

Maria Isabel Borrajo García, Mercedes Conde Amboage e Rosa María Crujeiras Casais (Departamento de Estatística, Análise Matemática e Optimización)

R é unha linguaxe de programación orientada ao ámbito da estatística. Trátase dunha linguaxe interpretada que se emprega maioritariamente de xeito interactivo, distribuída baixo licenza GNU, e que dispón dunha serie de características no módulo base que se pode ir ampliando por medio de librarías. O proceso de instalación e toda a información relativa ao programa pode atoparse en <http://www.r-project.org/>.

Para poder emplegar calquera das librarías ou paquetes os pasos que cómpre seguir son:

- Instalar a libraría dende o repositorio CRAN (precísase de conexión á Rede), para o que se emprega a orde `install.packages("nome_da_libraría")`.
- Cargar a libraría na sesión de R actual para poder emplegar as funcións que contén, isto farase coa sentenza `library(nome_do_paquete)`.

Para calquera dúbida sobre estas ou outras funcións do programa, pode consultarse a súa páxina de axuda tecleando na consola `?nome_da_función` ou `help(nome_da_función)`.


O programa estatístico R dispón de diversas interfaces gráficas más amigables para as persoas usuarias non expertas. Unha das más habitualmente empregadas é RStudio, que pode obterse de xeito libre dende <https://rstudio.com/>, outra opción dispoñible é R Commander, unha interface incluída dentro do propio R mediante a libraría Rcmdr.

## BÁSICOS

O primeiro que debemos de saber para manexar R é que a asignación (gardar un valor nunha variable) faise mediante o símbolo = ou <-; por exemplo, `x=5` ou `x<-5` para gardar o valor 5 nunha variable denominada x.

O seguinte que se debe coñecer son as distintas clases de obxectos que R permite manexar:

- logical: consta únicamente de dous valores de tipo lóxico que son TRUE (denotado tamén por T) ou FALSE (denotado tamén por F).
- integer: almacena valores de tipo enteiro (números naturais e opostos, sen decimais).
- numeric: almacena valores de tipo real.
- complex: almacena valores de tipo complexo (parte real e parte imaxinaria).
- character: almacena valores de tipo carácter, é dicir, secuencias de letras ou texto.
- factor: almacena variables de tipo categórico, onde as categorías constitúen os niveis do factor.



```

> x
[1] 1 2 3 4 5
>
> A=matrix(1:6, nr=2, nc=3)
> A
 [,1] [,2] [,3]
 [1,]    1    3    5
 [2,]    2    4    6
> 
  
```

A continuación verase unha colección de comandos básicos para traballar cos distintos tipos de obxectos, así como coas diferentes estruturas de datos que se poden manexar en R: vector, matrix (matriz), list (lista), data.frame (base de datos),...

### Creación de datos

<code>c(...)</code>	función para combinar argumentos separados por comas e formar un vector.
<code>dende:ata</code>	xera unha secuencia que comeza en dende e remata en ata con paso unha unidade.
<code>factor(x, levels=lev)</code>	crea un obxecto de tipo factor con categorías dadas en lev.
<code>matrix(datos, nrow=n, ncol=m, byrow=F)</code>	crea unha matriz a partir de datos de dimensión $n \times m$ onde os elementos se colocan por columnas; colocaranse enchendo filas se o argumento <code>byrow=T</code> .
<code>rbind(x1,x2,...); cbind(x1,x2,...)</code>	combina os elementos $x_1, x_2, \dots$ (vector, matriz ou base de datos) concatenándoo por filas (r) ou columnas (c).
<code>rep(x,times=v)</code>	constrúe un vector repetindo v veces o elemento x, que pode ser un valor, un vector, unha matriz, unha lista,...
<code>seq(dende,ata,by=p, length=l)</code>	xera unha secuencia que comeza en dende e remata en ata, ben con paso p ou ben de lonxitude l.

