R pentru incepatori

Emmanuel Paradis

Institututul de Stiinte ale Evolutiei
Universitatea din Montpellier II
F-34095 Montpellier cédex 05
Franta

E-mail: *paradis@isem.univ-montp2.fr*

I thank Julien Claude, Christophe Declercq, Élodie Gazave, Friedrich Leisch, Louis Luangkesron, François Pinard, and Mathieu Ros for their comments and suggestions on earlier versions of this document. I am also grateful to all the members of the R Development Core Team for their considerable efforts in developing R and animating the discussion list 'rhelp'. Thanks also to the R users whose questions or comments helped me to write "R for Beginners". Special thanks to Jorge Ahumada for the Spanish translation.

Traducerea si adaptarea textului in limba romana cu acordul autorului: Ana Maria Dobre

Multumiri: Multumiri echipei R-omania, cea care se ocupa de sustinerea R Project in Romania. Aceasta documentatie face parte din activitatile de cercetare ale echipei R-omania Team: www.r-project.ro

Contents

1 Introducere

Scopul prezentei documentatii este de a oferi un punct de plecare pentru cei nou interesati de R. Am ales sa scot in evidenta in intelegerea modului in care functioneaza R, cu intentia unui incepator, mai degraba decat a unui expert, utilizarea acestuia. Avand in vedere ca posibilitatile acoperite de R sunt vaste, este util unui incepator sa obtina notiuni si concepte de baza în scopul de a progresa cu usurinta. Am incercat sa simplific explicatiile cat de mult am putut pentru a le face usor de inteles de catre toti cititorii, dand in acelasi timp detalii utile, uneori exemplificate cu tabele.

R este un sistem pentru analize statistice si grafice creat de catre Ross Ihaka si Robert Gentleman [1]. R este in egala masura software si limbaj considerat a fi un dialect al limbajului S creat de catre AT&T Bell Laboratories. S este disponibil sub forma software-ului S-PLUS comercializat de catre Insightful[2]. Exista diferente importante intre designul R-ului si al S-ului: cei care doresc sa afle mai multe despre acest aspect pot citi articolul scris de catre Ihaka & Gentleman (1996) sau R-FAQ[3], o copie a acestuia fiind integrata in R.

R este distribuit in mod gratuit sub licenta *GNU General Public Licence*[4]; dezvoltarea precum si distributialui sunt in grija catorva statisticieni cunoscuti sub denumirea generica de *R Development Core Team*.

R este disponibil sub cateva forme: sursele (dezvoltate in special in C si proceduri in Fortran), esentiale pentru Unix si Linux sau cateva fisiere binare predefinite pentru Windows, Linux si Macintosh. Fisierele necesare pentru instalarea R, fie din surse sau din fisiere binare predefinite sunt distribuite pe site-ul *Comprehensive R Archive Network* (CRAN)[5] unde se gasesc si instructiunile pentru instalare. In ceea ce priveste variantele de Linux (Debian, ...), fisierele binare sunt in general disponibile pentu majoritatea versiunilor; cautati pe site-ul CRAN daca este necesar.

R are o multime de functii pentru analiza statistica si grafica; cele recente au vizualizare instantanee in propria fereastra si pot fi salvate in diferite formate (jpg, png, bmp, ps, pdf, emf, pictex, xfig; formatele disponibile pot depinde de sistemul de operare). Rezultatele unei analize statistice sunt afisate pe ecran, cateva rezultate intermediare (probabilitati, coeficienti de regresie, valori reziduale, ...) pot fi salvate, scrise intr-un fisier, sau folosite in analize ulterioare.

Limbajul R permite utilizatorului, spre exemplu, sa programeze grupurile de instructiuni pentru analiza succesiva a seturilor de date. De asemenea este

[1] Ihaka R. & Gentleman R. 1996. R: a language for data analysis and graphics. *Journal of Computational and Graphical Statistics* 5: 299–314.

[2] Vezi http://www.insightful.com/products/splus/default.asp pentru mai multe informatii

[3] http://cran.r-project.org/doc/FAQ/R-FAQ.html

[4] Pentru mai multe informatii: http://www.gnu.org/

[5] http://cran.r-project.org/

posibila combinarea intr-un singur program a mai multor functii statistice pentru a efectua analize mai complexe. Utilizatorii R pot beneficia de o gama larga de programe intocmite pentru S si care sunt disponibile pe Internet[6], majoritatea putand fi folosite direct in R.

