos:

- plot(x,y): Dibuja la familia de puntos $(x_1, y_1), ..., (x_n, y_n)$ donde $x = (x_1, ..., x_n)$ e $y = (y_1, ..., y_n)$.
- plot(x): Dibuja la familia de puntos $(1, x_1), ..., (1, x_n)$ donde $x = (x_1, ..., x_n)$.
- plot(f): Dibuja el gráfico de la función f definida mediante function.

Vamos a ver un ejemplo de cada uso de la función plot:

Listing 7.1: Código usos función plot

```
> #(1,1),(2,3),(3,5),(4,1),(7,8)
> x=c(1,2,3,4,7)
> y=c(1,3,5,1,8)
> plot(x,y)
```

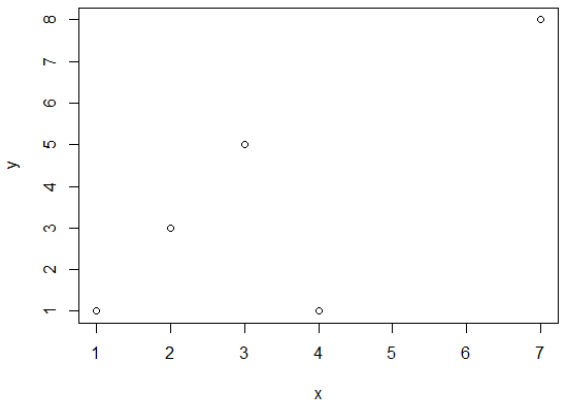

Figura 7.1: Función plot(x,y)

Podremos verlo más de cerca con la opción Zoom o podremos guardarlo como imagen con la opción Export.

Listing 7.2: Código usos función plot

```
> #(1,1),(2,3),(3,5),(4,1),(7,8)
> x=c(1,2,3,4,7)
> y=c(1,3,5,1,8)
> plot(x)
> 1:5
[1] 1 2 3 4 5
> x
[1] 1 2 3 4 7
```

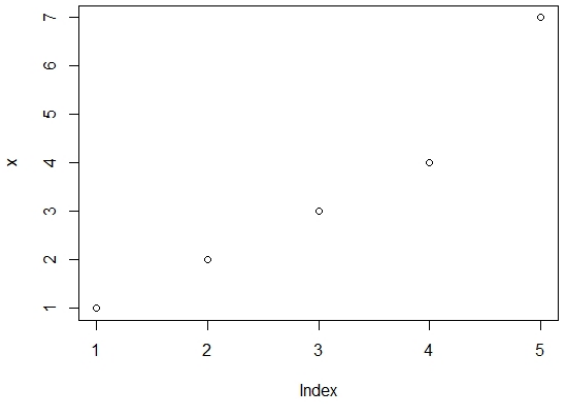

Figura 7.2: Función plot(x)

Listing 7.3: Código usos función plot

```
> f=function(x){sqrt(x)}
> plot(f)
```

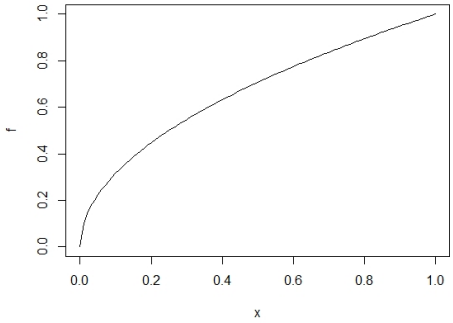

Figura 7.3: Función plot(f)

7.1. Parámetros

En este capítulo veremos los parámetros para modificar el gráfico y ajustarlo a nuestras necesidades.
Disponemos de unos tipos de parámetros:

- **Aspecto exterior**: Especifican el título y los nombres de los ejes de coordenadas.
- **Aspecto de los puntos**: Especifican el estilo, el tamaño y el color de los puntos.
- **Tipo de gráfico**: Puntos aislados, unidos por líneas, etc.
- **Ejes de coordenadas**: Especifican los rangos de los ejes y las posiciones de las marcas.

Podemos ver más parámetros a través de la ayuda con la función plot.

7.1.1. Parámetros de aspecto exterior

- main: Especifica el título.
- xlab, ylab: Especifican las etiquetas de los ejes de coordenadas. En caso de usar una fórmula matemática, hay que usar expression.

En ocasiones, es posible que el título o nombres de los ejes queden fuera de los márgenes del gráfico. Para modificarlos, se tiene que ejecutar (antes del plot).

- par: Modifica el aspecto general del gráfico.
- mar: Modifica los márgenes del gráfico.

Vamos a ejecutar una gráfica sencilla modificando su aspecto exterior:

Listing 7.4: Código modificación aspecto exterior

```
> f=function(x){x^3}
> plot(f)
> plot(f, main="Gráfico de la función cubo",ylab = "f(x)=x^3")
> viejo.par=par()
> par(mar=c(5,4,4,2)+0.5)
> plot(f,main="Gráfico de la función cubo",ylab=expression(f(x
    )==x^3))
```

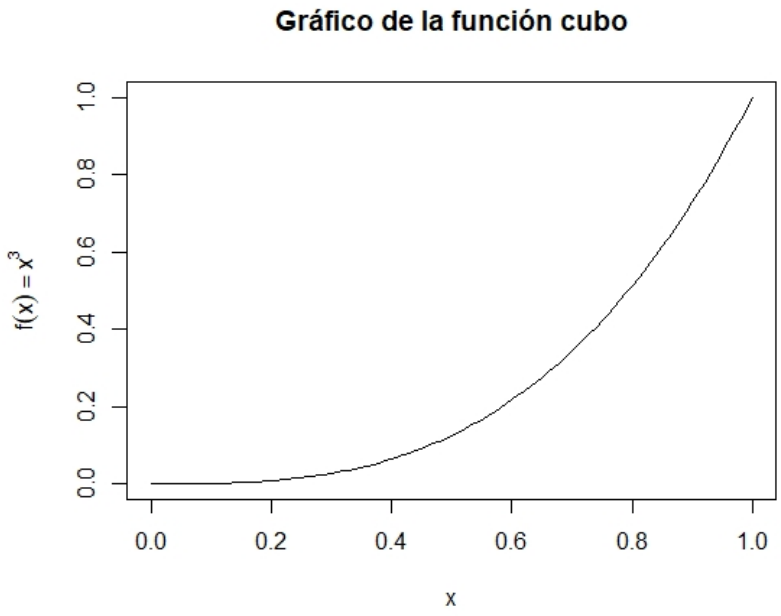

Figura 7.4: Figura modificada márgenes y aspecto exterior

7.1.2. Parámetros de aspecto de los puntos

Los parámetros de los puntos se pueden modificar a través de las siguientes funciones:

- pch: Especifica el estilo de los puntos.

Figura 7.5: Número con estilo de punto

- cex: Especifica el tamaño de los puntos en relación al tamaño por defecto.
- col: Especifica el color del borde de los puntos. En el caso de usar puntos con estilo pch de 21 a 25, se puede especificar un color de relleno con bg.

Vamos a realizar un nuevo ejemplo modificando sus puntos:

Listing 7.5: Código modificación aspecto de los puntos

```
> x=c(1,3,6,7)
> y=c(2,3,4,1)
> plot(x,y)
> plot(x,y, pch=2,col="red",cex=2)
```

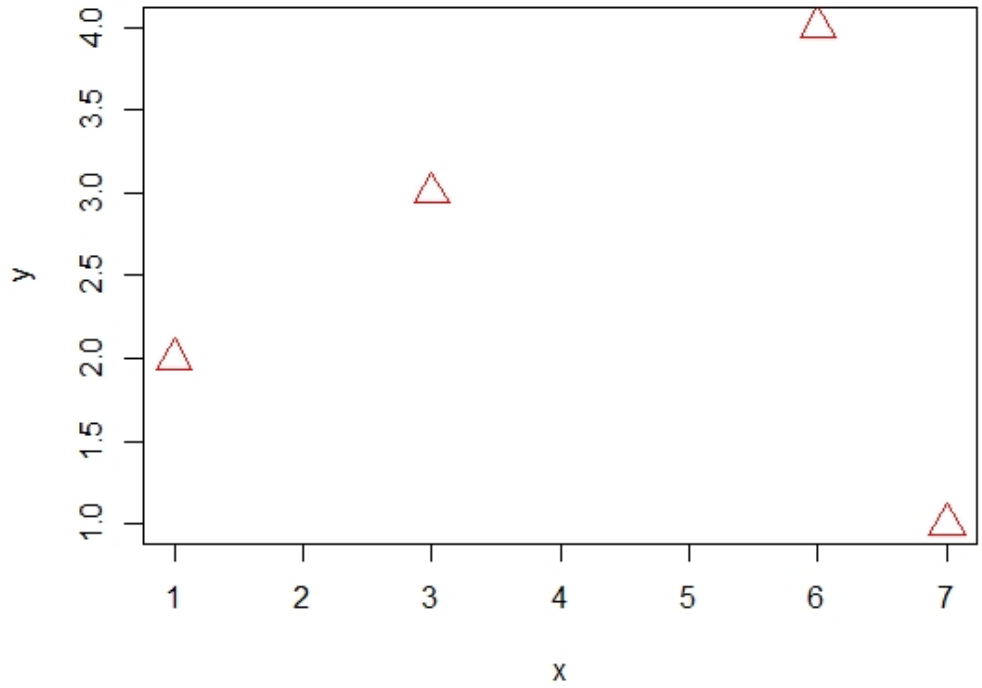

Figura 7.6: Primera modificación puntos

Seguimos con el mismo ejemplo, pero esta vez les pondremos borde negro y los rellenaremos de algún color:

Listing 7.6: Código modificación aspecto de los puntos

```
> plot(x,y, pch=24,col="black",bg="green",cex=2)
```

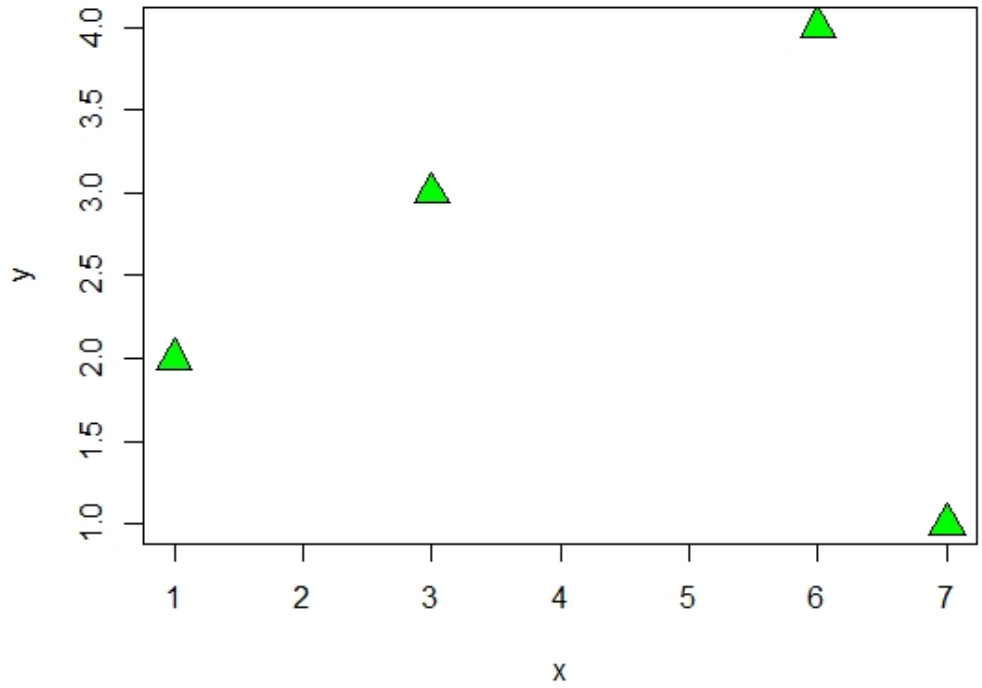

Figura 7.7: Segunda modificación puntos

7.1.3. Parámetros de tipo de gráfico

- type: Indica el tipo de gráfico.
  - "p": Puntos como simples puntos. Valor por defecto.
  - "l": Puntos unidos por líneas rectas. No se ven los puntos.
  - "b": Puntos unidos por líneas rectas. Se ven los puntos, las líneas no entran en los signos de los puntos.
  - "o": Como "b" pero ahora las líneas sí entran.
  - "h": Dibuja un histograma de líneas.
  - "s": Dibuja un diagrama de escalones.
  - "n": Sólo dibuja el exterior del gráfico.

Vamos a proceder a realizar un ejemplo modificando el tipo de gráfico:

Listing 7.7: Código modificando el tipo de gráfico

```
1 > x=c(1,3,6,7)
2 > y=c(2,3,4,1)
3 > plot(x,y, type = "p")
```

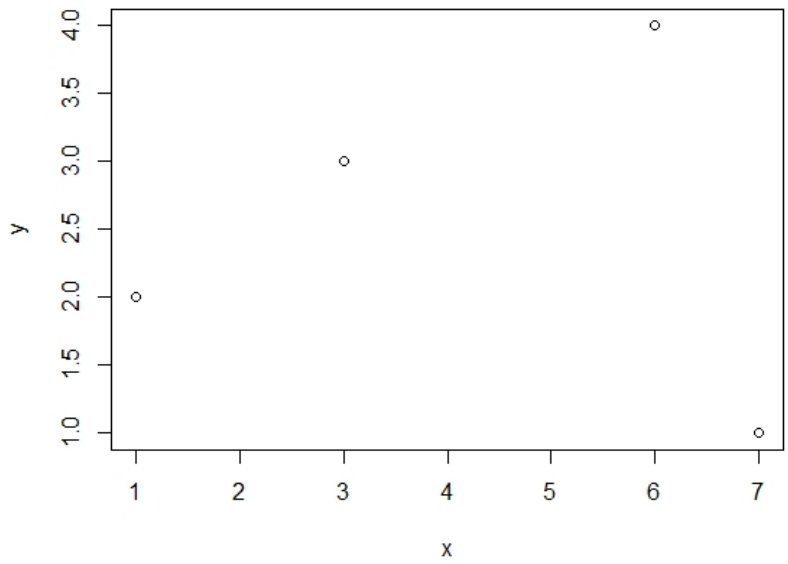

Figura 7.8: Primera modificación del gráfico

Listing 7.8: Código modificando el tipo de gráfico

```
> x=c(1,3,6,7)
> y=c(2,3,4,1)
> plot(x,y, type = "l")
```

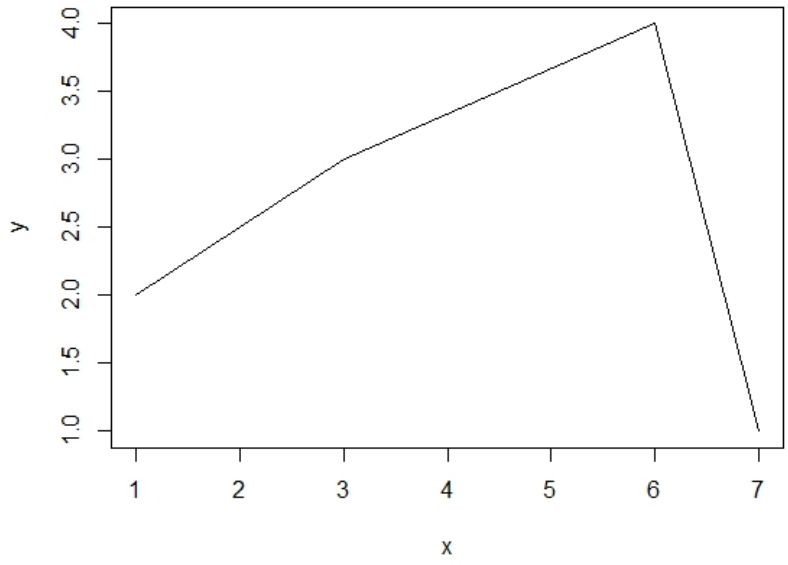

Figura 7.9: Segunda modificación del gráfico

Listing 7.9: Código modificando el tipo de gráfico

```
> x=c(1,3,6,7)
> y=c(2,3,4,1)
> plot(x,y, type = "b")
```

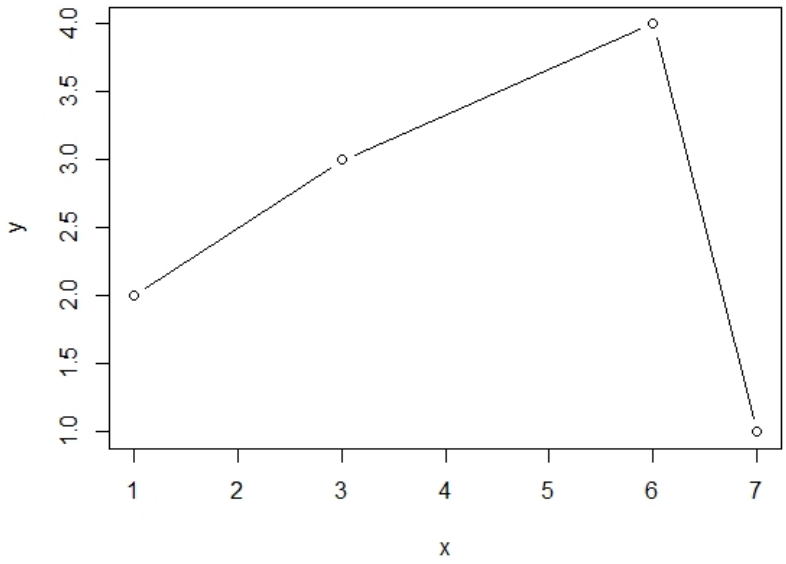

Figura 7.10: Tercera modificación del gráfico

Listing 7.10: Código modificando el tipo de gráfico

```
> x=c(1,3,6,7)
> y=c(2,3,4,1)
plot(x,y, type = "o")
```