## BÁSICOS (cont.)

### Extraer valores

x[k]	accede ao elemento k-ésimo do vector x.
x[-k]	accede a todos os elementos do vector x salvo ao k-ésimo.
x[c(1,3,7)]	accede ao primeiro, terceiro e séptimo elementos do vector x.
x[x<2]	accede a todos os elementos de x que cumpran a condición de seren menores que 2.
x[i,k]	accede ao elemento da fila i e columna k da matriz ou base de datos x.
x[i, ]	accede á fila i-ésima da matriz ou base de datos x.
x[ ,k]	accede á columna k-ésima da matriz ou base de datos x.
x[ ,c(2,4)]	accede ás columnas segunda e cuarta da matriz ou base de datos x.
x[[k]]	accede ao elemento k-ésimo da lista x.
x[["nome"]]	accede ao elemento da lista x denominado nome.
x\$nome	accede ao elemento da lista ou base de datos denominado nome.



### Información sobre variables

class(x)	devolve o tipo de obxecto que é x.
dim(x)	devolve a dimensión (nº de filas e nº de columnas) da matriz ou base de datos x.
is.numeric(x)	devolve cun valor lóxico indicando se o obxecto x é (T) ou non é (F) de tipo numérico. Análogo para is.character, is.na, is.complex, is.data.frame,...
length(x)	devolve o número de elementos do obxecto x.
nrow(x);ncol(x)	devolve o número de filas (nr) ou columnas (nc) da matriz ou base de datos x.
summary(x)	resume a información contida no obxecto x; dependendo da clase de x proporciona diferente información.

### Selección e manipulación de datos

choose(x,k)	calcula as posibles combinacións de coller k elementos en n repeticións.
cut(x,breaks=b)	crea a partir do obxecto x un novo obxecto de tipo factor mediante a división de x en intervalos (categorías); b pode ser o número de intervalos, ou os propios puntos de corte que delimitan os intervalos.
det(x)	calcula o determinante da matriz x.
diag(x)	accede á diagonal da matriz x.
eigen(x)	calcula os autovalores e autovectores da matriz x.
match(x,y)	define un vector da mesma lonxitude de x, cos elementos de x que están en y e NA (valor co que <b>R</b> codifica os datos ausentes) noutro caso.
round(x,digits=nd)	redondea os valores numéricos de x ao número de decimais dado por nd.
rowsum(x);colsum(x)	calcula a suma por filas (row) ou columnas (col) da matriz ou base de datos x.
rowMeans(x);colMeans(x)	calcula a media por filas (row) ou columnas (col) da matriz ou base de datos x.
solve(x)	calcula a matriz inversa da matriz x.
sort(x, decreasing=F)	ordena de xeito crecente (ou decrecente se decreasing=T) os elementos de x. Empregando o argumento index.return=T pódese obter o valor da posición dos elementos segundo a súa orde (crecente ou decrecente).
t(x)	calcula a matriz trasposta da matriz x.
x%*%y	calcula o produto escalar ou matricial dos vectores ou matrices x e y.
which(x<2)	determina a/as posición/s dos elementos de x que cumpran a condición de ser menores que 2.
which.min(x);which.max(x)	determina a posición que ocupa en x o seu elemento de menor (min) ou maior (max) valor.

$$A = \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{m1} & \cdots & a_{mn} \end{pmatrix}$$

### Lectura e escritura de datos

data(nome)	carga o conxunto de datos nome gardado en <b>R</b> ; se non se especifica ningún argumento, lista os conxuntos de datos dispoñibles na sesión actual de <b>R</b> .
load(...)	carga datos dende unha área de traballo previamente gardada (en xeral con save).
read.table(file="nome.ext", sep=";", dec=",", header=T)	carga os datos almacenados no arquivo nome, de extensión .ext (.txt, .dat). Co argumento sep determinase o elemento que serve para separar valores no arquivo, con dec indícase o símbolo empregado para o separador decimal e header é un argumento lóxico que indica se a primeira fila da base de datos contén os nomes das variables (T) ou contén os valores do primeiro individuo (F). Análogo read.csv para extensións .csv.