La prima vedere, R poate parea prea complex pentru un non-specialist. Lucrurile nu stau insa astfel. In realitate, o caracteristica de seama a lui R este chiar flexibilitatea sa. In timp ce un software clasic afiseaza imediat rezultatele unei analize, R memoreaza aceste rezultate intr-un "obiect", astfel ca o analiza poate fi efectuata fara afisarea vreunui rezultat. Utilizatorul poate ramane surprins din aceasta cauza, insa o asemenea particularitate este foarte utila. Intr-adevar, utilizatorul poate extrage doar partea din rezultat de care este interesat. Spre exemplu, daca cineva ruleaza o serie de 20 de regresii si vrea sa compare diferiti coeficienti de regresie, R poate afisa numai coeficientii estimati: astfel rezultatul poate avea o singura linie, in timp ce un software clasic poate deschide 20 de ferestre cu rezultate. Vom vedea si alte exemple ce ilustreaza flexibilitatea lui R in comparatie cu software-urile traditionale.

[6]Spre exemplu: http://stat.cmu.edu/S/

2 Cateva concepte de baza

Odata ce R a fost instalat pe computer, software-ul poate fi lansat prin fisierul executabil corespunzator. Prompt-ul, implicit '>', indica faptul ca R asteapta comenzile operatorului. La utilizarea in Windows a programului Rgui.exe, cateva comenzi (accesarea suportului online, deschiderea fisierelor,...) pot fi executate prin meniurile derulante. In aceasta etapa, un utilizator nou isi poate pune intrebarea « Ce e de facut acum ? ». Este, intr-adevar, foarte util sa cunoasteti cateva lucruri de baza atunci cand utilizati R pentru prima data, iar acest fapt va fi demonstrat in cele ce urmeaza.

Vom vedea, pe scurt, cum functioneaza R. Apoi, vom descrie operatorul "assign", operator care permite crearea obiectelor, vom arata cum se organizeaza obiectele in memorie si cum se utilizeaza suportul online care este foarte util atunci cand rulati R.

2.1 Cum functioneaza R

Faptul ca R este un limbaj ii poate face pe unii dintre utilizatori sa gandeasca "Eu nu pot face programare". Acest argument nu este solid din doua motive. In primul rand, R este un limbaj interpretat, nu unul compilat, ceea ce presupune ca toate comenzile introduse prin tastatura sunt direct executate fara sa fie necesara redactarea unui program complet asa cum se intampla in majoritatea limbajelor de programare (C, Fortran, Pascal, ...).

In al doilea rand, sintaxa R este foarte simpla si intuitiva. Spre exemplu, o regresie liniara poate fi efectuata cu ajutorul comenzii `lm(y ~ x)` care inseamna "adecvarea modelului liniar avand y ca variabila de raspuns si x ca predictor". In R, pentru a putea fi executata, o functie trebuie *intotdeauna* sa fie scrisa cu paranteze, chiar daca nu este nimic scris intre acestea (de exemplu, `ls()`). Daca se tasteaza numele unei functii fara sa fie urmat de paranteze, R va afisa continutul functiei. In aceasta documentatie, numele functiilor sunt in general scrise cu paranteze pentru a le distinge de alte obiecte, daca nu cumva textul indica altfel.

Atunci cand R ruleaza, variabilele, datele, functiile, rezultatele, etc, sunt retinute in memoria activa a computerului sub forma unor *obiecte* cu un anumit *nume*. Utilizatorul poate actiona asupra acestor obiecte prin intermediul *operatorilor* (aritmetici, logici, de comparatie, ...) si *functiilor* (chiar ele fiind considerate obiecte). Utilizarea operatorilor este relativ intuitiva, mai tarziu vom detalia acest aspect (p. 27). O functie R poate fi redata astfel:

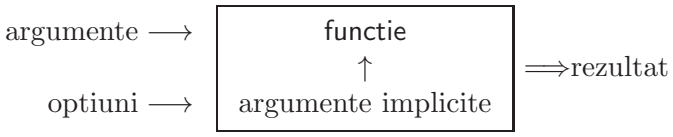

Argumentele pot fi obiecte ("date", formule, expresii, ...), cateva putand fi definite implicit in cadrul functiei; aceste valori implicite pot fi modificate de catre utilizator prin optiuni specifice. O functie R poate sa nu aiba nevoie de argument: fie toate argumentele sunt definite implicit (iar valorile lor pot fi modificate prin optiuni), fie nici un argument nu este definit in functie. Mai tarziu vom vedea mai multe detalii despre utilizarea si construirea functiilor (p. 70). Prezenta descriere este suficienta pentru moment ca sa intelegem cum functioneaza R.

Toate actiunile din R sunt executate asupra obiectelor retinute in memoria activa a computerului: nu sunt utilizate fisiere temporare (Fig. 1). Citirea si scrierea fisierelor sunt utilizate pentru input-ul si output-ul datelor si rezultatelor (grafice, ...). Utilizatorul executa functiile prin intermediul catorva comenzi. Rezultatele sunt afisate direct pe ecran, memorate intr-un obiect, sau scrise pe disc (in special pentru grafice). Din moment ce rezultatele sunt obiecte, pot fi considerate ca date si analizate ca atare. Fisierele de date pot fi citite de pe hard-disk-ul local sau de pe un server la distanta prin Internet.

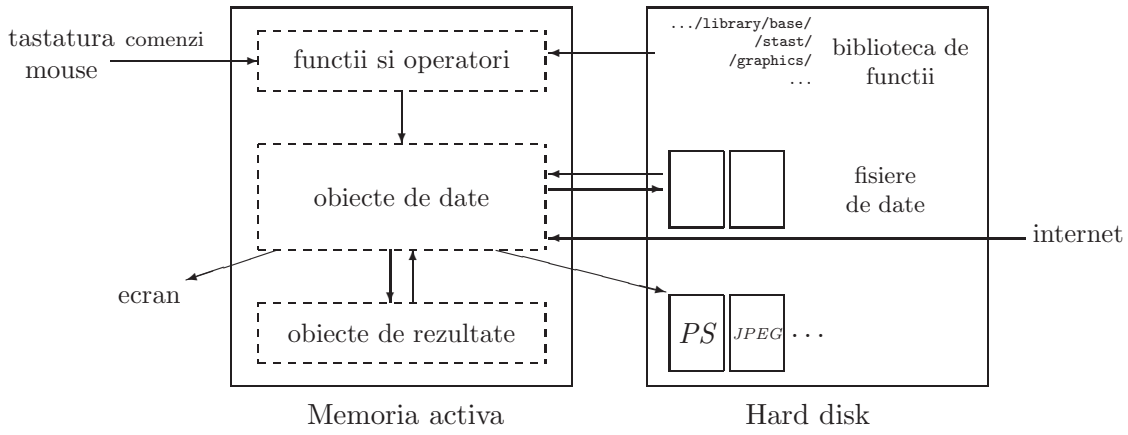

Figure 1: O vedere schematica asupra modului in care functioneaza R

Functiile disponibile utilizatorului sunt stocate in biblioteca localizata pe disc in folderul numit R_HOME/library (R_HOME este folderul unde este instalat R). Acest folder contine *pachete* de functii, care sunt la randul lor structurate in foldere. Pachetul numit base este, oarecum, baza R si contine functiile de baza ale limbajului, in special pentru a citi si a manipula datele. Fiecare pachet are un folder numit R cu un fisier cu denumirea pachetului (de exemplu, pentru pachetul base, acesta este fisierul R_HOME/library/base/R/base).

Acest fisier contine toate functiile pachetului.

Una dintre cele mai simple comenzi este tastarea unui nume de obiect pentru a afisa continutul sau. De exemplu, daca un obiect `n` contine valoarea 10:

```
> n
[1] 10
```

Cifra 1 dintre paranteze indica faptul ca afisajul incepe cu primul element al lui `n`. Aceasta comanda este o utilizare implicita a functiei `print` iar exemplul de mai sus este similar cu `print(n)` (in unele situatii, functia `print` trebuie sa fie utilizata explicit, cum ar fi in cadrul unei functii sau al unui ciclu).