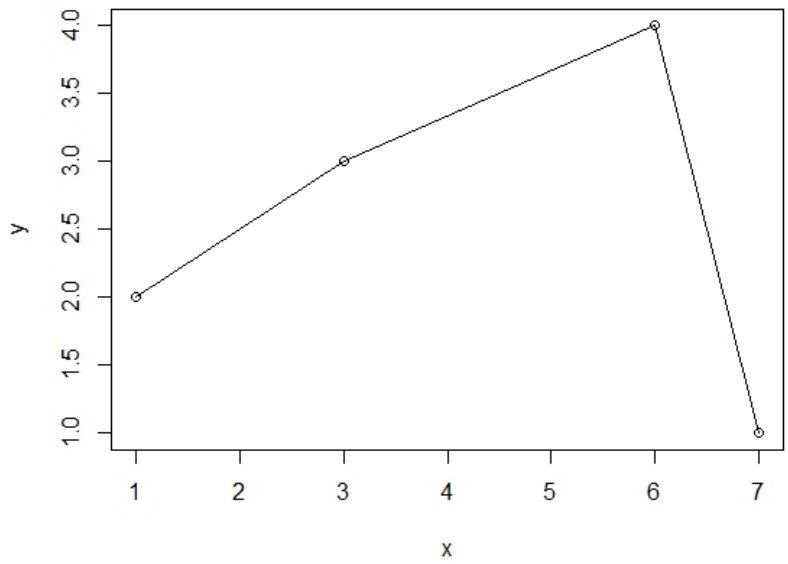

Figura 7.11: Cuarta modificación del gráfico

Listing 7.11: Código modificando el tipo de gráfico

```
> x=c(1,3,6,7)
> y=c(2,3,4,1)
plot(x,y, type = "h")
```

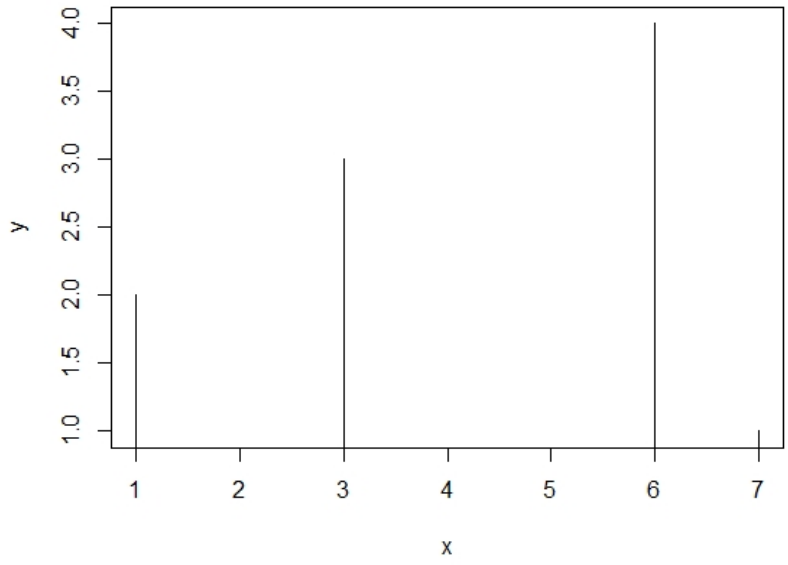

Figura 7.12: Quinta modificación del gráfico

Listing 7.12: Código modificando el tipo de gráfico

```
> x=c(1,3,6,7)
> y=c(2,3,4,1)
plot(x,y, type = "s")
```

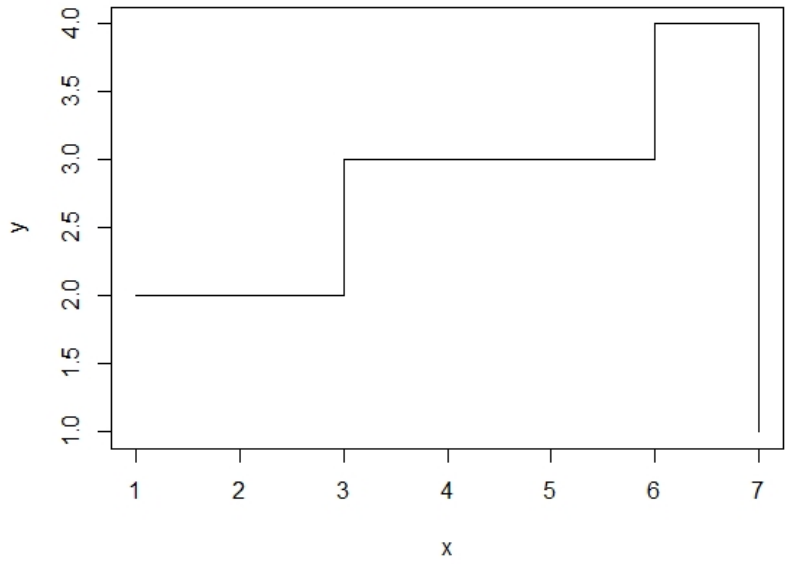

Figura 7.13: Sexta modificación del gráfico

Listing 7.13: Código modificando el tipo de gráfico

```
> x=c(1,3,6,7)
> y=c(2,3,4,1)
plot(x,y, type = "n")
```

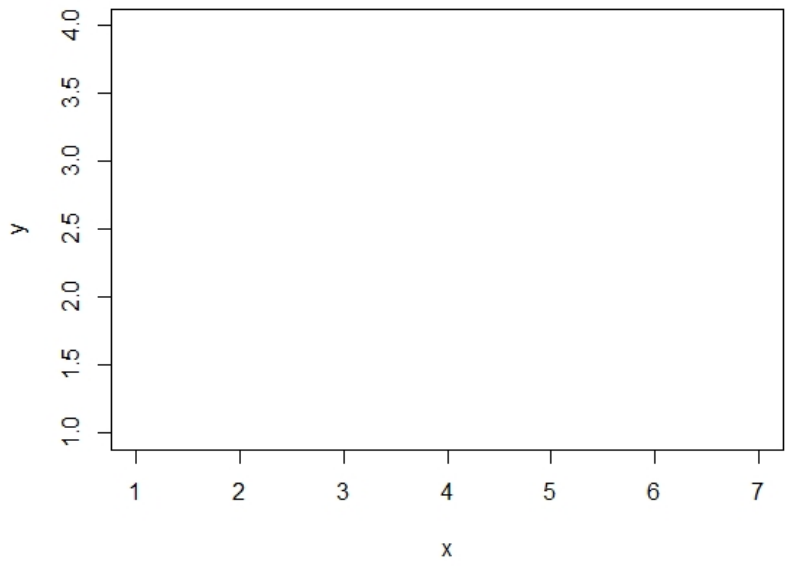

Figura 7.14: Séptima modificación del gráfico

En el caso de un gráfico de estilo “l”, se puede modificar el estilo de las líneas.

- col: Especifica el color.
- lty: Especifica el tipo de línea.
  - **1**: Continua. Valor por defecto.
  - **2**: Discontinua.
  - **3**: Línea de puntos.
  - **4**: Línea de puntos y rayas.
- lwd: Especifica el grosor de línea en relación al valor por defecto.

Vamos a modificar nuestro gráfico de estilo “l” con la mayor parte de modificaciones que podamos:

Listing 7.14: Código modificación gráfico estilo l

```
> x=c(1,3,6,7)
> y=c(2,3,4,1)
> plot(x,y, type = "l", col="blue",lty=2,lwd=3)
```

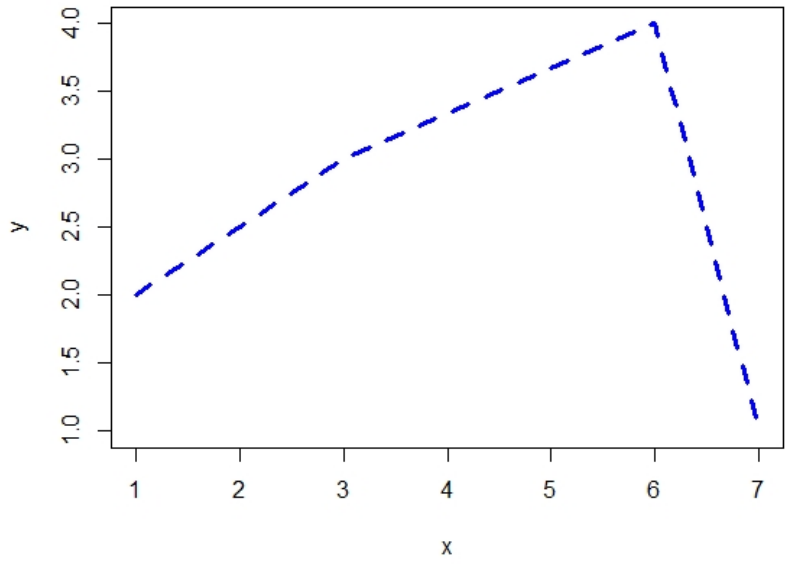

Figura 7.15: Gráfico modificado tipo l

7.1.4. Parámetros de ejes de coordenadas

- xlim, ylim: Especifican los rangos de los ejes mediante un vector con los extremos de los rangos.
- xaxp, yaxp: Especifican las marcas de los ejes como un vector c(n1,n2,m), dibujando m+1 marcas entre los valores n1 y n2.

Vamos a hacer un ejemplo de una función modificando los parámetros de los ejes de coordenadas:

Listing 7.15: Código modificando ejes de coordenadas

```
> f=function(x){exp(x)}
> plot(f)
> plot(f,xlim = (0,10))
> plot(f,xlim=c(0,10),xaxp=c(0,10,10),)
```

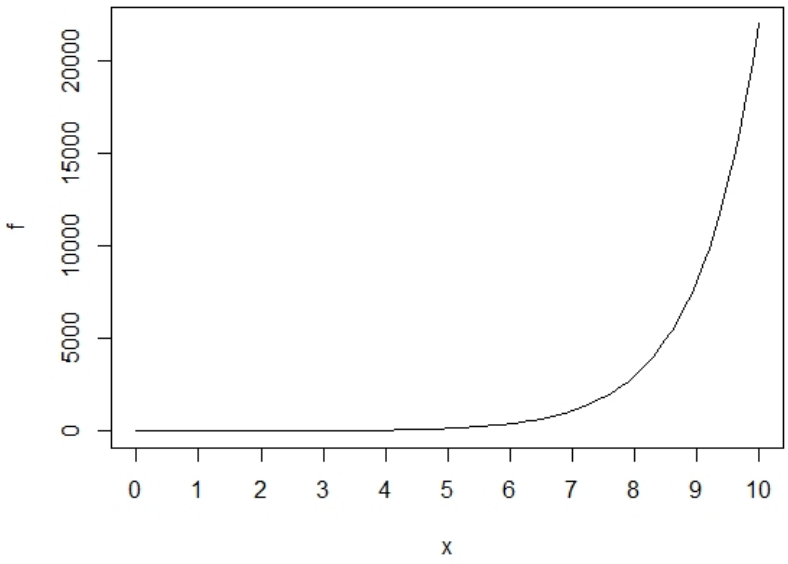

Figura 7.16: Gráfica modificada ejes

7.2. Cómo añadir elementos a un gráfico

En este capítulo aprenderemos añadir elementos a un gráfico a través de unas funciones adecuadas.

7.2.1. Añadir puntos

Podremos añadir puntos mediante la función points(x,y), que permite añadir puntos de coordenadas x e y al gráfico. Se puede indicar su color, estilo, etc. mediante los parámetros específicos.
Vamos a realizar un ejemplo añadiendo puntos a una función:

Listing 7.16: Código añadiendo puntos

```
> f=function(x){x^2}
> plot(f,xlim=c(-1,1),ylim=c(-1,1))
> points(0,0,pch=16)
```

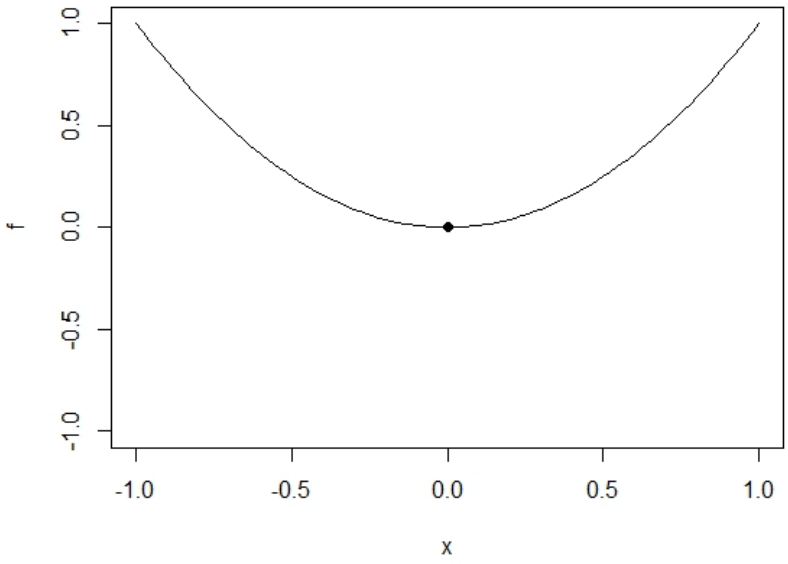

Figura 7.17: Gráfica con punto añadido

7.2.2. Añadir rectas

Podremos añadir rectas mediante la función abline, según el tipo de recta podremos añadir:

- abline(a,b) añade la recta $y = a + bx$.
- abline(v=xo) añade la recta vertical $x = xo$.
- abline(h=yo) añade la recta horizontal $y = yo$.

Se puede indicar el color, el grosor, etc. de la recta mediante los parámetros específicos. Vamos a dibujar una recta tangente al punto anterior:

Listing 7.17: Código añadir recta

```
> f=function(x){x^2}
> plot(f,xlim=c(-1,1),ylim=c(-1,1))
> points(0,0,pch=16)
> abline(h=0, col="green")
```

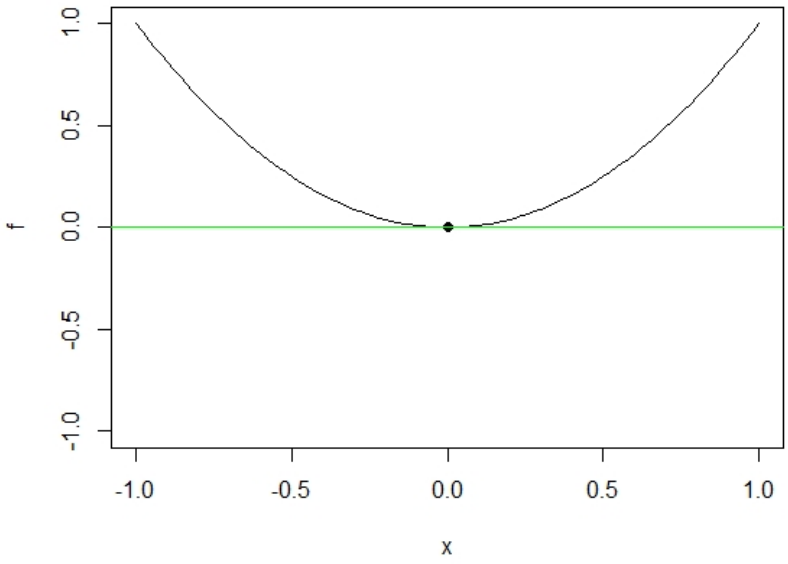

Figura 7.18: Gráfica con punto añadido y recta añadida

7.2.3. Añadir curvas

La función curve permite con el parámetro add=TRUE añadir una curva al gráfico. Si no añadimos el add=TRUE, curve tiene el mismo comportamiento que plot con la ventaja que sabe interpretar expresiones algebraicas con la variable x sin necesidad de utilizar function previamente.
Vamos a añadir al ejemplo de arriba una curva a la tangente previamente dibujada:

Listing 7.18: Código añadir curva

```
> f=function(x){x^2}
> plot(f,xlim=c(-1,1),ylim=c(-1,1))
> points(0,0,pch=16)
> abline(h=0, col="green")
> curve(-x^2, col="red",add=TRUE)
```

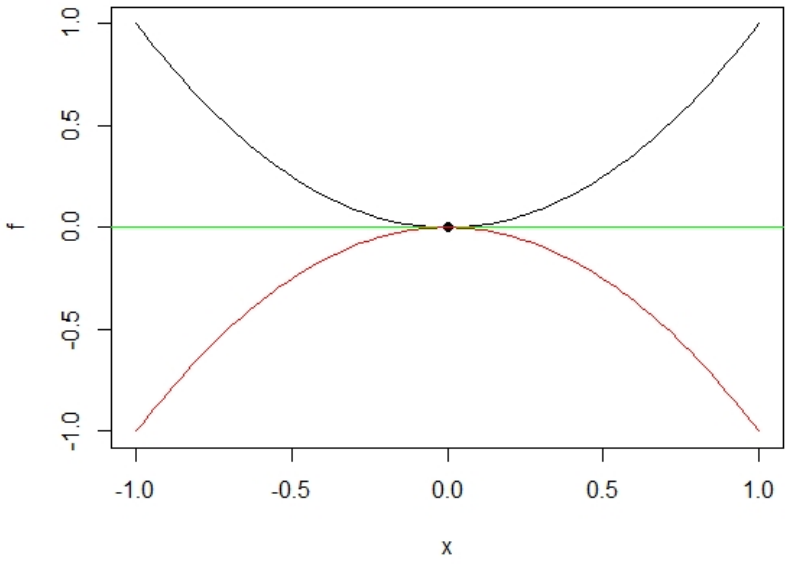

Figura 7.19: Gráfica con punto añadido, recta añadida y curva añadida

7.2.4. Añadir texto

Para añadir texto utilizaremos la función text(x,y,labels=...,pos=...), que permite añadir el texto especificado en labels, mediante comillas o expression, en (x, y). La posición exacta depende del valor de pos:

- **pos=1**: Abajo del punto.
- **pos=2**: Izquierda del punto.
- **pos=3**: Arriba del punto.
- **pos=4**: Derecha del punto.
- **pos=NULL**: Encima del punto. Valor por defecto.