## BÁSICOS (cont.)

### Lectura e escritura de datos (cont.)

attach(dat)	carga no contorno de traballo as variables da base de datos dat.
complete.cases(x,y)	indica as posicións comúns sen NA nos elementos x e y.
head(dat)	amosa as seis primeiras liñas do elemento dat.
names(dat)	indica os nomes dos elementos almacenados en dat.
save(nome,file=arquivo)	garda o elemento nome en arquivo.
save.image()	garda todos os elementos que se atopen na memoria da sesión nese momento nun arquivo .RData.
View(dat)	permite visualizar a base de datos dat nun formato de táboa ao estilo dunha folla de cálculo.
write.table(x, file="nome.ext")	garda o elemento x nun arquivo .ext (.txt, .csv) tras convertelo en base de datos.




## ESTATÍSTICA DESCRIPTIVA

addmargins(tab)	engade a fila e columna dos totais (marxinais) a unha táboa de dobre entrada tab.
barplot(tab)	representa o diagrama de barras asociado ás frecuencias tab, que se poden obter, por exemplo, coa función table.
boxplot(x)	representa un diagrama de caixa para os valores de x.
boxplot(x~y)	representa un diagrama de caixa para os valores de x agrupados segundo as categorías do factor y.
cov(x,y);cor(x,y)	calcula a cuasicovarianza (cov) ou correlación (cor) entre os valores de x e de y.
cumsum(x);cumprod(x)	vector no que o elemento i-ésimo é a suma (sum) ou produto (prod) acumulados dos elementos x[1:i].
describe(x)	calcula numerosas características dos elementos de x: tamaño da mostra, número de valores perdidos, media, cuantís, táboa de frecuencias,... Esta función está dispoñible na libraría Hmisc.
diff(x)	calcula un vector de lonxitude unha unidade menor que a lonxitude de x coas diferenzas iteradas dos elementos de x.
hist(x,breaks=b,freq=T)	representa un histograma con b+1 intervalos (ou cos intervalos dados en b); se freq=T representa as frecuencias absolutas, en caso contrario representa densidades.
IQR(x)	calcula o rango intercuartílico (terceiro menos primeiro cuartil) dos elementos de x.
kurtosis(x)	calcula o coeficiente de curtose para os valores de x. Esta función está dispoñible na libraría moments.
max(x)	calcula o valor máximo dos elementos de x.
mean(x)	calcula a media da mostra x. Engadindo o argumento trim=p, calcula a media recortada coa proporción de datos eliminados dada por p.
median(x)	calcula a mediana da mostra x.
min(x)	calcula o valor mínimo dos elementos de x.
pie(tab)	representa o diagrama de sectores asociado ás frecuencias tab, que se poden obter, por exemplo, coa función table.
pie3D(tab)	representa o diagrama de sectores con volume (3D) asociado ás frecuencias tab, que se poden obter, por exemplo, coa función table.
proportions(tab,margin=m)	calcula as proporcións condicionadas da táboa tab dadas as marxinais m.
qqplot(x,y)	representa os cuantís de x fronte aos cuantís de y.
quantile(x,probs=p)	calcula o cuantil dos elementos de x definido pola probabilidade en p. Tamén é valido que p sexa un vector de probabilidades.
range(x)	calcula simultaneamente os valores mínimo e máximo dos elementos de x.
skewness(x)	calcula o coeficiente de asimetría para os valores de x. Esta función está dispoñible na libraría moments.
sum(x);prod(x)	calcula a suma (sum) ou producto (prod) dos elementos de x.
table(x)	conta os elementos dos distintos valores de x.
table(x,y)	realiza unha táboa de dobre entrada dos elementos x e y.
unique(x)	vector cos elementos de x eliminando os elementos repetidos.
var(x);sd(x)	calcula a cuasivarianza (var) ou cuasidesviación típica (sd) dos elementos de x.
weighted.mean(x,w)	calcula a media da mostra x ponderada polo vector de pesos w.