Numele unui obiect poate incepe cu o litera (A–Z and a–z) si poate include litere, cifre (0–9), puncte (.) si underline (_). R face diferenta intre majuscule si minuscule in numele obiectelor, astfel ca `x` si `X` pot fi doua nume de obiecte distincte (chiar si in Windows).

2.2 Crearea, listarea si stergerea obiectelor din memorie

Un obiect poate fi creat prin operatorul "assign" care este scris ca o sageata cu un semn de minus si o paranteza; acest simbol poate fi orientat de la stanga la dreapta sau invers:

```
> n <- 15
> n
[1] 15
> 5 -> n
> n
[1] 5
> x <- 1
> X <- 10
> x
[1] 1
> X
[1] 10
```

Daca obiectul exista deja, valoarea sa precedenta va fi stearsa (modificarea are efect numai asupra obiectelor din memoria activa, nu si asupra datelor de pe disc). Valoarea atribuita in acest mod poate fi rezultatul unei operatii si/sau al unei functii:

```
> n <- 10 + 2
> n
[1] 12
> n <- 3 + rnorm(1)
> n
[1] 2.208807
```

Functia `rnorm(1)` genereaza o valoare aleatoare normala de medie zero si varianta unitara (p. 19). De retinut ca puteti doar sa tastati o expresie fara sa atribuiti valoarea sa unui obiect, rezultatul afisat astfel nefiind retinut in memorie:

```
> (10 + 2) * 5
[1] 60
```

Atribuirea va fi omisa in exemple daca nu este necesara pentru intelegere.

Functia `ls` listeaza obiectele din memorie: doar numele obiectelor sunt afisate.

```
> name <- "Carmen"; n1 <- 10; n2 <- 100; m <- 0.5
> ls()
[1] "m"    "n1"   "n2"   "name"
```

De remarcat ca se pot utiliza semi-coloane pentru separarea comenzilor distincte pe aceeasi linie. Daca dorim sa listam doar obiectele care contin un anumit caracter in numele lor, poate fi utilizata optiunea `pattern` (care poate fi prescurtata cu `pat`):

```
> ls(pat = "m")
[1] "m"    "name"
```

Pentru a restrictiona listarea caracterelor ale caror nume incep cu un anumit caracter:

```
> ls(pat = "^m")
[1] "m"
```

Functia `ls.str` afiseaza unele detalii despre obiectele din memorie:

```
> ls.str()
m :  num 0.5
n1 :  num 10
n2 :  num 100
name :  chr "Carmen"
```

Optiunea `pattern` poate fi utilizata in acelasi mod ca si `ls`. O alta optiune utila a lui `ls.str` este `max.level` care specifica nivelul detalierii pentru afisarea obiectelor compuse. In mod implicit, `ls.str` afiseaza detaliile obiectelor din memorie, inclusiv coloane de secvente de date, matrici si liste, care pot avea ca rezultat un afisaj lung. Putem evita afisarea tuturor acestor detalii prin optiunea `max.level = -1`:

```
> M <- data.frame(n1, n2, m)
> ls.str(pat = "M")
M : ‘data.frame’:       1 obs. of  3 variables:
```

```
 $ n1: num 10
 $ n2: num 100
 $ m : num 0.5
> ls.str(pat="M", max.level=-1)
M : 'data.frame':       1 obs. of  3 variables:
```

Pentru a sterge obiectele din memorie, folosim functia `rm`: `rm(x)` sterge obiectul `x`, `rm(x,y)` sterge ambele obiecte `x` si `y`, `rm(list=ls())` sterge toate obiectele din memorie; aceleasi optiuni mentionate pentru functia `ls()` pot fi utilizate pentru a sterge in mod selectiv cateva obiecte: `rm(list=ls(pat="^m"))`.

2.3 Suportul online

Suportul online al lui R ofera informatii foarte utile cu privire la modul in care se utilizeaza functiile. Suportul este disponibil direct printr-o functie, ca de exemplu:

```
> ?lm
```

va afisa, in cadrul R, pagina de asistenta pentru functia `lm()` (*model liniar*). Comenzile `help(lm)` si `help("lm")` au acelasi efect. Cea din urma trebuie utilizata pentru a accesa suportul cu caractere non-conventionale:

```
> ?*
Error: syntax error
> help("*")
Arithmetic              package:base              R Documentation

Arithmetic Operators
...
```

Prin apelarea suportului se deschide o pagina (aceasta depinde de sistemul de operare) cu informatii generale pe primul rand cum ar fi numele pachetului in cadrul caruia se afla functia sau operatorii respectivi. Apoi urmeaza un titlu urmat de sectiuni care ofera informatii detaliate.