Vamos a indicar que el punto marcado es el punto de intersección entre las dos curvas y la recta:

Listing 7.19: Código añadir texto

```
> f=function(x){x^2}
> plot(f,xlim=c(-1,1),ylim=c(-1,1))
> points(0,0,pch=16)
> abline(h=0, col="green")
> curve(-x^2, col="red",add=TRUE)
> text(0,0,labels="pt.intersección", pos=1)
```

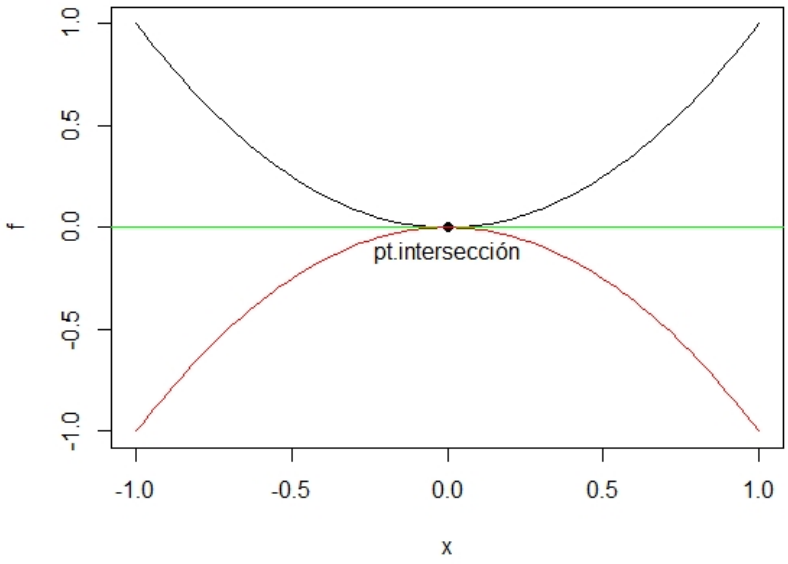

Figura 7.20: Gráfica con punto añadido, recta añadida, curva añadida y texto añadido

7.2.5. Añadir una leyenda

En gráficos con muchas curvas o rectas mediante la función legend(posición, legend=..., parámetro=...,...,parámetro=...)nos permite añadir una leyenda al gráfico activo. La posición indica donde queremos situar la leyenda, el vector legend contiene los nombres de las distintas curvas y cada parámetro contiene un vector de los valores del parámetro sobre las distintas curvas.
Vamos a añadir una leyenda al gráfico que hemos utilizado para todos los ejemplos:

Listing 7.20: Código añadir leyenda

```
> f=function(x){x^2}
> plot(f,xlim=c(-1,1),ylim=c(-1,1))
> points(0,0,pch=16)
> abline(h=0, col="green")
> curve(-x^2, col="red",add=TRUE)
> text(0,0,labels="pt.intersección", pos=1)
> legend("topleft", legend=c(expression(x^2), expression(-x^2)
    , expression(y=0)), col=c("black","red","green"),lwd=3)
```

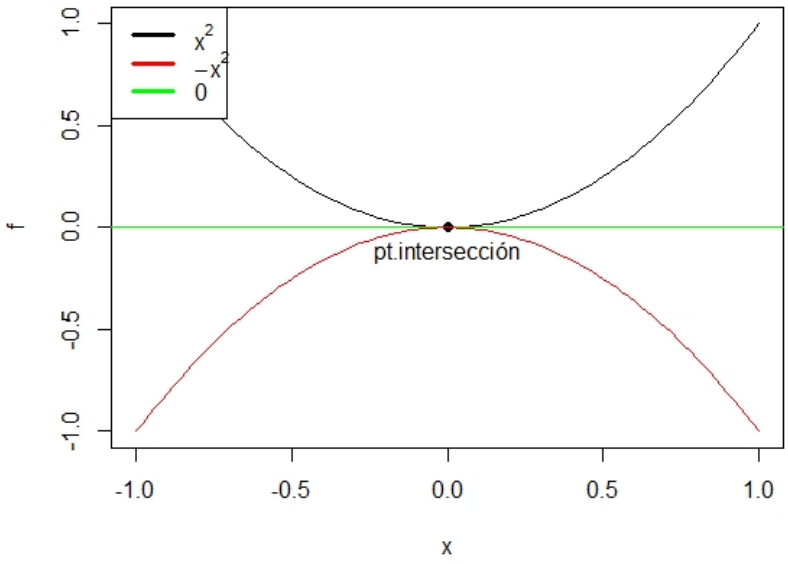

Figura 7.21: Gráfica con leyenda añadida

Capítulo 8

Tablas de frecuencias, diagramas de barras, otros gráficos básicos para datos cualitativos y un ejemplo completo

8.1. Tablas de frecuencias

8.1.1. Tablas unidimensionales de frecuencias

Vamos a poner un ejemplo de una variable cualitativa, es decir, que sólo se puede comparar en número.

> Mujer, Mujer, Hombre, Mujer, Mujer, Mujer, Mujer, Mujer, Mujer, Hombre, Mujer, Hombre, Hombre, Mujer, Mujer, Hombre, Mujer, Mujer, Mujer, Mujer, Hombre.

A partir de estos datos vamos a sacar sus frecuencias absolutas, relativas y porcentajes.
Frecuencias absolutas:
Hombre: 6, Mujer: 14.
Frecuencias relativas:
Hombre:$\frac{6}{20} = 0{,}3$, Mujer: $\frac{14}{20} = 0{,}7$.
Porcentajes:
Hombre: 30 %, Mujer: 70 %.
La moda sería los objetos con la frecuencia relativa o absoluta más grande.
Las frecuencias absoluta y relativa se resumen en la tabla de frecuencias, de este ejemplo sería la siguiente:

Cuadro 8.1: Tabla de frecuencias del ejemplo

Sexo	**nj**	**fj**	**%**
Hombre	6	0.3	30 %
Mujer	14	0.7	70 %
Total	20	1	100 %

Ahora vamos a realizar un ejemplo de tabla unidimensionales de frecuencia en R:

Listing 8.1: Código tabla unidimensional de frecuencia

```
> x=c(3,2,5,1,3,1,5,6,2,2,2,1,3,5,2)
#Frecuencias absolutas
> table(x)
x
1 2 3 5 6
3 5 3 3 1
#Nombres tabla de frecuencia
> names(table(x))
[1] "1" "2" "3" "5" "6"
> table(x)[4]
5
3
> table(x)[3]
3
3
#Sumar valores tabla de frecuencia
> sum(table(x))
[1] 15
#Raíces cuadradas
> sqrt(table(x))
x
       1        2        3        5        6
1.732051 2.236068 1.732051 1.732051 1.000000
#Tabla de frecuencias relativas
> prop.table(table(x))
x
         1          2          3          5
0.20000000 0.33333333 0.20000000 0.20000000
         6
0.06666667
#Moda
names(which(table(x)==3))
> names(which(table(x)==3))
[1] "1" "3" "5"
names(which(table(x)==max(table(x))))
> names(which(table(x)==max(table(x))))
[1] "2"
```

8.1.2. Tablas bidimensionales de frecuencias

Son tablas de frecuencias de dos variables. Vamos a ver un ejemplo de una de ellas:

Cuadro 8.2: Tabla de respuestas Si o no de hombre y mujer

Variable	Valores							
Respuesta	No	No	Si	No	Si	No	No	Si
Sexo	M	M	M	H	H	H	H	H

Cuadro 8.3: Tabla bidimensional de frecuencias

	Sexo	
Respuestas	H	M
No	3	2
Si	2	1

Vamos a proceder a hallar esta tabla en R:

Listing 8.2: Código tabla bidimensional

```
Respuestas=c("No","No","Si","No","Si","No","No", "Si")
Sexo=c("M","M","M","H","H","H","H","H")#H es hombre, M es
    mujer

table(Respuestas,Sexo)
           Sexo
Respuestas H M
        No 3 2
        Si 2 1
#Referise entrada
table(Respuestas,Sexo)[1,2]
[1] 2
table(Respuestas,Sexo)["No","M"]
[1] 2
```

Tipos de frecuencias relativas

Como en el caso anterior, la función proptable halla las frecuencias relativas de los pares de variables. En este caso, tenemos dos tipos:

- **Frecuencias relativas globales**: Fracción de individuos que pertenecen a ambos niveles respecto del total de la muestra.
- **Frecuencias relativas marginales**: Fracción de individuos que pertenecen al segundo nivel respecto del total de la subpoblación definida por el primer nivel.

Vamos a seguir con el ejemplo anterior para hallar sus frecuencias relativas:

Listing 8.3: Código frecuencias relativas globales y marginales

```
#Frecuencias relativas globales
prop.table(table(Respuestas,Sexo))
```

```
3             Sexo
4 Respuestas      H      M
5         No  0.375  0.250
6         Si  0.250  0.125
7 #Frecuencis relativas marginales
8 #Respuestas
9 prop.table(table(Respuestas,Sexo), margin = 1)
10            Sexo
11 Respuestas          H         M
12        No  0.6000000 0.4000000
13        Si  0.6666667 0.3333333
14 #Sexo
15 prop.table(table(Respuestas,Sexo), margin = 2)
16            Sexo
17 Respuestas          H         M
18        No  0.6000000 0.6666667
19        Si  0.4000000 0.3333333
```

8.1.3. Tablas multidimensionales de frecuencias

Son tablas de frecuencias con cualquier número de variables.
A continuación vamos a ver un ejemplo de muchas variables cualitativas:

Cuadro 8.4: Tabla con tres variables

Variable	Valores							
Respuesta	No	No	Si	No	Si	No	No	Si
Sexo	M	M	M	H	H	H	H	H
País	Fra	Ale	Ita	Ita	Ita	Ita	Ale	Fra

Cuadro 8.5: Tabla tridimensional

		Respuesta	
País	**Sexo**	No	Si
Ale	H	1	0
	M	1	0
Ita	H	2	1
	M	0	1
Fra	H	0	1
	M	1	0

Vamos a proceder a hallar su tabla en R:

Listing 8.4: Código tabla tridimensional

```
1 Respuestas=c("No","No","Si","No","Si","No","No","Si")
```

```
Sexo=c("M","M","M","H","H","H","H","H")#H es hombre, M es
    mujer
País=c("Fra","Ale","Ita","Ita","Ita","Ita","Ale","Fra")

table(Sexo,Respuestas,País)
, , País = Ale

     Respuestas
Sexo No Si
   H  1  0
   M  1  0

, , País = Fra

     Respuestas
Sexo No Si
   H  0  1
   M  1  0

, , País = Ita

     Respuestas
Sexo No Si
   H  2  1
   M  0  1
ftable(Sexo,Respuestas,País)
                  País Ale Fra Ita
Sexo Respuestas
H    No                 1   0   2
     Si                 0   1   1
M    No                 1   1   0
     Si                 0   0   1
ftable(Sexo,Respuestas,País,col.vars=c("Sexo","Respuestas"))
     Sexo          H     M
     Respuestas No Si No Si
País
Ale              1  0  1  0
Fra              0  1  1  0
Ita              2  1  0  1
#Referirse entrada
table(Sexo,Respuestas,País)["H","Si","Ita"]
[1] 1
table(Sexo,Respuestas,País)[,"Si","Ita"]
H M
1 1
table(Sexo,Respuestas,País)[,,"Ita"]
     Respuestas
```

```
Sexo No Si
   H  2  1
   M  0  1
#Frecuencias relativas globales
prop.table(table(Sexo,Respuestas,País))
, , País = Ale

     Respuestas
Sexo    No    Si
   H 0.125 0.000
   M 0.125 0.000

, , País = Fra

     Respuestas
Sexo    No    Si
   H 0.000 0.125
   M 0.125 0.000

, , País = Ita

     Respuestas
Sexo    No    Si
   H 0.250 0.125
   M 0.000 0.125
prop.table(ftable(Sexo,Respuestas,País))
                 País    Ale    Fra    Ita
Sexo Respuestas
H    No               0.125  0.000  0.250
     Si               0.000  0.125  0.125
M    No               0.125  0.125  0.000
     Si               0.000  0.000  0.125
#Frecuencias marginales por país
prop.table(table(Sexo,Respuestas,País),margin=3)
, , País = Ale

     Respuestas
Sexo   No   Si
   H 0.50 0.00
   M 0.50 0.00

, , País = Fra

     Respuestas
Sexo   No   Si
   H 0.00 0.50
   M 0.50 0.00
```

```
96
97 , , País = Ita
98
99      Respuestas
100 Sexo    No    Si
101    H 0.50  0.25
102    M 0.00  0.25
103 #Sexo y país
104 prop.table(table(Sexo,Respuestas,País),margin=c(1,3))
105 , , País = Ale
106
107      Respuestas
108 Sexo          No          Si
109    H 1.0000000  0.0000000
110    M 1.0000000  0.0000000
111
112 , , País = Fra
113
114      Respuestas
115 Sexo          No          Si
116    H 0.0000000  1.0000000
117    M 1.0000000  0.0000000
118
119 , , País = Ita
120
121      Respuestas
122 Sexo          No          Si
123    H 0.6666667  0.3333333
124    M 0.0000000  1.0000000
```

Como podemos ver, R muestra la tabla como una lista de tablas bidimensionales, pero con ftable las muestra en un formato plano. Además de realizar la tabla hemos calculado las frecuencias relativas globales y marginales.

8.2. Tablas de frecuencias a partir de data frames

En este capítulo explicaremos cómo calcular frecuencias absolutas a partir de un data frame.
Para explicar cómo realizarlo vamos a utilizar los datos de la siguiente dirección: http://aprender.uib.es/Rdir/bebenerg.txt. Donde encontramos las siguientes variables:

- **sexo**: Sexo de los estudiantes.
- **estudio**: Grado en el que están matriculados.
- **bebe**: Si consumen bebidas energéticas.

Listing 8.5: Código de tabla de frecuencias a partir de data frames

```
Beb_Energ=read.table("http://aprender.uib.es/Rdir/bebenerg.txt
    ", header=TRUE, encoding="UTF-8")
head(Beb_Energ)
          estudio bebe    sexo
1     Informática   No   Mujer
2     Matemáticas   No Hombre
3 Ing.Industrial   Sí   Mujer
4     Informática   Sí Hombre
5 Ing.Industrial   No   Mujer
6     Matemáticas   No   Mujer
#Frecuencias absolutas de cada variable
summary(Beb_Energ)
            estudio    bebe         sexo
 Informática    :53   No:97   Hombre:83
 Ing.Industrial:37   Sí:25   Mujer :39
 Matemáticas    :16
 Telemática     :16
#Formato tabla de frecuencias
sapply(Beb_Energ, FUN=table)
$estudio

   Informática Ing.Industrial     Matemáticas
            53              37              16
     Telemática
            16

$bebe

No Sí
97 25

$sexo

Hombre  Mujer
    83     39
#Tabla de frecuencias absolutas ordenadas
table(Beb_Energ)
  , sexo = Hombre

                bebe
estudio          No Sí
  Informática    30  7
  Ing.Industrial 19  6
  Matemáticas     8  1
  Telemática     10  2
```

```
, , sexo = Mujer

                bebe
estudio          No Sí
  Informática    11  5
  Ing.Industrial 10  2
  Matemáticas     6  1
  Telemática      3  1
ftable(Beb_Energ)
                      sexo  Hombre  Mujer
estudio          bebe
Informática      No             30     11
                 Sí              7      5
Ing.Industrial   No             19     10
                 Sí              6      2
Matemáticas      No              8      6
                 Sí              1      1
Telemática       No             10      3
                 Sí              2      1
```

8.3. Diagramas de barras

El gráfico para representar una variable cualitativa es el diagrama de barras. La altura de la barra es la frecuencia de la variable cualitativa.
Vamos a poner un ejemplo de variable cualitativa:

> Mujer, Mujer, Hombre, Mujer, Mujer, Mujer, Mujer, Mujer, Hombre, Mujer, Hombre, Hombre, Mujer, Mujer, Hombre, Mujer, Mujer, Mujer, Mujer, Hombre.

Vamos a ver cómo sería su código para generar el diagrama de barras de este ejemplo:

Listing 8.6: Código del diagrama de barras

```
Sexo_Ger=c("Mujer", "Mujer", "Hombre", "Mujer", "Mujer", "
    Mujer", "Mujer", "Mujer", "Hombre", "Mujer", "Hombre", "
    Hombre", "Mujer", "Mujer", "Hombre", "Mujer", "Mujer", "
    Mujer", "Mujer", "Hombre")
#Diagrama de barras frecuencias absolutas
barplot(table(Sexo_Ger),col=c("lightblue","pink"), main="
    Diagrama de barras de las frecuencias absolutas de la
    variable \"Sexo_Ger")
#Diagrama de barras frecuencias relativas
barplot(prop.table(table(Sexo_Ger)),col=c("lightblue","pink"),
     main="Diagrama de barras de las frecuencias relativas de la
     variable \"Sexo_Ger")
```

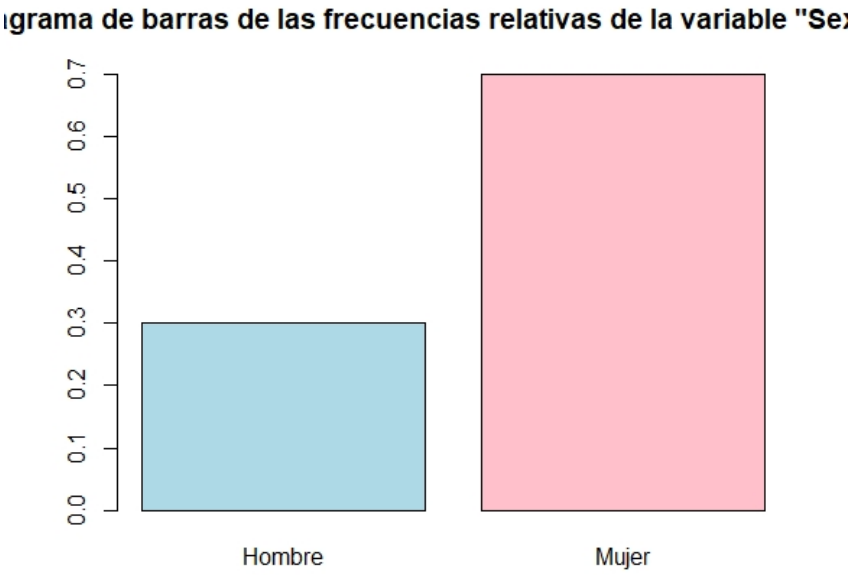

Figura 8.1: Diagrama de barras de las frecuencias relativas

Vamos a aplicar la función barplot a una tabla bidimensional.