## VARIABLES ALEATORIAS



calcula a función de masa de probabilidade (función de densidade) nun punto  $x$  asociada a unha variable DISTR discreta (variable continua). Amais, os argumentos desta función dependen da DISTR considerada. As principais variables que podemos empregar con son:

DISTRIBUCIÓN	DISTR	ARGUMENTOS
Binomial ( $n,p$ )	binom	size=n, prob=p
Binomial negativa ( $n,p$ )	nbinom	size=n, prob=p
Poisson ( $\lambda$ )	pois	lambda=λ
Uniforme ( $a,b$ )	unif	min=a, max=b
Normal ( $\mu,\sigma$ )	norm	mean=μ, sd=σ
Exponencial ( $\lambda$ )	exp	rate=λ
Gamma ( $n,\lambda$ )	gamma	shaper=n, rate=λ
T-Student con $gl$ graos de liberdade	t	df=gl
$\chi^2$ con $gl$ graos de liberdade	chisq	df=gl
F de Snedecor con $gl_1$ e $gl_2$ graos de liberdade	f	df1=gl1, df2=gl2

`density(x)`

estima a función de densidade asociada a unha mostra  $x$  empregando métodos non paramétricos.

`ecdf(x)`

calcula a función de distribución empírica asociada a unha mostra  $x$ .

`fitdistr(x, densfun="NOME")`

emprega o método de máxima verosimilhanza para axustar os parámetros asociados a unha distribución NOME para a mostra  $x$ . As distintas distribucións compatibles con esta función poden verse en `?fitdistr`. Esta función está dispoñible na libraría MASS.

`pDISTR(x)`

calcula a función de distribución nun punto  $x$  asociada a unha variable DISTR discreta ou continua. Esta función pódese aplicar para as mesmas distribucións que `dDISTR`.

`qDISTR(τ)`

calcula o cuantil de orde  $\tau$  asociado a unha variable DISTR discreta ou continua. Esta función pódese aplicar para as mesmas distribucións que `dDISTR`.

`qqPlot(x)`

representa os cuantís asociados á mostra  $x$  fronte aos cuantís dunha distribución normal. Esta función está dispoñible na libraría car.

`rDISTR(n)`

xera  $n$  datos asociados a unha variable DISTR discreta ou continua. Esta función pódese aplicar para as mesmas distribucións que `dDISTR`.

## INFERENCIA ESTATÍSTICA

`ks.test(x, "pDISTR")`

realiza un contraste de Kolmogorov-Smirnov para contrastar se a mostra  $x$  (que procede dunha variable aleatoria continua) segue unha distribución DISTR.

`chisq.test(x, y)`

realiza un contraste de independencia sobre dúas variables categóricas das que se coñecen as mostras  $x$  e  $y$ . Tamén se podería realizar o contraste introducindo simplemente unha táboa de continxencia.

`prop.test`

`(x, n, conf.level=β)`

calcula un intervalo de confianza de nivel  $\beta$  para a probabilidade de éxito asociado a un experimento de Bernoulli do que se observaron  $n$  realizacións das cales  $x$  foron éxitos. Se  $n$  e  $x$  fosen vectores de dimensión 2, calcularía un intervalo de confianza de nivel  $\beta$  para a diferenza das probabilidades de éxito asociadas a dous experimentos de Bernoulli.

`(x, n, p=p, alternative=alt)`

realiza un contraste de hipóteses para a probabilidade de éxito asociado a un experimento de Bernoulli do que se observaron  $n$  realizacións, das cales  $x$  foron éxitos. O valor da probabilidade de éxito que se quere contrastar será  $p$  mentres que o tipo de contraste vén determinado polo argumento `alternative`\*. Amais, se  $n$  e  $x$  fosen vectores de dimensión 2, realizaría un contraste para a diferenza das probabilidades de éxito asociadas a dous experimentos de Bernoulli (neste caso o argumento  $p$  non se emprega).