Descriere: o scurta descriere.

Utilizare: in cazul unei functii, precizeaza numele cu toate argumentele sale si optiunile posibile (cu valorile corespunzatoare implicite); pentru un operator precizeaza utilizarea specifica.

Argumente: in cazul unei functii, detaliaza fiecare argument al sau.

Detalii: descriere detaliata.

Valoare: daca este cazul, tipul obiectului returnat de functie sau operator.

Vezi si: alte pagini de suport apropiate sau similare cu cea actuala.

Exemple: cateva exemple care pot fi executate in general fara deschiderea suportului cu functia `example`.

Pentru incepatori, este bine sa se consulte sectiunea **Exemple**. In general, este util sa se citeasca cu atentie sectiunea **Argumente**. Pot fi intalnite si alte sectiuni, cum ar fi **Note**, **Referinte** sau **Autor(i)**.

In mod implicit, functia `help` cauta doar in pachetele care sunt incarcate in memorie. Optiunea `try.all.packages`, care in mod implicit este `FALSE`, permite cautarea in toate pachetele daca valoarea sa este `TRUE`:

```
> help("bs")
No documentation for 'bs' in specified packages and libraries:
you could try 'help.search("bs")'
> help("bs", try.all.packages = TRUE)
Help for topic 'bs' is not in any loaded package but
can be found in the following packages:

  Package               Library
  splines               /usr/lib/R/library
```

De retinut ca in acest caz pagina de suport a functiei `bs` nu este afisata. Utilizatorul poate afisa paginile de suport pentru un pachet neincarcat in memorie utilizand optiunea `package`:

```
> help("bs", package = "splines")
bs                 package:splines                 R Documentation

B-Spline Basis for Polynomial Splines

Description:

     Generate the B-spline basis matrix for a polynomial spline.
...
```

Pagina de suport in format html (citita, de exemplu, cu Netscape) este afisata prin:

```
> help.start()
```

O cautare prin cuvinte-cheie este posibila cu acest suport html. Sectiunea **Vezi si** contine linkuri hypertext catre alte pagini suport pentru functii. Cautarea prin cuvinte-cheie este de asemenea posibila in R prin functia `help.search`. Cea din urma apare pentru un anumit topic, ca un sir de caractere, in paginile de suport ale tuturor pachetelor instalate. De exemplu, `help.search("tree")` va afisa o lista de functii pe care paginile de suport le numesc "tree". De retinut ca, in cazul in care cateva pachete au fost recent instalate, poate fi utila reimprospatarea bazei de date utilizate

de `help.search` folosind optiunea `rebuild` (de ex., `help.search("tree", rebuild = TRUE)`).

Functia `apropos` gaseste toate functiile ale caror nume contin sirul de caractere dat ca argument; se cauta doar in pachetele incarcate in memorie :

```
> apropos(help)
[1] "help"         ".helpForCall" "help.search"
[4] "help.start"
```

3 Date in R

3.1 Obiecte

Am vazut ca R lucreaza cu obiecte care sunt, desigur, caracterizate de numele lor si de continut, dar si de *atribute* care specifica tipul datelor reprezentate in obiect. Pentru a intelege utilitatea acestor atribute, considerati o variabila care poate lua valorile 1, 2, sau 3: o asemenea variabila poate fi de tip integer (de exemplu, numarul oualelor dintr-un cuib) sau codificarea unei variabile categoriale (de exemplu, sexul unor populatii de crustacei: masculin, feminin, sau hermafrodit).

Este clar ca analiza statistica a acestei variabile nu va fi aceeasi in ambele cazuri: in R, atributele unui obiect dau informatia necesara. In termeni mai tehnici si mai generali, actiunea unei functii asupra unui obiect depinde de atributele acestuia din urma.