Listing 8.7: Código función barplot tabla bidimensional

```
Respuestas=c("No","No","Si","No","Si","No","No", "Si")
Sexo=c("M","M","M","H","H","H","H","H")#H es hombre, M es
    mujer
barplot(table(Sexo,Respuestas))
#Una al lado de la otra
barplot(table(Sexo,Respuestas),beside=TRUE)
#Con leyenda
barplot(table(Sexo,Respuestas),beside=TRUE,legend.text = TRUE)
```

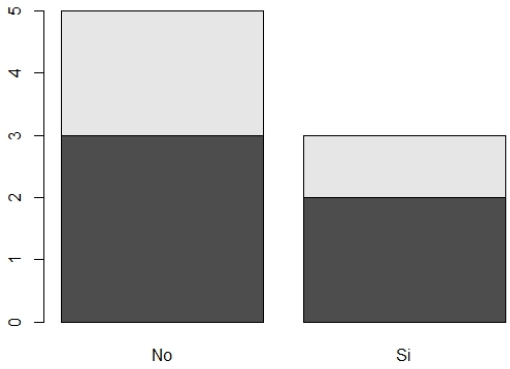

Figura 8.2: Diagrama de barras bidimensional

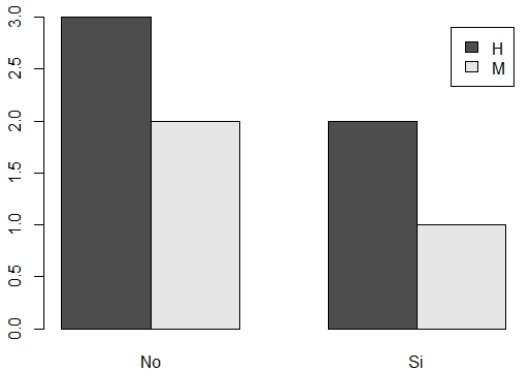

Figura 8.3: Diagrama de barras bidimensional datos enfrentados y leyenda

8.4. Otros gráficos básicos para datos cualitativos

8.4.1. Diagrama circular

Uno de los gráficos más populares es el diagrama circular o pie chart, donde se muestran las variables cualitativas como sectores circulares. El área del sector circular serán las frecuencias. Vamos a realizar un ejemplo de un diagrama circular:

Listing 8.8: Código diagrama circular

```
x=c(3,2,5,1,3,1,5,6,2,2,2,1,3,5,2)
pie(table(x),main="Diagrama circular")
```

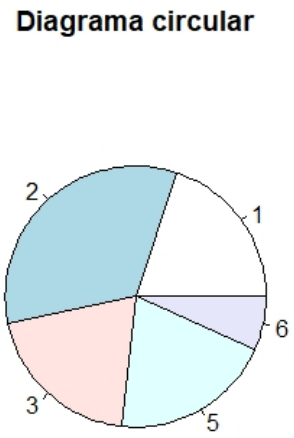

Figura 8.4: Diagrama circular

Esta función admite cambios de color y otros parámetros explicados anteriormente.

8.4.2. Gráficos de mosaico

Otro tipo de gráficos son los gráficos mosaico. Se obtienen sustituyendo cada entrada de frecuencias por una región rectangular de área proporcional a su valor. Vamos a realizar un diagrama mosaico de un ejemplo anterior:

Listing 8.9: Código gráfico mosaico

```
Respuestas=c("No","No","Si","No","Si","No","No","Si")
Sexo=c("M","M","M","H","H","H","H","H")
plot(table(Sexo,Respuestas), main="Gráfico mosaico")
```

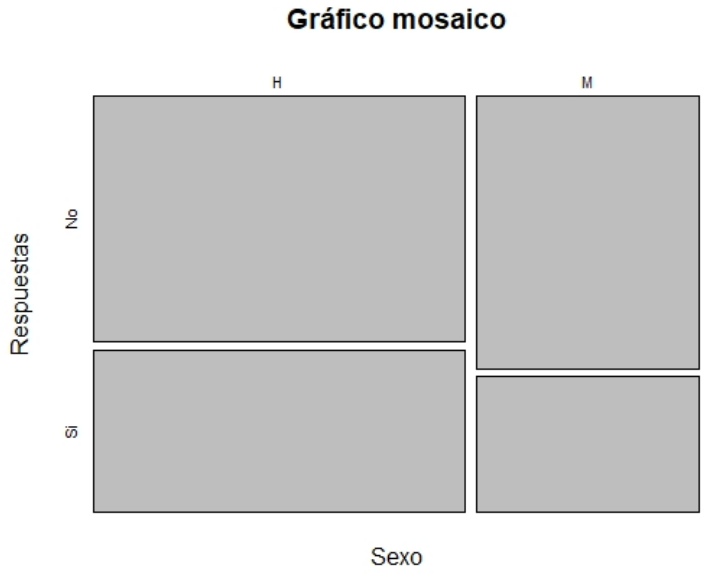

Figura 8.5: Gráfico mosaico

Admite parámetros como:

- col: Para asignar colores a los niveles de la última variable.
- dir: Igualado a un vector de direcciones v (vertical) y h (horizontal), sirve para especificar la dirección de las barras de cada variable.

Paquete vcd

Primero instalaremos el paquete vcd, que incorpora una función mosaic. Y de ejemplo, utilizaremos la tabla de datos HairEyeColor que contiene el color del pelo, color de ojos y sexo de 592 estudiantes de estadística. Y las variables son:

- **Hair**: Black, Brown, Red, Blond.
- **Eye**: Brown, Blue, Hazel, Green.
- **Sex**: Male, Female.

Listing 8.10: Código gráfico mosaico HairEyeColor

```
> library(vcd)
mosaic(HairEyeColor, dir=c("v","h","v"), highlighting ="Sex",
    highlighting_fill =c("pink","lightblue"), main="Gráfico de
    mosaico de la tabla HairEyeColor"  )
```

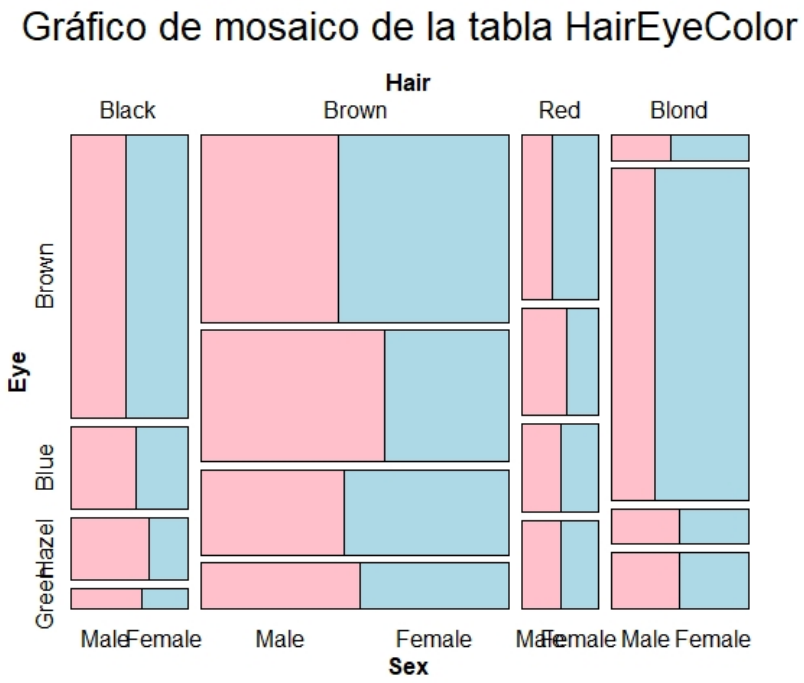

Figura 8.6: Gráfico mosaico de la tabla HairEyeColor

En esta función podremos encontrar los parámetros:

- dir: Es el equivalente al parámetro dir explicado anteriormente.
- highlighting: Sirve para destacar una variable.
- hightlighting_fill: Sirve para asignar colores a los niveles de la variable destacada.

8.5. Un ejemplo completo

En este capítulo vamos a repasar todos los contenidos de los capítulos anteriores. Para ello, utilizaremos los datos del paquete vcd. Los datos son los de HairEyeColor. Y las variables son:

- **Hair**: Black, Brown, Red, Blond.
- **Eye**: Brown, Blue, Hazel, Green.
- **Sex**: Male, Female.

Listing 8.11: Código ejemplo completo

```
#Tabla bidimensional de frecuencias absolutas
HEC=as.table(apply(HairEyeColor,MARGIN=c(1,2),FUN=sum))
> HEC
        Eye
Hair     Brown Blue Hazel Green
  Black     68   20    15     5
```

```
7    Brown    119    84     54     29
8    Red       26    17     14     14
9    Blond      7    94     10     16
10 #Nombres al castellano
11 dimnames(HEC)
12 $Hair
13 [1] "Black" "Brown" "Red"   "Blond"
14
15 $Eye
16 [1] "Brown" "Blue"  "Hazel" "Green"
17 dimnames(HEC)=list(Cabello=c("Negro","Castaño","Rojo","Rubio")
       ,Ojos=c("Marrones","Azules","Pardos","Verdes"))
18 > HEC
19           Ojos
20 Cabello    Marrones Azules Pardos Verdes
21   Negro          68      20      15      5
22   Castaño       119      84      54     29
23   Rojo           26      17      14     14
24   Rubio           7      94      10     16
25 #Diagrama de mosaico
26 plot(HEC,col=c("lightblue"),main="Diagrama de mosaico de la
       tabla bidimensional de frecuencias de colores de cabello y
       ojos")
27 #Tablas de frecuencias absoluta y relativa de cada variable
28 sum(HEC)
29 [1] 592
30 #Frecuencia absoluta color de ojos
31 colSums(HEC)
32 Marrones   Azules   Pardos   Verdes
33       220      215       93       64
34 #Frecuencia absoluta color de cabello
35 rowSums(HEC)
36   Negro Castaño    Rojo   Rubio
37     108     286      71     127
38 #Frecuencias relativas
39 #Color de los ojos
40 round(prop.table(colSums(HEC)),3)
41 Marrones   Azules   Pardos   Verdes
42    0.372    0.363    0.157    0.108
43 #Color del cabello
44 round(prop.table(rowSums(HEC)),3)
45   Negro Castaño    Rojo   Rubio
46   0.182   0.483   0.120   0.215
47 #Diagrama de barras de la frecuencia relativa color ojos
48 barplot(prop.table(colSums(HEC)),ylim=c(0,0.4),col=c("
       burlywood","lightblue","orange3","lightgreen"),main="
       Frecuencias relativas de colores de ojos")
```

```
#Color del cabello
barplot(prop.table(rowSums(HEC)),ylim=c(0,0.5),col=c("black","brown","red","gold"),main="Frecuencias relativas de colores de cabello")
#Frecuencias relativas globales
round(prop.table(HEC),3)
          Ojos
Cabello    Marrones Azules Pardos Verdes
  Negro       0.115  0.034  0.025  0.008
  Castaño     0.201  0.142  0.091  0.049
  Rojo        0.044  0.029  0.024  0.024
  Rubio       0.012  0.159  0.017  0.02
#Color del cabello
round(prop.table(HEC,margin=1),3)
          Ojos
Cabello    Marrones Azules Pardos Verdes
  Negro       0.630  0.185  0.139  0.046
  Castaño     0.416  0.294  0.189  0.101
  Rojo        0.366  0.239  0.197  0.197
  Rubio       0.055  0.740  0.079  0.126
#Color de los ojos
round(prop.table(HEC,margin=2),3)
        Ojos
Cabello    Marrones Azules Pardos Verdes
  Negro       0.309  0.093  0.161  0.078
  Castaño     0.541  0.391  0.581  0.453
  Rojo        0.118  0.079  0.151  0.219
  Rubio       0.032  0.437  0.108  0.250
#Diagrama de barras de frecuencias relativas
#Colores de cabello en cada ojos
barplot(prop.table(HEC,margin=1),beside=TRUE,legend.text=TRUE,col=c("black","brown","red","gold"),ylim=c(0,0.8),main="Frecuencias relativas de colores de cabello \n en cada color de ojos")
#Colores en ojos en cada color cabello
barplot(prop.table(HEC,margin=2),beside=TRUE,legend.text=TRUE,col=c("burlywood4","lightblue","orange3","lightgreen"),ylim=c(0,0.6),main="Frecuencias relativas de colores de ojos \n en cada color de cabello")
> library(vcd)
#Mosaico
mosaic(HairEyeColor,dir=c("v","h","v"),highlighting="Sex",highlighting_fill=c("pink","lightblue"),main="Gráfico mosaico de la tabla HairEyeColor")
```

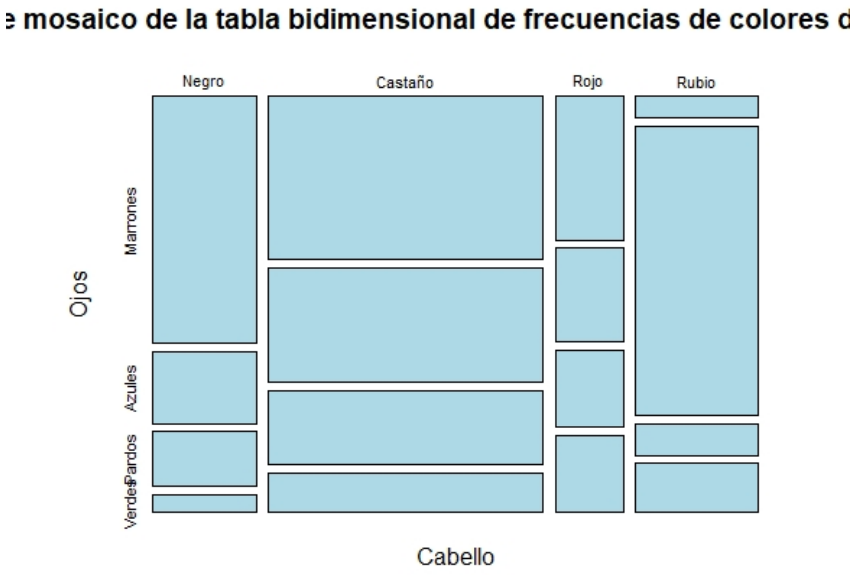

Figura 8.7: Diagrama mosaico ejemplo

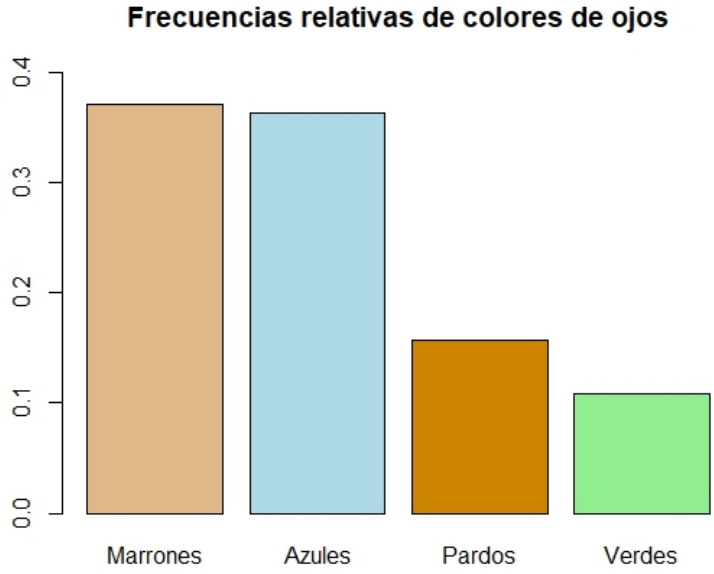

Figura 8.8: Diagrama de barras frecuencias relativas color ojos

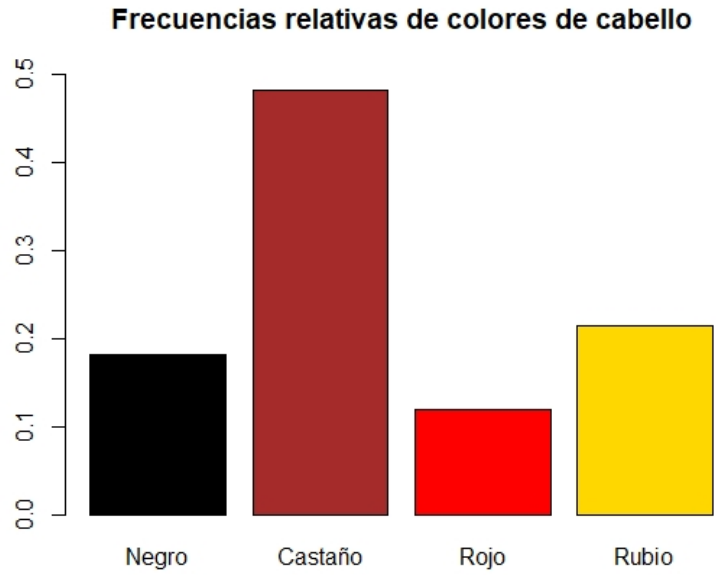

Figura 8.9: Diagrama de barras frecuencias relativas color cabello

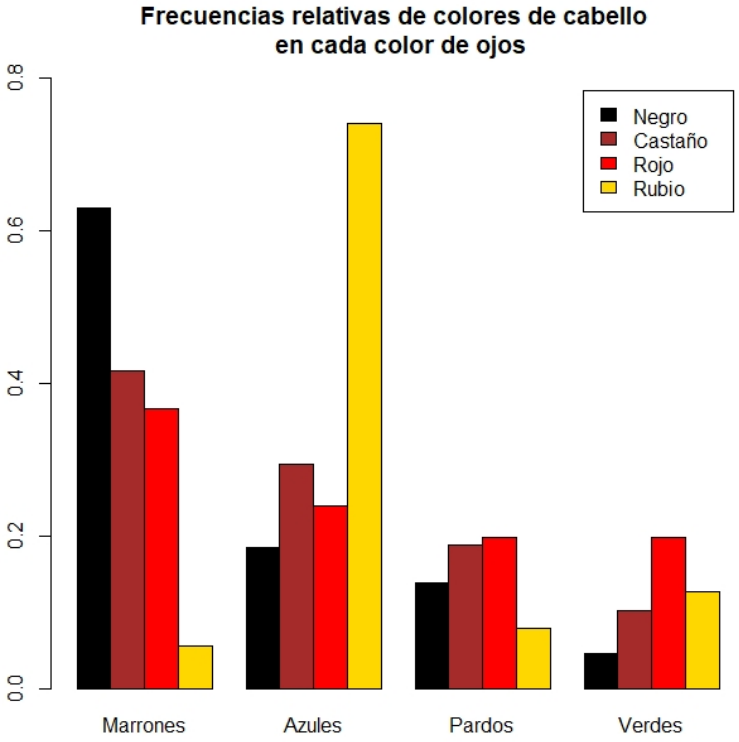

Figura 8.10: Diagrama de barras frecuencias relativas color cabello en cada ojos

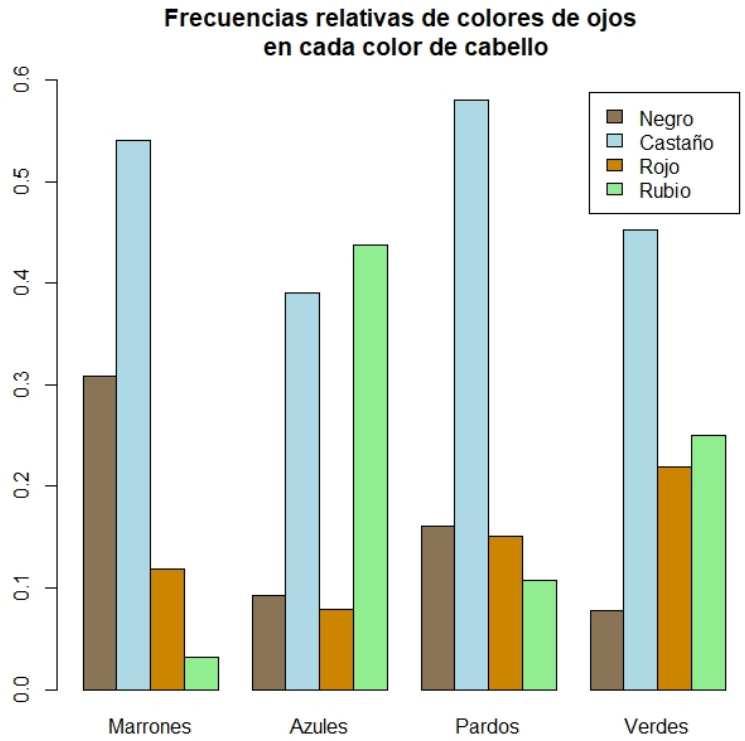

Figura 8.11: Diagrama de barras frecuencias relativas color ojos en cada color cabello