`shapiro.test(x)`

realiza un contraste de normalidade para unha variable  $X$  da que se ten a mostra  $x$ .


\* Nas funcións `prop.test`, `sigma.test`, `t.test`, `var.test` e `z.test` o argumento `alternative` pode ser “two.sided” (contraste bilateral), “less” (contraste unilateral esquerdo) ou “greater” (contraste unilateral dereito).

## INFERENCIA ESTATÍSTICA (cont.)

`sigma.test`

`(x, conf.level=β)`

`(x, sigmasq = σ², alternative=alt)`



calcula un intervalo de confianza de nivel  $\beta$  para a varianza poboacional dunha distribución normal da que se coñece unha mostra  $x$ .

realiza un contrate de hipóteses para a varianza poboacional dunha distribución normal da que se coñece unha mostra  $x$ . O valor da varianza poboacional que se quere contrastar será  $σ^2$  mentres que o tipo de contraste vén determinado polo argumento `alternative`\*\*.

Esta función está dispoñible na libraría `TeachingDemos`.

`t.test`

`(x, conf.level=β)`

`(x, y, conf.level=β, paired=T)`

`(x, mu=μ₀, alternative=alt)`

`(x, y, mu=μ₀, paired=F)`

calcula un intervalo de confianza de nivel  $\beta$  para a media poboacional dunha distribución normal da que se coñece unha mostra  $x$ .

calcula un intervalo de confianza de nivel  $\beta$  para a diferenza de medias poboacionais de dúas distribucións normais dependentes (`paired=T`) ou independentes (`paired=F`) das que se coñecen as mostras  $x$  e  $y$ . No caso de que `paired=F`, emprégase o argumento `var.equal=T` ou `F` para indicar que as varianzas poboacionais son iguais ou non.

realiza un contrate de hipóteses para a media poboacional dunha distribución normal da que se coñece unha mostra  $x$ . O valor da media poboacional que se quere contrastar será  $μ_0$  mentres que o tipo de contraste vén determinado polo argumento `alternative`\*\*.

calcula un contraste de hipóteses para a diferenza de medias poboacionais de dúas distribucións normais dependentes (`paired=T`) ou independentes (`paired=F`) con varianzas coñecidas ou descoñecidas (`var.equal=T` ou `F`) das que se coñecen as mostras  $x$  e  $y$ . O valor da diferenza de medias poboacionais que se quere contrastar será  $μ_0$  mentres que o tipo de contraste vén determinado polo argumento `alternative`\*\*.

`var.test`

`(x, y, conf.level=β)`

`(x, y, ratio=r, alternative=alt)`

calcula un intervalo de confianza de nivel  $\beta$  para o cociente das varianzas poboacionais de dúas distribucións normais das que se coñecen as mostras  $x$  e  $y$ .

realiza un contrate de hipóteses para o cociente das varianzas poboacionais de dúas distribucións normais das que se coñecen as mostras  $x$  e  $y$ . O valor do cociente de varianzas poboacionais que se quere contrastar será  $r$  mentres que o tipo de contraste vén determinado polo argumento `alternative`\*\*.

`z.test`

`(x, stdev= σ, conf.level=β)`

`(x, mu=μ₀, stdev= σ, alternative=alt)`

calcula un intervalo de confianza de nivel  $\beta$  para a media poboacional dunha distribución normal con desviación típica  $σ$  coñecida da que se coñece unha mostra  $x$ .

realiza un contrate de hipóteses para a media poboacional dunha distribución normal con desviación típica  $σ$  coñecida da que se coñece unha mostra  $x$ . O valor da media poboacional que se quere contrastar será  $μ_0$  mentres que o tipo de contraste vén determinado polo argumento `alternative`\*\*.