Toate obiectele au doua atribute *intrinseci*: *categoria* si *lungimea*. Categoria reprezinta tipul de baza al elementelor obiectului; exista patru categorii principale: numeric, caracter, complex[7], si logic (`FALSE` or `TRUE`). Exista si alte categorii insa acestea nu reprezinta date, ca de exemplu functia sau expresia. Lungimea este numarul de elemente ale obiectului. Pentru a afisa categoria si lungimea unui obiect, se pot utiliza functiile `mode` si, respectiv, `length`:

```
> x <- 1
> mode(x)
[1] "numeric"
> length(x)
[1] 1
> A <- "Gomphotherium"; compar <- TRUE; z <- 1i
> mode(A); mode(compar); mode(z)
[1] "character"
[1] "logical"
[1] "complex"
```

Indiferent de categorie, datele lipsa sunt reprezentate de `NA` (*not available*). O valoare numerica foarte mare poate fi specificata cu ajutorul unei notatii exponentiale:

```
> N <- 2.1e23
> N
[1] 2.1e+23
```

R reprezinta in mod corect valori numerice infinite, cum ar fi $\pm\infty$ cu `Inf` si `-Inf`, sau valori nenumerice cu `NaN` (*not a number*).

[7] Categoria complex nu va fi tratata in aceasta documentatie.

```
> x <- 5/0
> x
[1] Inf
> exp(x)
[1] Inf
> exp(-x)
[1] 0
> x - x
[1] NaN
```

O valoare a categoriei de tip caracter este introdusa cu ghilimele duble ". Este posibil sa includa ultimul caracter in valoare daca acesta urmeaza un backslash \. Cele doua caractere \" vor fi tratate impreuna in mod specific de cateva functii, cum ar fi `cat` pentru afisarea pe ecran, sau `write.table` pentru scrierea pe hard-disk (p. 16, optiunea `qmethod` a acestei functii).

```
> x <- "Double quotes \" delimitate R's strings."
> x
[1] "Double quotes \" delimitate R's strings."
> cat(x)
Double quotes " delimitate R's strings.
```

Ca o alternativa, variabilele de tip caracter pot fi delimitate cu ghilimele simple (’); in acest caz nu este necesar sa inlocuim ghilimelele duble cu backslash-uri (insa trebuie sa existe ghilimele simple!):

```
> x <- 'Double quotes " delimitate R\'s strings.'
> x
[1] "Double quotes \" delimitate R's strings."
```

Tabelul urmator prezinta un rezumat al tipurilor de obiecte ce reprezinta date.

obiect	**tipuri**	**mai multe tipuri posibile in acelasi obiect**
vector	numeric, caracter, complex *sau* logic	Nu
factor	numeric *sau* caracter	Nu
sir	numeric, caracter, complex *sau* logic	Nu
matrice	numeric, caracter, complex *sau* logic	Nu
secventa de date	numeric, caracter, complex *sau* logic	Da
ts	numeric, caracter, complex *sau* logic	Nu
lista	numeric, caracter, complex, logic, functie, expresie, ...	Da

Un vector este o variabila in sensul general valabil. Un factor este o variabila categoriala. Un sir este un tabel cu k dimensiuni, o matrice fiind un caz particular de sir cu $k = 2$. De retinut ca elementele unui sir sau ale unei matrici sunt toate de acelasi tip. O secventa de date este un tabel compus din unul sau cativa vectori si/sau factori de aceeasi lungime dar posibil de tipuri diferite. Un 'ts' este un set de date de serii de timp ce contine atribute aditionale cum ar fi frecventa si datele. Nu in ultimul rand, o lista poate contine orice tip de obiect, inclusiv liste!

In cazul unui vector, tipul sau/si lungimea sunt suficiente pentru a descrie datele. In cazul altor obiecte, sunt necesare alte informatii care sunt date de atribute *non-intrinseci*. Dintre aceste atribute, putem mentiona *dim*, ce corespunde dimensiunilor unui obiect. De exemplu, o matrice cu 2 linii si 2 coloane are pentru `dim` perechea de valori [2, 2], insa lungimea sa este 4.