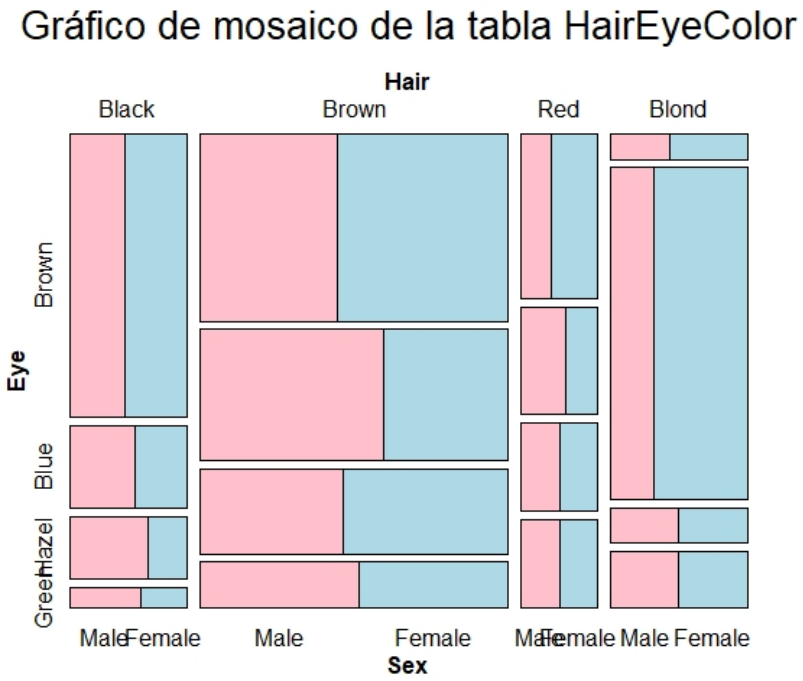

Figura 8.12: Gráfico mosaico de la tabla HairEyeColor

Capítulo 9

Datos ordinales

A diferencia de los valores cualitativos, los datos ordinales si que tienen un orden natural.
En este capítulo vamos a ver cómo tratar los datos ordinales.
Se van a tratar igual que los cualitativos con la función table() obtendremos las frecuencias absolutas, con la función barplot(table()) dibujaremos nuestro diagrama de barras correspondiente, para obtener las frecuencias relativas acumuladas aplicamos la función cumsum(prop.table(table())) y con la función barplot(cumsum(prop.table(table()))) tendremos el diagrama de barras de las frecuencias acumuladas.
Por otro lado, si la table es multidimensional no podremos aplicar la función cumsum, por lo que tendremos que aplicar la función apply(tabla,MARGIN=,FUN=cumsum) y según queramos sumar filas o columnas utilizaremos:

- MARGIN=1: Por filas.
- MARGIN=2: Por columnas.

Capítulo 10

Frecuencias, medidas de tendencia central y de posición, medidas de dispersión y diagrama de cajas

10.1. Frecuencias

Los datos cuantitativos pueden ser ordenados usando el orden natural de los números reales.

Datos: 18,22,16,19,23,35,18,18,16.
Orden valores observados: 16<18<19<22<23<35.

Se pueden calcular sus frecuencias y frecuencias acumuladas. Sólo se tienen en cuenta los valores observados.
A continuación vamos a sacar las frecuencias y las frecuencias acumuladas de la cantidad de pases de un jugador de rugby:

Listing 10.1: Código medidas frecuencias pases

```
> pases=scan()
1: 31 34 35 28 29 29 29 32 35 31 29 31 28 26 30 30 33 35 30 29
     27 27 28 30 29
26:
Read 25 items
> table(pases)
pases
26 27 28 29 30 31 32 33 34 35
 1  2  3  6  4  3  1  1  1  3
> cumsum(table(pases))
26 27 28 29 30 31 32 33 34 35
 1  3  6 12 16 19 20 21 22 25
> prop.table(table(pases))
pases
   26    27    28    29    30    31    32    33    34    35
0.04  0.08  0.12  0.24  0.16  0.12  0.04  0.04  0.04  0.12
> cumsum(prop.table(table(pases)))
```

```
17    26    27    28    29    30    31    32    33    34    35
18 0.04  0.12  0.24  0.48  0.64  0.76  0.80  0.84  0.88  1.00
```

10.2. Medidas de tendencia central y de posición

En este capítulo veremos cómo calcular con R la media, la mediana y los cuantiles de un vector numérico de datos.

10.2.1. Medidas de tendencia central

Dan un valor representativo de todas las observaciones.

- **Moda**: Es el valor o valores de máxima frecuencia.
- **Media aritmética**: Es la división de la suma de los datos entre el número total de datos.
- **Mediana**: Representa el valor central de la lista ordenada de observaciones. Si el número de datos es par, se calcula como la media aritmética de los dos valores centrales.

Moda

Para calcular la moda con datos cualitativos utilizamos la función names(which(table(x)==max(table(x)))). Pero en este capítulo estamos tratando datos cuantitativos por lo que transformáremos el resultado de esta función con la función as.numeric.

Media aritmética y mediana

Se calculan con las funciones mean y median.
Vamos a realizar un ejemplo con estas funciones:

Listing 10.2: Código medidas de tendencia central

```
1 > paradas=scan()
2 1: 12 9 10 13 13 4 11 10 8 10 9 12 8 10 8 6 14 7 11 7 9 12 5 6
      6
3 26:
4 Read 25 items
5 #Moda
6 > as.numeric(names(which(table(paradas)==max(table(paradas))))
    )
7 [1] 10
8 > table(paradas)
9 paradas
10  4  5  6  7  8  9 10 11 12 13 14
11  1  1  3  2  3  3  4  2  3  2  1
12 #Media
```

```
> mean(paradas)
[1] 9.2
#Mediana
> median(paradas)
[1] 9
```

10.2.2. Medidas de posición

Estiman qué valores dividen la población en unas determinadas proporciones. Los valores que determinan estas posiciones reciben el nombre de cuantiles.
Dada una proporción $0 < p < 1$, el cuantil de orden p de una variable cuantitativa, que denotaremos por Q_p, es el valor más pequeño tal que su frecuencia relativa acumulada es mayor o igual que p.
Algunos cuantiles importantes:

- **Mediana**: Es el cuantil $Q_{0,5}$.
- **Cuartiles**: Son los cuantiles $Q_{0,25}$, $Q_{0,5}$ y $Q_{0,75}$.
- **Deciles**: Son los cuantiles Q_p con p un múltiplo entero de 0.1.
- **Percentiles**: Son los cuantiles Q_p con p un múltiplo entero de 0.01.

10.2.3. Cálculo del cuantil

Con R los cuantiles de orden p se calculan con la función quantile(x,p) donde x es un vector de datos. R dispone de 9 métodos distintos para calcular los cuantiles a través del parámetro type. Usaremos type=7 que corresponde al valor por defecto.
Vamos a calcular los cuantiles 0.25, 0.5 y 0.75 del ejemplo anterior:

Listing 10.3: Código cálculo cuantiles

```
> quantile(paradas,0.25)
25%
  7
> quantile(paradas,0.5)
50%
  9
> quantile(paradas,0.75)
75%
 11
> cumsum(prop.table(table(paradas)))
   4    5    6    7    8    9   10   11   12   13   14
0.04 0.08 0.20 0.28 0.40 0.52 0.68 0.76 0.88 0.96 1.00
```

10.3. Medidas de dispersión

En este capítulo veremos la variabilidad de los datos a través de las medidas de dispersión. Las medidas de dispersión evalúan lo desperdigados que están los datos.

- **Rango**: Es la diferencia entre el máximo y el mínimo de las observaciones. Se calcula con la función diff(range(x)) donde range(x) da el valor mínimo y máximo de los datos.
- **Rango intercuartílico**: Es la diferencia entre los cuartiles $Q_{0,75}$ y $Q_{0,25}$. Se calcula con la función IQR.
- **Varianza**: Es la media aritmética de las diferencias al cuadrado entre los datos x_i y la media $\vec{x}$.
$$s^2 = \frac{\sum_{i=1}^{n}(x_i - \vec{x})^2}{n}.$$
Se calcula mediante la función (n-1)/n*var.
- **Varianza muestral**: ES la corrección de la varianza dada por:
$$\vec{s^2} = \frac{n}{n-1}s^2.$$
Se calcula mediante la función var.
La varianza muestral de una muestra aproxima significativamente mejor la varianza real de la población que la varianza de la muestra.
- **Desviación típica**: Es la raíz de la varianza. Se calcula mediante sqrt((n-1)/n)*sd.
- **Desviación típica muestral**: Es la raíz de la varianza muestral. Se calcula mediante la función sd.
Las desviaciones típicas están en la misma unidad que las observaciones.

Vamos a realizar un ejemplo calculando este tipo de medidas, para ello, necesitaremos el data frame ChickWeight.

Listing 10.4: Código medidas de dispersión

```
data("ChickWeight")
#Rango
diff(range(ChickWeight$weight))
[1] 338
#Rango intercuartilico
IQR(ChickWeight$weight)
[1] 100.75
#Varianza muestral
var_mu=var(ChickWeight$weight)
> var_mu
[1] 5051.223
#Varianza verdadera
var_v=var(ChickWeight$weight)*(length(ChickWeight$weight)-1)/
   length(ChickWeight$weight)
```

```
> var_v
[1] 5042.484
#Desviación típica muestra
dtip_mu=sqrt(var_mu)
> dtip_mu
[1] 71.07196
sd(ChickWeight$weight)
[1] 71.07196
#Desviación típica verdadera
dtip=sqrt(var_v)
> dtip
[1] 71.01045
sd(ChickWeight$weight)*sqrt((length(ChickWeight$weight)-1)/
   length(ChickWeight$weight))
[1] 71.01045
```

10.3.1. Resumen estadístico

Si queremos obtener un resumen estadístico de un vector numérico que contenga los valores mínimo y máximo, sus tres cuartiles y su media, hay que usar la función summary. Esta función también puede aplicarse a un data frame, obteniendo un resumen estadístico de todas sus variables.
Si queremos aplicar cualquier función (y en particular, obtener el resumen estadístico) a algunas columnas de un data frame segmentándolas según los niveles de factor se usa by(columnas,factor,FUN=función).
Vamos a aplicar esta función al ejemplo anterior:

Listing 10.5: Código resumen estadístico

```
#Resumen estadístico
summary(ChickWeight)
     weight           Time           Chick     Diet
 Min.   : 35.0   Min.   : 0.00   13     : 12   1:220
 1st Qu.: 63.0   1st Qu.: 4.00   9      : 12   2:120
 Median :103.0   Median :10.00   20     : 12   3:120
 Mean   :121.8   Mean   :10.72   10     : 12   4:118
 3rd Qu.:163.8   3rd Qu.:16.00   17     : 12
 Max.   :373.0   Max.   :21.00   19     : 12
                                 (Other):506
by(ChickWeight$weight,ChickWeight$Diet,FUN=summary)
                                ChickWeight$Diet: 1
   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
  35.00   57.75   88.00  102.65  136.50  305.00
 ChickWeight$Diet: 2
   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
   39.0    65.5   104.5   122.6   163.0   331.0
```

```
17 ------------------------------------------------------------
18 ChickWeight$Diet: 3
19    Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
20    39.0    67.5   125.5   142.9   198.8   373.0
21 ------------------------------------------------------------
22 ChickWeight$Diet: 4
23    Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
24   39.00   71.25  129.50  135.26  184.75  322.00
```

10.4. Diagramas de cajas

Los diagramas de cajas son unas herramientas muy importantes para ver a simple vista datos estadísticos. Es un gráfico que resume algunos datos estadísticos de una variable cuantitativa.

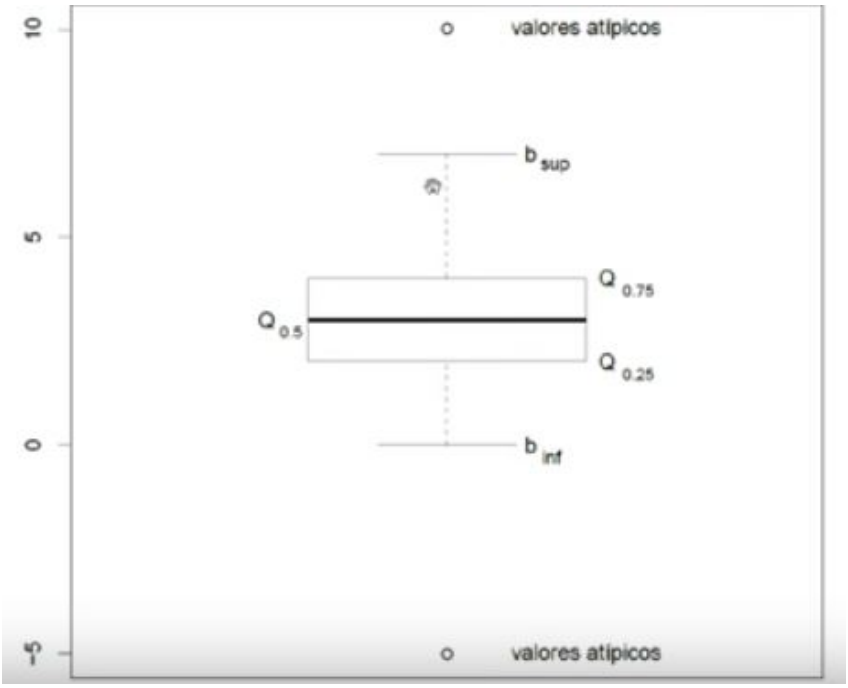

Figura 10.1: Ejemplo de diagrama de caja

En las dos puntas de las cajas tenemos los percentiles, en la esquina superior tenemos el máximos y en la esquina inferior el mínimo.
La función básica para dibujar un diagrama de caja con R es boxplot. Admite los parámetros usuales de plot para mejorar el resultado.
Hay distintos usos de esta función dependiendo de sus entradas:

- boxplot(x): Calcula el diagrama de caja de un vector numérico.
- boxplot(x,y,z): Si la aplicamos a varios vectores numéricos dibujará diagramas de caja en un mismo gráfico.

- boxplot(df): Aplicado a un data frame representa todos los diagramas de caja del data frame en un solo paso.
- boxplot(variable numérica variable factor, data=data frame): Dibuja en un único gráfico los diagramas de caja de una variable numérica de un data frame segmentada por un factor.

Vamos a utilizar los mismos datos que en el capítulo anterior para hacer distintos diagramas de cajas.

Listing 10.6: Código diagramas de cajas

```
#Diagramas de cajas
boxplot(ChickWeight$weight, main="Diagrama de caja de peso",
    ylab="peso",col="red")
boxplot(ChickWeight$weight~ChickWeight$Diet, main="Diagrama de
    caja de peso según la dieta",ylab="peso",xlab="dieta",col="
    red")
```

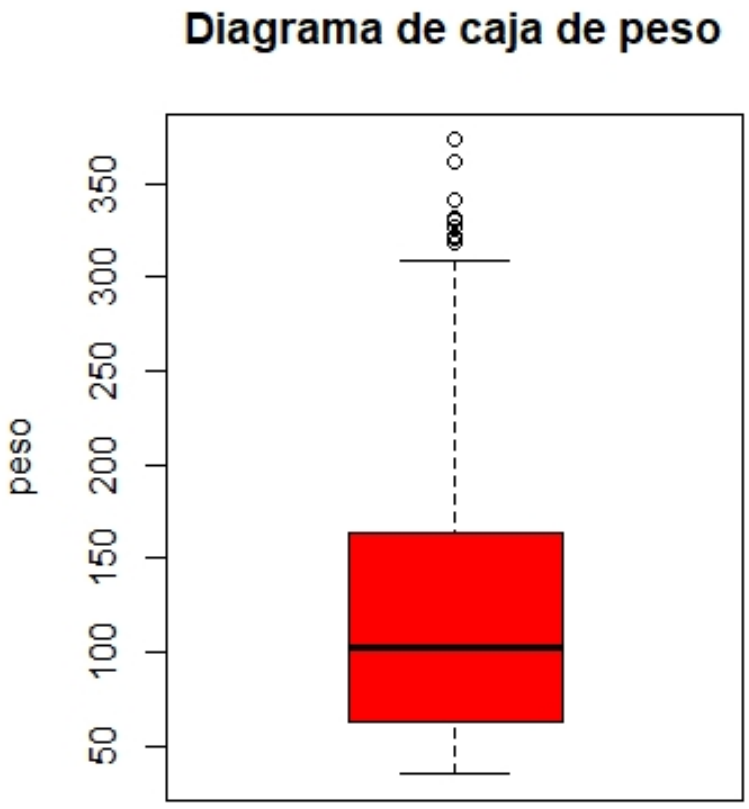

Figura 10.2: Diagrama de caja de peso

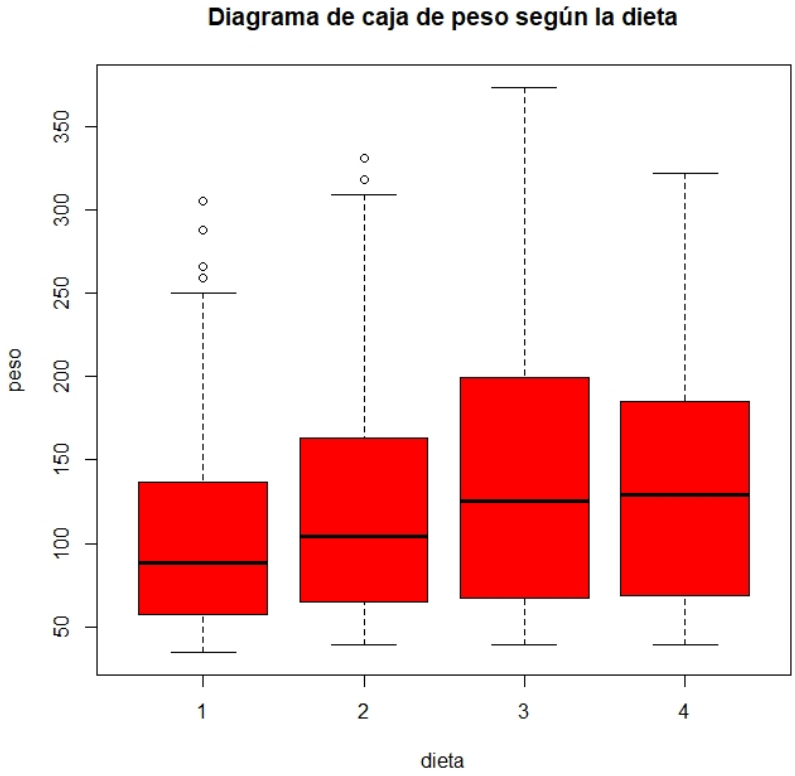

Figura 10.3: Diagrama de caja de peso según la dieta

Además, podremos obtener el resultado de una boxplot en una list. De la que podemos destacar:

- stats: Para cada diagrama de caja del gráfico, da las ordenadas de sus cinco líneas horizontales.
- out: Da los valores atípicos, indicando a qué diagrama pertenecen en la componente group.