Esta función está dispoñible na libraría `TeachingDemos`.

\*\* Nas funcións `prop.test`, `sigma.test`, `t.test`, `var.test` e `z.test` o argumento `alternative` pode ser “`two.sided`” (contraste bilateral), “`less`” (contraste unilateral esquierdo) ou “`greater`” (contraste unilateral dereito).

## MODELOS DE REGRESIÓN

aov(y~grupos)

realiza un contraste de igualdade de medias poboacionais asociadas a unha distribución normal (da que coñecemos unha mostra y) medida en diferentes grupos (determinados polo vector grupos).

boxcox(y~x1+x2+...+xd)

calcula o parámetro  $\lambda$  óptimo asociado a unha transformación tipo Box-Cox que permite corrixir a falta de cumprimento das hipóteses básicas do modelo de regresión linear múltiple con variable resposta y e variables explicativas  $x_1, x_2, \dots, x_d$ . Esta función está dispoñible na libraría MASS.

Box.test(x, lag = γ,  
type="Ljung-Box")

realiza o contraste de Ljung-Box que comproba se as observacións da mostra x son non correladas fronte á hipótese alternativa de que exista correlación secuencial de orde γ.

confint(mod, level = β)

calcula intervalos de confianza de nivel β asociados aos parámetros do modelo de regresión mod.

glm(y~x1+x2+...+xd, family = NOME)


estima un modelo de regresión linear xeneralizado con variable resposta y e variables explicativas  $x_1, x_2, \dots, x_d$ . O argumento family permite seleccionar a función de enlace adecuada en función da natureza da variable resposta.

hmctest(mod)

contrasta a homocedasticidade do modelo de regresión linear múltiple mod. Esta función está dispoñible na libraría lmtest.

lm(y~x1+x2+...+xd)

estima un modelo de regresión linear múltiple con variable resposta y e variables explicativas  $x_1, x_2, \dots, x_d$  empregando o método de mínimos cadrados.



names(mod)

proporciona os nomes das estimacións asociadas a un modelo de regresión, como os residuos (mod\$residuals) ou os valores axustados (mod\$fitted.values).

nls(y~fun(θ1,θ2,...,θk,  
start=list((θ1=n<sub>1</sub>,θ2=n<sub>2</sub>,...,θk=n<sub>k</sub>))

estima un modelo de regresión non linear cuxa expresión vén determinada por fun (coñecida) salvo polos parámetros  $\theta_1, \theta_2, \dots, \theta_k$ . Co argumento start introdúcese o punto de arranque do algoritmo iterativo de estimación.

plot(mod)

realiza catro representacións gráficas que permiten levar a cabo unha validación e diagnose do modelo de regresión múltiple mod.

predict(mod,data.frame(x1=δ<sub>1</sub>,  
x2=δ<sub>2</sub>,...,xd=δ<sub>d</sub>))

calcula predicións puntuais da variable resposta dun modelo de regresión mod con covariables  $x_1, x_2, \dots, x_d$  dada unha nova observación  $(\delta_1, \delta_2, \dots, \delta_d)$  das covariables. Tamén permite calcular intervalos de confianza para a esperanza condicional (interval="confidence") e intervalos de predición (interval="prediction").

resettest(y ~ x, power=2/3)

realiza o contraste do modelo linear simple con variable resposta y e variable explicativa x fronte a modelos polinómicos de orde 2/3. Esta función está dispoñible na libraría lmtest.

sm.regression(x,y,  
model="linear")

contrasta a linearidade dun modelo de regresión linear múltiple con covariables x (como máximo de dimensión 2) e variable resposta y. Esta función está dispoñible na libraría sm.

summary(mod)

proporciona unha lista de estatísticos resumo asociados a un modelo de regresión mod, como por exemplo, contrastes de significación dos coeficientes, a estimación da desviación típica do erro ou o coeficiente de determinación.