También dispone de otros parámetros como:

- horizontal: Igualado a TRUE, dibuja las cajas horizontales.
- names: Específica los nombres bajo los diagramas de cajas.
- notch: Dibuja las cinturas alrededor de las medianas que permiten contrastar si las medianas poblacionales son diferentes.
- plot: Igualado a FALSE calcula el diagrama de caja, pero no lo dibuja.

Vamos a comprobar con estos parámetros el ejemplo anterior:

Listing 10.7: Código diagrama de caja con parámetros modificados

```
1 boxplot(ChickWeight$weight~ChickWeight$Diet, main="Diagrama de
    caja de peso según la dieta",ylab="peso",xlab="dieta",col="
  red",notch=TRUE)
```

```
boxplot(ChickWeight$weight~ChickWeight$Diet, plot=FALSE)$stats
      [,1]  [,2]  [,3]  [,4]
[1,]  35.0  39.0  39.0  39.0
[2,]  57.5  65.0  67.0  69.0
[3,]  88.0 104.5 125.5 129.5
[4,] 137.0 163.0 199.5 185.0
[5,] 250.0 309.0 373.0 322.0
boxplot(ChickWeight$weight~ChickWeight$Diet, plot=FALSE)$out
[1] 288 305 259 266 318 331
boxplot(ChickWeight$weight~ChickWeight$Diet, plot=FALSE)$group
[1] 1 1 1 1 2 2
```

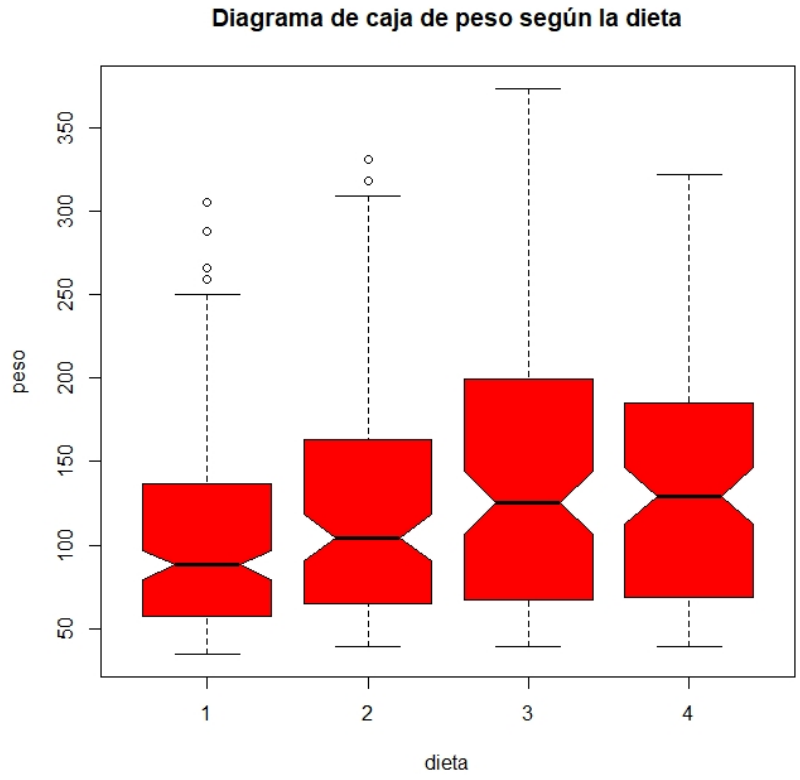

Figura 10.4: Diagrama de caja de peso según dieta con notch=TRUE

Capítulo 11

Matrices de datos cuantitativos, covarianzas y correlaciones, y representación gráfica de datos multidimensionales

11.1. Matrices de datos cuantitativos

En este capítulo vamos a ver datos que necesitan más de una variable para representarlos. Estos datos se agrupan en filas y en columnas.

Cuadro 11.1: Representación de datos cuantitativos

	Variable 1	**Variable 2**	**...**	**Variable p**
Individuo 1	x11	x12	...	x1p
Individuo 2	x21	x22	...	x2p
...	...	...	...	....
Individuo n	xn1	xn2	...	xnp

Vamos a representar la matriz tanto por filas como por columnas.

11.1.1. Estadísticos multidimensionales

Vector de medias:

$$\vec{X} = \left(\vec{x_{o1}}, x_{o2}, \vec{...}, \vec{x_{op}}\right), \vec{x_{oj}} = \frac{1}{n}\sum_{i=1}^{n} x_{ij}$$

Vector de varianzas:

$$s^2x = (s_1^2, s_2^2, ..., s_p^2), s_j^2 = \frac{1}{n}\sum_{i=1}^{n}(x_{ij} - \vec{x_{oj}})^2$$

Vector de varianzas muestrales:

$$\vec{s_x^2} = (\vec{s_1^2}, \vec{s_2^2}, ..., \vec{s_p^2})$$

$$\vec{s}_j^2 = \frac{1}{n-1}\sum_{i=1}^{n}(x_{ij} - \vec{x}_{oj})^2 = \frac{n}{n-1}s_j^2$$

Vamos a ver cómo hallar en R los estadísticos anteriores:

Listing 11.1: Código estadísticos multidimensionales

```
X=data.frame(V1=c(1,1,2,3),V2=c(-1,0,3,0),V3=c(3,3,0,1))
> X
  V1 V2 V3
1  1 -1  3
2  1  0  3
3  2  3  0
4  3  0  1
#Media
sapply(X,mean)
  V1   V2   V3
1.75 0.50 1.75
#Varianza muestral
sapply(X,var)
       V1        V2        V3
0.9166667 3.0000000 2.2500000
#Desviación típica muestral
sapply(X,sd)
       V1        V2        V3
0.9574271 1.7320508 1.5000000
#Verdaderas
#Varianza
var_ver=function(x){var(x)*(length(x)-1)/length(x)}
sapply(X, var_ver)
    V1     V2     V3
0.6875 2.2500 1.6875
#Desviación típica
sd_ver=function(x){sqrt(var_ver(x))}
sapply(X,sd_ver)
       V1        V2        V3
0.8291562 1.5000000 1.2990381
```

Es muy típico tipificar una tabla multidimensional, para ello la restaremos su media y la dividiremos por su desviación típica. Para tipificar una tabla de datos multidimensional en R vamos a utilizar la función scale(X,center=...,scale=...), donde:

- X: Matriz o tabla de datos.
- center: Vector que restamos a la columnas. center=TRUE (defecto), restamos el valor de medias. center=FALSE, no restamos nada.
- scale: Vector por el que dividimos la matriz. scale=TRUE (defecto), dividimos por las desviaciones típicas muestrales. scale=FALSE, no dividimos por nada.

Vamos a proceder a tipificar nuestra tabla de datos:

Listing 11.2: Código tipificación tabla de datos

```
#Tipificacion tabla de datos
scale(X)
              V1         V2         V3
[1,] -0.7833495 -0.8660254  0.8333333
[2,] -0.7833495 -0.2886751  0.8333333
[3,]  0.2611165  1.4433757 -1.1666667
[4,]  1.3055824 -0.2886751 -0.5000000
attr(,"scaled:center")
  V1   V2   V3
1.75 0.50 1.75
attr(,"scaled:scale")
       V1        V2        V3
0.9574271 1.7320508 1.5000000
apply(scale(X),2,mean)
            V1             V2             V3
-4.163336e-17  0.000000e+00  0.000000e+00
apply(scale(X),2,var)
V1 V2 V3
 1  1  1
scale(X, center=TRUE, scale=FALSE)
        V1   V2    V3
[1,] -0.75 -1.5  1.25
[2,] -0.75 -0.5  1.25
[3,]  0.25  2.5 -1.75
[4,]  1.25 -0.5 -0.75
attr(,"scaled:center")
  V1   V2   V3
1.75 0.50 1.75
```

11.2. Covarianzas y correlaciones

En este capítulo vamos a ver las covarianzas y las correlaciones de una matriz de datos.

11.2.1. Covarianza entre dos variables

Covarianza:

$$s_{ij} = \frac{1}{n}\sum_{k=1}^{n}((x_{ki} - \vec{x}_{oi})(x_{kj} - \vec{x}_{oj})) = \frac{1}{n}\sum_{k=1}^{n} x_{ki}x_{kj} - \vec{x}_{oi}\vec{x}_{oj}$$

Covarianza muestral

$$\vec{s}_{ij} = \frac{1}{n-1}\sum_{k=1}^{n}((x_{ki} - \vec{x}_{oi})(x_{kj} - \vec{x}_{oj})) = \frac{n}{n-1}s_{ij}$$

Relación entre ambas:

$$s_{ij} = s_{ji}, \vec{s}_{ij} = \vec{s}_{ji}, s_{ii} = s_i^2, \vec{s}_{ii} = \vec{s}_i^2$$

Ejemplo de cálculo de covarianza:

$$X = \begin{pmatrix} 1 & -1 & 3 \\ 1 & 0 & 3 \\ 2 & 3 & 0 \\ 3 & 0 & 1 \end{pmatrix}$$

$$s_{12} = \frac{1}{4}(1 \cdot (-1) + 1 \cdot 0 + 2 \cdot 3 + 3 \cdot 0) - 1{,}75 \cdot 0{,}5 = 1{,}25 - 0{,}875 = 0{,}375$$

$$\vec{s}_{12} = \frac{4}{3} s_{12} = 0{,}5$$

Vamos a proceder a calcular la covarianza en R:

Listing 11.3: Código de cálculo de covarianza

```
X=data.frame(V1=c(1,1,2,3),V2=c(-1,0,3,0),V3=c(3,3,0,1))
> X
  V1 V2 V3
1  1 -1  3
2  1  0  3
3  2  3  0
4  3  0  1
#Covarianza entre las dos primeras columnas
#Muestral
cov(X$V1,X$V2)
[1] 0.5
#Verdadera
cov(X$V1,X$V2)*3/4
[1] 0.375
```

11.2.2. Matrices covarianzas y covarianzas muestrales

$$s = \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1p} \\ s_{21} & s_{22} & \cdots & s_{2p} \\ \cdots & \cdots & \cdots & \cdots \\ s_{p1} & s_{p2} & \cdots & s_{pp} \end{pmatrix}, \vec{s} = \begin{pmatrix} \vec{s}_{11} & \vec{s}_{12} & \cdots & \vec{s}_{1p} \\ \vec{s}_{21} & \vec{s}_{22} & \cdots & \vec{s}_{2p} \\ \cdots & \cdots & \cdots & \cdots \\ \vec{s}_{p1} & \vec{s}_{p2} & \cdots & \vec{s}_{pp} \end{pmatrix}$$

Vamos a ver cómo podemos realizar en R las matrices covarianzas y covarianzas muestrales:

Listing 11.4: Código matrices covarianzas y covarianzas muestrales

```
#Matrices covarianzas y covarianzas muestrales
#Muestral
cov(X)
```

```
             V1         V2         V3
V1   0.9166667   0.500000 -1.083333
V2   0.5000000   3.000000 -2.166667
V3 -1.0833333 -2.166667  2.250000
#Verdadera
n=dim(X)[1]
((n-1)/n)*cov(X)
          V1      V2       V3
V1   0.6875   0.375 -0.8125
V2   0.3750   2.250 -1.6250
V3 -0.8125 -1.625  1.6875
```

11.2.3. Correlación entre dos variables

$$r_{ij} = \text{cor}(x_{oi}, x_{oj}) = \frac{s_{ij}}{s_i \cdot s_j}$$

$$\vec{r}_{ij} = \frac{\vec{s}_{ij}}{\vec{s}_i \cdot \vec{s}_j} = r_{ij}$$

11.2.4. Propiedades de la correlación entre dos variables

- **Simetría**: $r_{ij} = r_{ji}$.
- **Correlación de una variable consigo misma**: $r_{ii} = 1$.
- **Valore entre -1 y 1**: $-1 \leq r_{ij} \leq 1$.
- **Relación perfecta**: Si $r_{ij} = \pm 1$, existe una relación lineal perfecta entre las variables x_{oi} y x_{oj}. O sea, existen valores a y b tal que $x_{oi} = a \cdot x_{oj} + b$.

La correlación es una covarianza normalizada.
Ejemplo de correlación entre dos variables:

$$X = \begin{pmatrix} 1 & -1 & 3 \\ 1 & 0 & 3 \\ 2 & 3 & 0 \\ 3 & 0 & 1 \end{pmatrix}$$

$$s_{12} = 0{,}375, s_1 = \frac{\sqrt{11}}{4} = 0{,}8292, s_2 = \frac{3}{2} = 1{,}5$$

$$r_{12} = \frac{0{,}375}{0{,}8292 \cdot 1{,}5} = 0{,}3015$$

11.2.5. Matrices de correlaciones

$$r = \begin{pmatrix} r_{11} & r_{12} & \cdots & r_{1p} \\ r_{21} & r_{22} & \cdots & r_{2p} \\ \cdots & \cdots & \cdots & \cdots \\ r_{p1} & r_{p2} & \cdots & r_{pp} \end{pmatrix}$$

Está formada por las correlaciones ij.
Vamos a calcular las correlaciones en R, para ello vamos a utilizar la función cor:

Listing 11.5: Código cálculo correlaciones

```
#Cálculo correlaciones
#Matriz correlaciones
cor(X)
             V1          V2          V3
V1  1.0000000  0.3015113 -0.7543365
V2  0.3015113  1.0000000 -0.8339504
V3 -0.7543365 -0.8339504  1.0000000
cov(scale(X))
             V1          V2          V3
V1  1.0000000  0.3015113 -0.7543365
V2  0.3015113  1.0000000 -0.8339504
V3 -0.7543365 -0.8339504  1.0000000
```

11.3. Representación gráfica de datos multidimensionales

En este capítulo vamos a ver cómo representar datos multidimensionales de una manera sencilla.

11.3.1. La función plot

Listing 11.6: Código dos variables en función plot

```
#Representación de dos en función plot
iris.pet=iris[,c("Petal.Length","Petal.Width")]
plot(iris.pet,pch=20,xlab="Largo",ylab="Ancho")
```

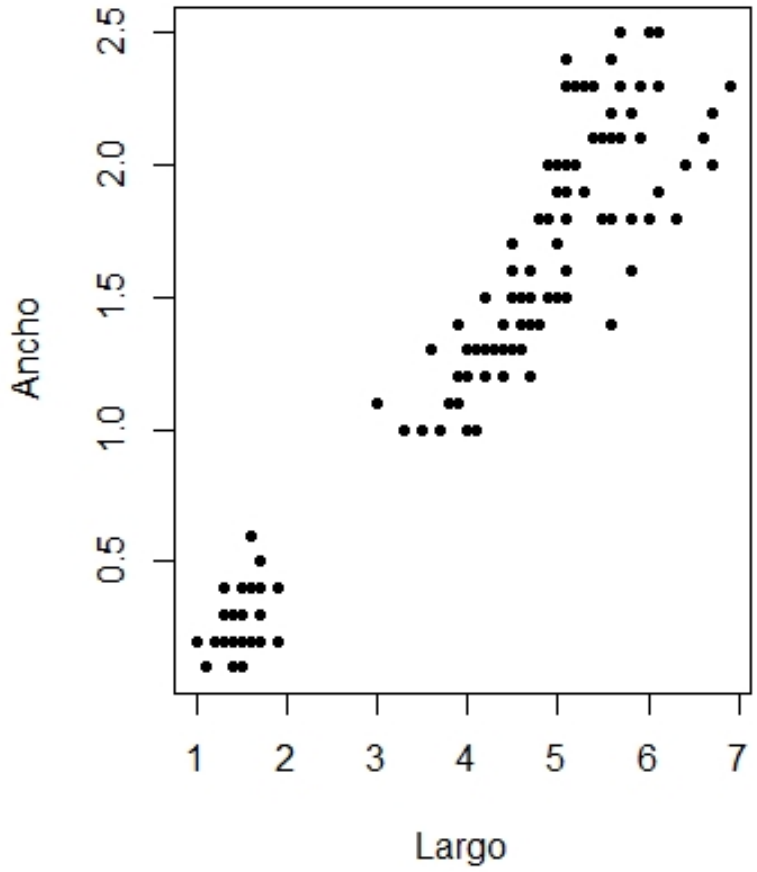

Figura 11.1: Dos variables en una función plot

11.3.2. La función scatterplot3d

Listing 11.7: Código tres variables en función scatterplot3d

```
#Representación de 3 variables
> library(scatterplot3d)#Instalar paquete antes
scatterplot3d(iris[,1:3],pch=20)
```

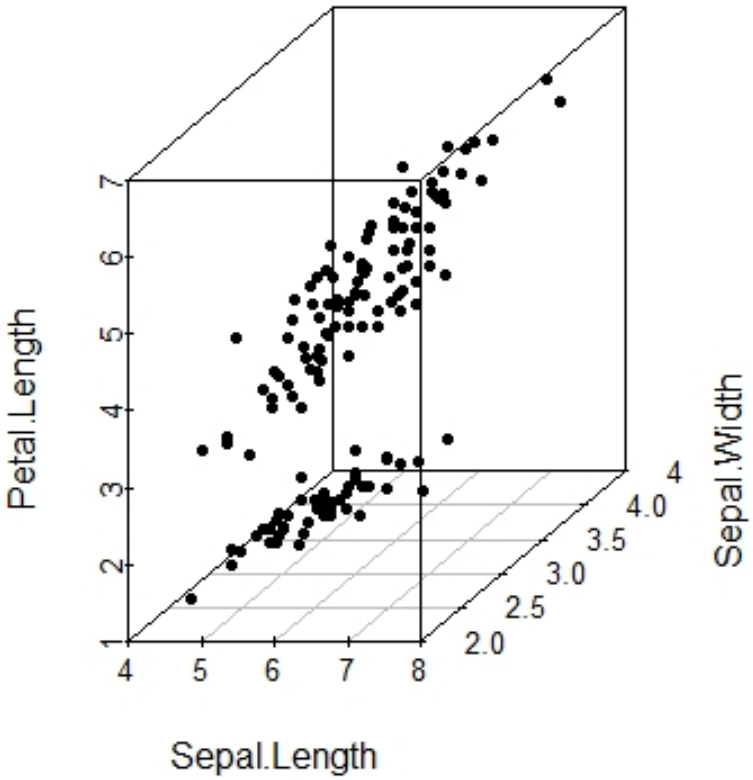

Figura 11.2: Tres variables en la función scatterplot3d

11.3.3. Diagramas de dispersión con plot

Listing 11.8: Código diagramas de dispersión con plot

```
#Diagramas de dispersión con plot
plot(iris[,1:4])
```

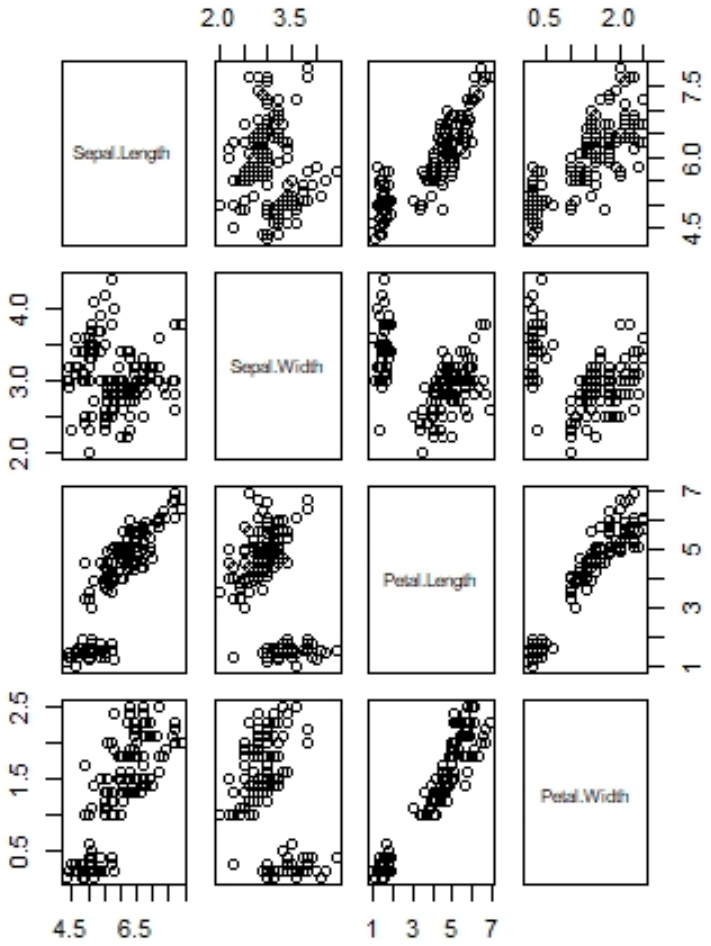

Figura 11.3: Diagramas de dispersión con plot

Se puede hacer este mismo diagrama de dispersión distinguiendo una variable cualitativa de la siguente forma:

Listing 11.9: Código diagramas de dispersión con plot distinguiedo variable

```
plot(iris[,1:4],col=iris$Species)
```

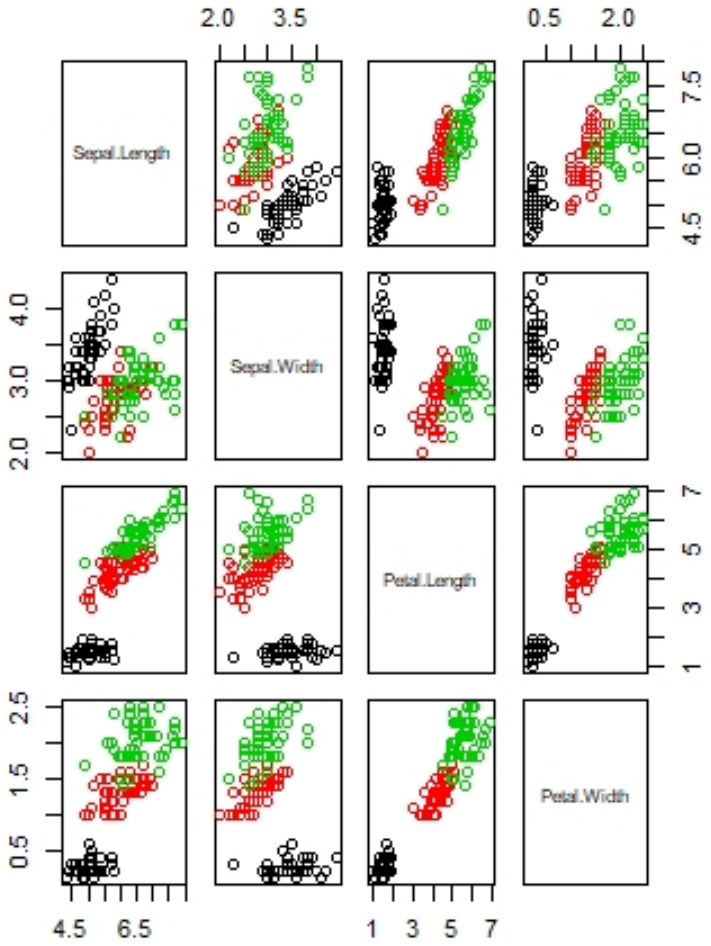

Figura 11.4: Diagramas de dispersión con plot distinguiendo variable

11.3.4. Diagramas de dispersión con la función pairs

Por otro lado, podemos utilizar para los diagramas de dispersión la función pairs:

Listing 11.10: Código diagrama dispersión con función pairs

```
#Pairs
pairs(iris[,1:4],col=iris$Species)
```

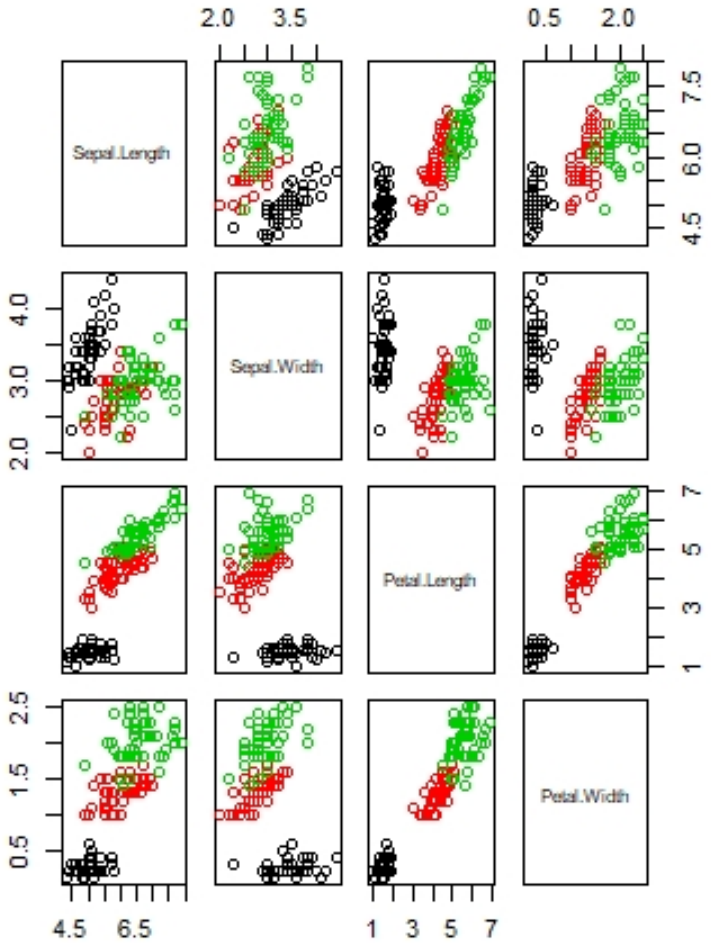

Figura 11.5: Diagramas de dispersión con pairs

Esta función se puede aplicar a una matriz.

11.3.5. Diagramas de dispersión con spm

Los diagramas de dispersión de esta función contienen mucha más información que los dos anteriores. Para ello, requerimos la instalación del paquete car.

Listing 11.11: Código diagrama dispersión con función spm

```
> library(car)
#Diagramas de dispersión con spm
spm(iris[,1:4])
```

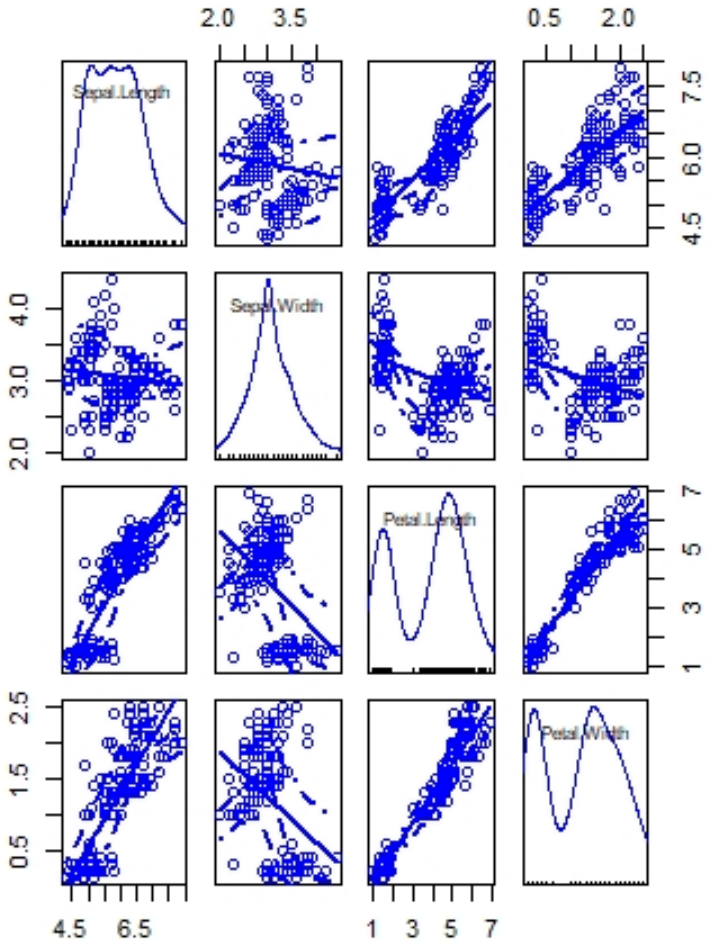

Figura 11.6: Diagramas de dispersión con spm

Capítulo 12

Agrupamiento de datos con R, estadísticos para datos agrupados e histogramas

12.1. Agrupamiento de datos con R

En este capítulo nos vamos a centrar cómo agrupar datos cuantitativos con R y a determinar sus frecuencias.

12.1.1. Agrupamiento de datos

Es frecuente cuando trabajamos en estadística con datos cuantitativos, agruparlos por distintas razones.

- Datos continuos imposibles de medir exactamente.
- Datos discretos con muchos posibles valores.
- Gran número de datos e interesa estudiar sus frecuencias.

Para agrupar datos:

a). Se decide el número de intervalos.

b). Se decide su amplitud.

c). Se calculan los extremos.

d). Se calcula la marca de clase.

Número de intervalos

R dispone de las funciones nclass.Sturges, nclass.scott y nclass.FD para calcular este número usando las reglas de Sturges, Scott o Freedman-Diaconis, respectivamente.

Amplitud

- Todos los intervalos de la misma longitud.
- La amplitud A es el cociente entre el rango de datos y el número de intervalos, redondeado por exceso.

Extremos

Intervalos de la forma:

$$[L_1, L_2), [L_2, L_3), ..., [L_k, L_{k+1})$$

$$L_1 = \min(x) - 0{,}5 \cdot \text{precisión}$$

$$L_i = L_1 + (i-1)A$$

Vamos a proceder a realizar un agrupamiento de datos en R:

Listing 12.1: Código agrupamiento de datos

```
#Datos a agrupar
> iris$Petal.Length
  [1] 1.4 1.4 1.3 1.5 1.4 1.7 1.4 1.5 1.4 1.5 1.5 1.6 1.4 1.1
      1.2 1.5 1.3 1.4
 [19] 1.7 1.5 1.7 1.5 1.0 1.7 1.9 1.6 1.6 1.5 1.4 1.6 1.6 1.5
      1.5 1.4 1.5 1.2
 [37] 1.3 1.4 1.3 1.5 1.3 1.3 1.3 1.6 1.9 1.4 1.6 1.4 1.5 1.4
      4.7 4.5 4.9 4.0
 [55] 4.6 4.5 4.7 3.3 4.6 3.9 3.5 4.2 4.0 4.7 3.6 4.4 4.5 4.1
      4.5 3.9 4.8 4.0
 [73] 4.9 4.7 4.3 4.4 4.8 5.0 4.5 3.5 3.8 3.7 3.9 5.1 4.5 4.5
      4.7 4.4 4.1 4.0
 [91] 4.4 4.6 4.0 3.3 4.2 4.2 4.2 4.3 3.0 4.1 6.0 5.1 5.9 5.6
      5.8 6.6 4.5 6.3
[109] 5.8 6.1 5.1 5.3 5.5 5.0 5.1 5.3 5.5 6.7 6.9 5.0 5.7 4.9
      6.7 4.9 5.7 6.0
[127] 4.8 4.9 5.6 5.8 6.1 6.4 5.6 5.1 5.6 6.1 5.6 5.5 4.8 5.4
      5.6 5.1 5.1 5.9
[145] 5.7 5.2 5.0 5.2 5.4 5.1
#Agrupación datos
nclass.scott(iris$Petal.Length)
[1] 6
nclass.Sturges(iris$Petal.Length)
[1] 9
nclass.FD(iris$Petal.Length)
[1] 5
k=nclass.FD(iris$Petal.Length)
A=diff(range(iris$Petal.Length))/k
> A
[1] 1.18
A=1.2#Redondear a la décima, en exceso
```

```
#Extremos de los intervalos
m=min(iris$Petal.Length)
L=m-0.05+A*(0:k)
> L
[1] 0.95 2.15 3.35 4.55 5.75 6.95
#Marcas de clase
marcas=(L[0:k]+L[1:k+1])/2
> marcas
[1] 1.55 2.75 3.95 5.15 6.35
```

12.1.2. Agrupamiento de datos con R

R agrupa los datos codificándolos en un factor cuyos niveles son las clases en las que hemos agrupado los valores y asignando cada dato a su clase.

cut(x,breaks=...,labels=...,right=...)

- x es un vector numérico.
- breaks es un vector numérico con los extremos de los intervalos en los que queremos agrupar.
- labels es un vector con las etiquetas de los intervalos.
- right indica cómo queremos el extremo derecho de los intervalos.

Retorna una lista con los elementos de x codificados. Una vez agrupados los datos, podemos calcular sus frecuencias.
Vamos a terminar de agrupar los datos del ejemplo anterior:

Listing 12.2: Código agrupamiento de datos con R

```
#Terminar de agrupar
etiq=c("muy corto","corto","medio","largo","muy largo")
Largo_cut=cut(iris$Petal.Length,breaks=L,labels=etiq,right=
    FALSE)
> Largo_cut
  [1] muy corto muy corto muy corto muy corto muy corto muy
      corto muy corto
  [8] muy corto muy corto muy corto muy corto muy corto muy
      corto muy corto
 [15] muy corto muy corto muy corto muy corto muy corto muy
     corto muy corto
 [22] muy corto muy corto muy corto muy corto muy corto muy
     corto muy corto
 [29] muy corto muy corto muy corto muy corto muy corto muy
     corto muy corto
 [36] muy corto muy corto muy corto muy corto muy corto muy
     corto muy corto
```

```
 [43] muy corto muy corto muy corto muy corto muy corto muy
    corto muy corto
 [50] muy corto largo      medio      largo      medio      largo
      medio
 [57] largo      corto      largo      medio      medio      medio
      medio
 [64] largo      medio      medio      medio      medio      medio
      medio
 [71] largo      medio      largo      largo      medio      medio
      largo
 [78] largo      medio      medio      medio      medio      medio
      largo
 [85] medio      medio      largo      medio      medio      medio
      medio
 [92] largo      medio      corto      medio      medio      medio
      medio
 [99] corto      medio      muy largo  largo      muy largo  largo
      muy largo
[106] muy largo  medio      muy largo  muy largo  muy largo  largo
      largo
[113] largo      largo      largo      largo      largo      muy
    largo muy largo
[120] largo      largo      largo      muy largo  largo      largo
      muy largo
[127] largo      largo      largo      muy largo  muy largo  muy
    largo largo
[134] largo      largo      muy largo  largo      largo      largo
      largo
[141] largo      largo      largo      muy largo  largo      largo
      largo
[148] largo      largo      largo
Levels: muy corto corto medio largo muy largo
#Calculamos sus frecuencias para agruparlas en un data.frame
f_abs=as.vector(table(Largo_cut))
f_abs_acum=cumsum(table(Largo_cut))
f_rel=as.vector(prop.table(table(Largo_cut)))
f_rel_acum=cumsum(prop.table(table(Largo_cut)))
tabla_frec=data.frame(marcas,f_abs,f_abs_acum,f_rel,f_rel_acum
    )
           marcas f_abs f_abs_acum     f_rel f_rel_acum
muy corto   1.55    50         50 0.3333333  0.3333333
corto       2.75     3         53 0.0200000  0.3533333
medio       3.95    34         87 0.2266667  0.5800000
largo       5.15    47        134 0.3133333  0.8933333
muy largo   6.35    16        150 0.1066667  1.0000000
```

12.2. Estadísticos para datos agrupados

En este capítulo vamos a ver cómo realizar cálculos estadísticos de datos agrupados, como por ejemplo de encuestas. Cuando tratamos con datos agrupados:

- Si disponemos de los datos en bruto, se calculan los estadísticos de la forma habitual.
- En caso contrario, se aproximan los estadísticos de los datos reales mediante estadísticos de los datos agrupados.

Mismas fórmulas que con datos sin agrupar pero **cambiando cada clase por su marca**.

12.2.1. Fórmulas de los estadísticos

Supongamos que tenemos k clases, con marcas $X_1, ..., X_k$ y frecuencias absolutas $n_1, ..., n_k$ con un total de n datos. Entonces:
Media:

$$\vec{x} = \frac{\sum_{i=1}^{k} n_i \cdot X_i}{n}$$

Varianza:

$$s^2 = \frac{\sum_{i=1}^{k} n_i \cdot X_i^2}{n} - \vec{x}^2$$

Varianza muestral:

$$\vec{s}^2 = \frac{n}{n-1} s^2$$

Desviación típica:

$$s = \sqrt{s^2}$$

Desviación típica muestral:

$$\sqrt{s} = \sqrt{\vec{s}^2}$$

Moda→ **Intervalo modal**: Clase con mayor frecuencia.
Para realizar estos cálculos en R vamos a utilizar el data frame Chile, que cuenta las intenciones de voto en el plebiscito de Chile de 1988.

- **region**: Región del país.
- **population**: Población del municipio o ciudad.
- **sex**: Sexo.
- **age**: Edad.
- **education**: Nivel educativo.
- **income**: Ingresos mensuales.
- **statusquo**: Nivel de apoyo al status quo.
- **vote**: Intención de voto.

Listing 12.3: Código fórmulas estadísticas aplicadas al data frame Chile

```
> library(car)
> data(Chile)
> head(Chile)
  region population sex age education income statusquo vote
1      N     175000   M  65         P  35000   1.00820    Y
2      N     175000   M  29        PS   7500  -1.29617    N
3      N     175000   F  38         P  15000   1.23072    Y
4      N     175000   F  49         P  35000  -1.03163    N
5      N     175000   F  23         S  35000  -1.10496    N
6      N     175000   F  28         P   7500  -1.04685    N
#Quitar datos perdidos
Chile2=na.omit(Chile)
#Agrupamiento de datos
k=nclass.scott(Chile2$age)
> k
[1] 14
k=nclass.scott(Chile2$age)
diff(range(Chile2$age))/k
[1] 3.714286
A=4
#Creación tabla de frecuencias
#Creación tabla de frecuencias
Tabla_frec_agrup=function(x,k,a,p){
  L=min(x)-p/2+A*(0:k)
  x_int=cut(x,breaks = L,right = FALSE)
  intervalos=levels(x_int)
  marcas=(L[1]+L[2]/2+A*(0:(k-1)))
  f.abs=as.vector(table(x_int))
  f.rel=f.abs/length(x)
  f.abs.cum=cumsum(f.abs)
  f.rel.cum=cumsum(f.rel)
  tabla_x=data.frame(intervalos,marcas,f.abs,f.abs.cum,f.rel,f
      .rel.cum)
  tabla_x
}
tabla=Tabla_frec_agrup(Chile2$age,k,A,1)
> tabla
     intervalos marcas f.abs f.abs.cum      f.rel f.rel.cum
1  [17.5,21.5)  28.25   310        310 0.12751954 0.1275195
2  [21.5,25.5)  32.25   302        612 0.12422871 0.2517483
3  [25.5,29.5)  36.25   238        850 0.09790210 0.3496503
4  [29.5,33.5)  40.25   207       1057 0.08515014 0.4348005
5  [33.5,37.5)  44.25   259       1316 0.10654052 0.5413410
6  [37.5,41.5)  48.25   204       1520 0.08391608 0.6252571
7  [41.5,45.5)  52.25   193       1713 0.07939120 0.7046483
```

```
8  [45.5,49.5)  56.25   134       1847 0.05512135 0.7597696
9  [49.5,53.5)  60.25   111       1958 0.04566022 0.8054299
10 [53.5,57.5)  64.25   115       2073 0.04730564 0.8527355
11 [57.5,61.5)  68.25   136       2209 0.05594406 0.9086796
12 [61.5,65.5)  72.25    98       2307 0.04031263 0.9489922
13 [65.5,69.5)  76.25    79       2386 0.03249691 0.9814891
14 [69.5,73.5)  80.25    45       2431 0.01851090 1.0000000
#Cálculo estadísticos
Total=sum(tabla$f.abs)
> Total
[1] 2431
#Media
Media=sum(tabla$f.abs*tabla$marcas)/Total
> Media
[1] 47.08176
Media.sin.agrupar=mean(Chile2$age)
> Media.sin.agrupar
[1] 38.29
#Varianza
Varianza=sum(tabla$f.abs*tabla$marcas^2)/Total-Media^2
> Varianza
[1] 216.2115
Varianza.sin.agrupar=(Total-1)/Total*var(Chile2$age)
> Varianza.sin.agrupar
[1] 215.0377
#Desviación típica
Desv.tip=sqrt(Varianza)
> Desv.tip
[1] 14.70413
#Intervalo modal
Int.modal=tabla$intervalos[which(tabla$f.abs==max(tabla$f.abs)
    )]
> Int.modal
[1] [17.5,21.5)
14 Levels: [17.5,21.5) [21.5,25.5) [25.5,29.5) [29.5,33.5) ...
     [69.5,73.5)
```

12.2.2. Cuantiles de datos agrupados

Para calcular el cuantil Q_p de orden p, se requiere el **Intervalo crítico**, que es el primer intervalo con frecuencia relativa acumulada $\geq p$. Sea este $[L_c, L_{c+1})$. Entonces el cuantil de orden p viene dado por:

$$Q_p = L_c + A_c \cdot \frac{pn - N_{c-1}}{n_c}$$

Donde:

- A_c es la amplitud del intervalo crítico.
- n es el total de datos.
- N_{c-1} es la frecuencia absoluta acumulada del intervalo anterior al crítico.
- nc es la frecuencia absoluta del intervalo crítico.

Vamos a seguir con el ejemplo anterior para sumarle estos datos estadísticos:

Listing 12.4: Código fórmulas estadísticas aplicadas al data frame Chile

```
#Mediana
crit=min(which(tabla$f.rel.cum>=0.5))
> crit
[1] 5
> tabla$intervalos[crit]
[1] [33.5,37.5)
14 Levels: [17.5,21.5) [21.5,25.5) [25.5,29.5) [29.5,33.5) ...
    [69.5,73.5)
Lc=tabla$marcas[crit]-A/2
> Lc
[1] 42.25
n=Total
> n
[1] 2431
nc=tabla$f.abs[crit]
> nc
[1] 259
Nc1=tabla$f.abs.cum[crit-1]
> Nc1
[1] 1057
Mediana=Lc+A*(0.5*n-Nc1)/nc
> Mediana
[1] 44.69788
median(Chile2$age)
[1] 36
```

12.3. Histogramas

En este capítulo vamos a ver cómo generar histogramas con R y cómo mejorarlos.
Los histogramas son unos diagramas de barras con los que se describen gráficamente los datos agrupados. Cada barra representa una clase cuya frecuencia determina el área de la barra.

- **Histogramas de frecuencias absolutas**: La altura de cada barra es la necesaria para que el área sea igual a la frecuencia absoluta de cada clase. **Histogramas de frecuencias relativas**: La altura de cada barra es la necesaria para que el área sea igual a la frecuencia relativa de la clase.

- **Histogramas de frecuencias acumuladas (absolutas o relativas)**: Las alturas de las barras son iguales a las frecuencias acumuladas de las clases.

12.3.1. Histogramas en R

La función para dibujar histogramas con R es hist(x,breaks=...,freq=...,right=...,....) donde:

- x es el vector de datos.
- breaks establece los valores de los extremos de los intervalos, el número de intervalos o el método para calcular las clases.
- freq igualado a TRUE produce el histograma de frecuencias absolutas. Igualado a FALSE de frecuencias relativas.
- right igualado a FALSE deja los intervalos abiertos por la derecha.
- Otros parámetros usuales de la función plot.

El resulado de hist es una list con las siguentes componentes:

- breaks: Da los extremos de los intervalos.
- mids: Da los puntos medios de los intervalos.
- counts: Da las frecuencias absolutas de los intervalos.
- density: Da las densidades de los intervalos.

Para ver los histogramas, vamos a volver a utilizar el data frame Chile:

Listing 12.5: Código histogramas

```
data(Chile)
head(Chile)
  region population sex age education income statusquo vote
1      N     175000   M  65         P  35000   1.00820    Y
2      N     175000   M  29        PS   7500  -1.29617    N
3      N     175000   F  38         P  15000   1.23072    Y
4      N     175000   F  49         P  35000  -1.03163    N
5      N     175000   F  23         S  35000  -1.10496    N
6      N     175000   F  28         P   7500  -1.04685    N
Chile2=na.omit(Chile)
k=14
A=4
L=min(Chile2$age)-0.5+A*(0:14)
#Histograma
hist(Chile2$age,breaks=L,right=FALSE,main="Histograma de
   frecuencias absolutas",xlab="Intervalos",ylab="Frecuencias
   absolutas")
```

```
h=hist(Chile2$age,breaks=L, right=FALSE, plot=FALSE)
h$breaks
[1] 17.5 21.5 25.5 29.5 33.5 37.5 41.5 45.5 49.5 53.5 57.5
   61.5 65.5 69.5 73.5
h$mids
[1] 19.5 23.5 27.5 31.5 35.5 39.5 43.5 47.5 51.5 55.5 59.5
   63.5 67.5 71.5
h$counts
[1] 310 302 238 207 259 204 193 134 111 115 136  98  79  45
#Histograma de frecuencias absolutas
hist_abs=function(x,L){
  h=hist(x,breaks=L,right=FALSE, freq=FALSE,
         xaxt="n",yaxt="n",col="lightgray",
         main="Histograma de frecuencias absolutas",
         xlab="Intervalos y marcas de clase",
         ylab="Frecuencias absolutas")
  axis(1,at=L)
  text(h$mids,h$density/2,labels=h$counts,col="blue" )
}
hist_abs(Chile2$age,L)
#Histograma de frecuencias absolutas acumuladas
hist_abs.cum=function(x,L){
  h=hist(x,breaks=L, right=FALSE,plot=FALSE)
  h$density=cumsum(h$density)
  plot(h,freq=FALSE,xaxt="n",yaxt="n",col="lightgray",
       main="Histograma de frecuencias absolutas acumuladas",
       xlab="Intervalos",ylab="Frec.absolutas acumuladas")
  axis(1,at=L)
  text(h$mids,h$density/2,labels=cumsum(h$counts),col="blue")
}
hist_abs.cum(Chile2$age,L)
```

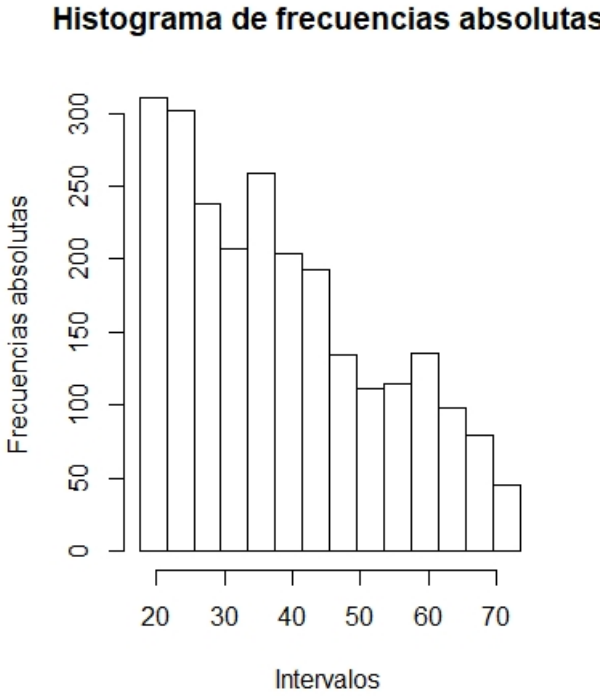

Figura 12.1: Histograma de frecuencias absolutas

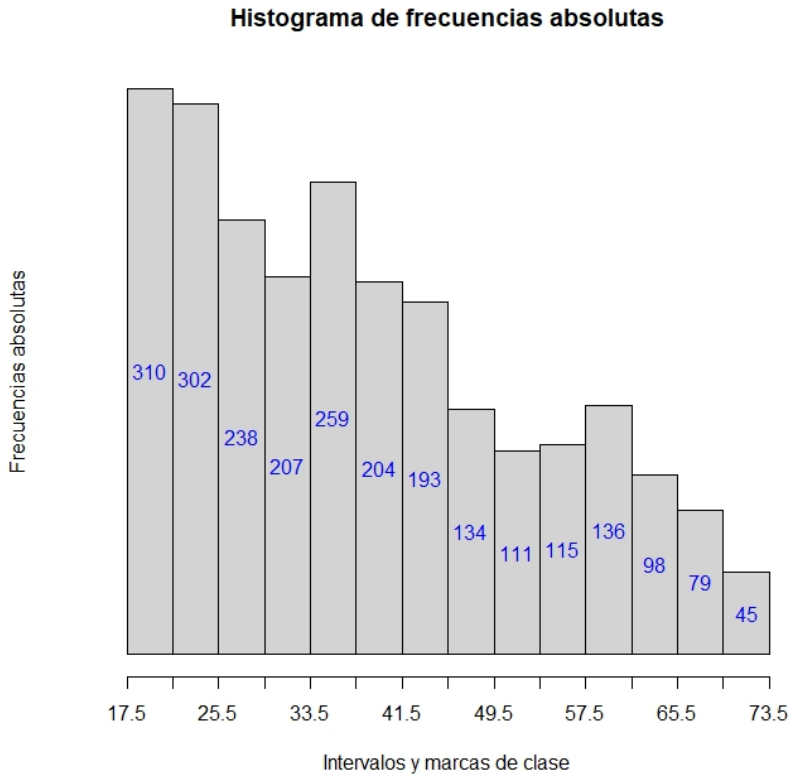

Figura 12.2: Histograma de frecuencias absolutas con colores y datos frecuencias

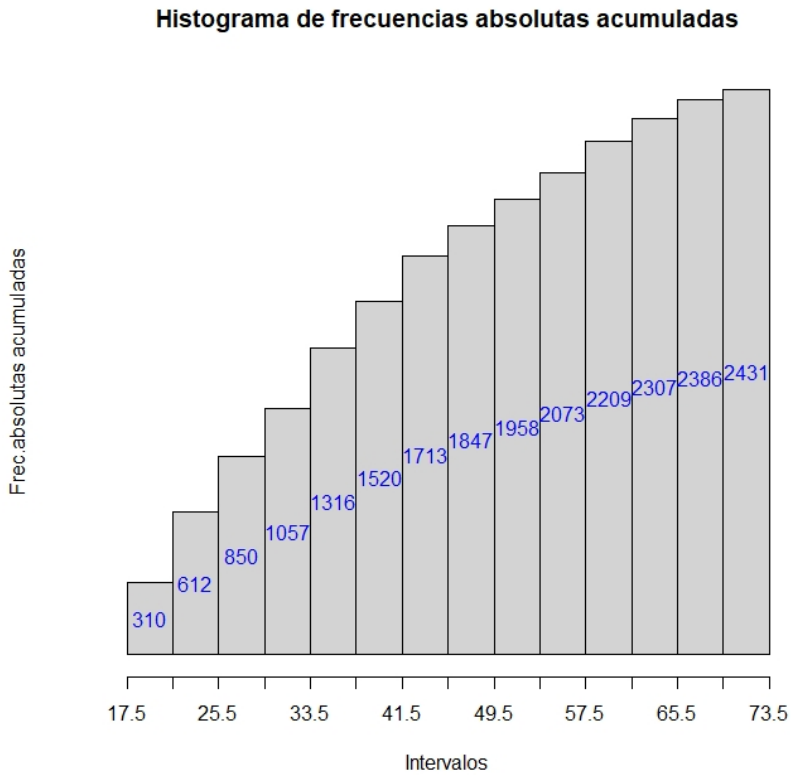

Figura 12.3: Histograma de frecuencias absolutas acumuladas

12.3.2. Densidad de una variable

La densidad de una variable es una curva tal que el área comprendida entre el eje de abscisas y la curva sobre un intervalo es igual a la fracción de individuos de la población que caen dentro de ese intervalo.
Para estimar la densidad de la distribución a partir de una muestra hay que usar la función density.
Se suele incluir en los histogramas de frecuencias relativas.

Función de distribución de una variable

La función de distribución de una variable nos da, en cada punto, la frecuencia relativa acumulada por la variable sobre la población en ese punto.
Para estimar la función de distribución hay que ir acumulando los valores dados por density.
Se suele incluir en los histogramas de frecuencias relativas acumuladas.
Vamos a ver la densidad del ejemplo anterior:

Listing 12.6: Código cálculo densidad

```
#Densidad
plot(density(Chile2$age), type="l", main="Densidad de la
    variable edad", xlab="Edad",ylab="Densidad")
```

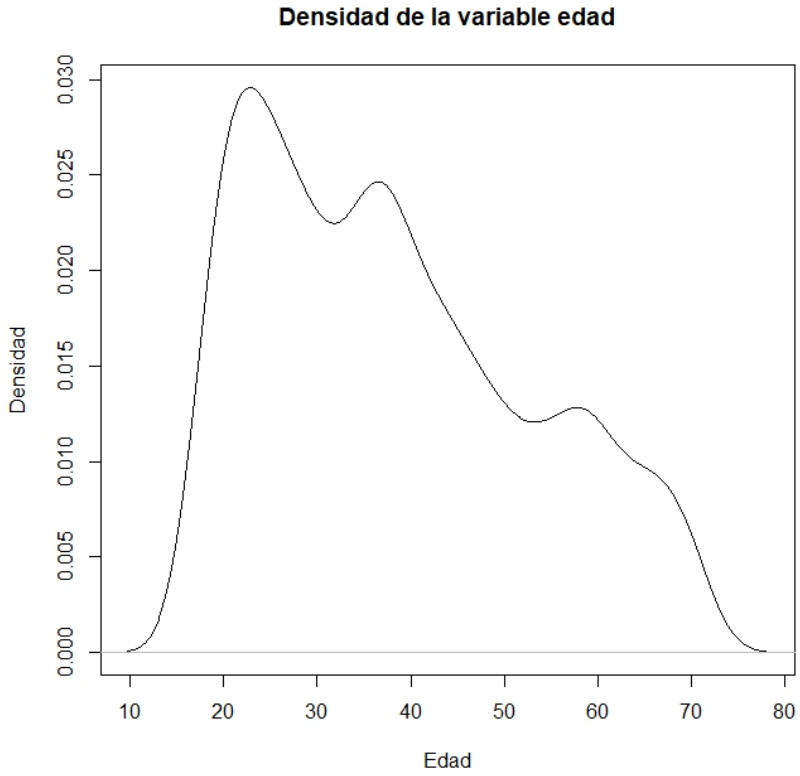

Figura 12.4: Densidad de la variable edad

Se podrá dibujar la curva de densidad junto con el histograma de frecuencias acumuladas.

Índice de figuras

Índice de cuadros

Listings

PASCAL
ENERO 2018
Ult. actualización 4 de mayo de 2019
LaTeX lic. LPPL & powered by TEFLON CC-ZERO