3.2 Citirea datelor dintr-un fisier

Pentru scrierea si citirea in fisiere, R utilizeaza folderul de lucru. Pentru a gasi acest folder, comanda `getwd()` (*obtine folderul de lucru*) poate fi utilizata, iar folderul de lucru poate fi schimbat cu `setwd("C:/data")` sau `setwd("/home/paradis/R")`. Este necesar sa atribuim calea unui fisier daca acesta nu se afla in folderul de lucru.[8]

R poate citi date stocate in fisiere text (ASCII) cu urmatoarele functii: `read.table` (care are cateva variante, vezi mai jos), `scan` si `read.fwf`. R poate de asemenea sa citeasca fisiere in alte formate (Excel, SAS, SPSS, ...) si sa acceseze baze de date de tip SQL, insa functiile necesare nu se afla in pachetul `base`. Aceste functionalitati sunt foarte eficiente pentru o utilizare mai avansata a R, insa ne vom opri aici la citirea fisierelor in format ASCII.

Functia `read.table` are ca efect crearea unei secvente de date, iar aceasta este modalitatea principala de citire a datelor in forma tabelara. De exemplu, pentru un fisier numit data.dat, comanda:

```
> mydata <- read.table("data.dat")
```

va crea o secventa de date numita `mydata`, iar fiecare variabila va fi numita, implicit, `V1`, `V2`, ... si poate fi accesata individual prin `mydata$V1`, `mydata$V2`, ..., sau prin `mydata["V1"]`, `mydata["V2"]`, ..., sau, inca o alta varianta, prin `mydata[, 1]`, `mydata[,2 ]`, ...[9] Exista cateva optiuni ale caror valori implicite (de ex. cele utilizate de R daca sunt omise de utilizator) sunt detaliate in tabelul urmator:

[8] In Windows, este utila crearea unui shortcut al Rgui.exe apoi editarea proprietatilor si schimbarea folderului in campul "Start in:" sub tab-ul "Short-cut": acest folder va deveni folderul de lucru daca R este pornit din acest shortcut.

[9] Exista o diferenta: `mydata$V1` si `mydata[, 1]` sunt vectori in timp ce `mydata["V1"]` este o secventa de date. Vom vedea mai tarziu (p. 20) cateva detalii privind manipularea obiectelor.

```
read.table(file, header = FALSE, sep = "", quote = "\"'", dec = ".",
           row.names, col.names, as.is = FALSE, na.strings = "NA",
           colClasses = NA, nrows = -1,
           skip = 0, check.names = TRUE, fill = !blank.lines.skip,
           strip.white = FALSE, blank.lines.skip = TRUE,
           comment.char = "#")
```

`fisier`	numele fisierului (intre "" sau o variabila de tip caracter), posibil cu calea sa (simbolul \ nu este permis si trebuie inlocuit cu /, chiar si in Windows), sau acces la distanta catre un fisier de tip URL (http://...)
`header`	o variabila de tip logic (`FALSE` sau `TRUE`) ce indica daca fisierul contine numele variabilelor pe prima linie
`sep`	campul separator folosit in fisier, de exemplu `sep="\t"` daca este o tabulare
`quote`	caracterele folosite pentru a cita variabilele de tip caracter
`dec`	caracterul utilizat pentru zecimale
`row.names`	un vector cu numele liniilor care poate fi un vector de tip caracter, sau numar (sau nume) a unei variabile din fisier (implicit: `1`, `2`, `3`, ...)
`col.names`	un vector cu numele variabilelor (implicit: `V1`, `V2`, `V3`, ...)
`as.is`	controleaza conversia variabilelor de tip caracter in factori (daca este `FALSE`) le pastreaza caractere (`TRUE`); `as.is` poate fi vector de tip logic, numeric sau caracter cu mentionarea variabilelor ce trebuie pastrate ca si caractere
`na.strings`	valoarea atribuita datelor lipsa (convertita in `NA`)
`colClasses`	un vector de tip caracter ce returneaza clasele ce trebuie atribuite coloanelor
`nrows`	numarul maxim de linii de citit (valorile negative sunt ignorate)
`skip`	numarul de linii de omis inainte de citirea datelor
`check.names`	pentru `TRUE`, verifica daca numele variabilei este valid pentru R
`fill`	daca `TRUE` si toate liniile nu au acelasi numar de variabile, sunt adaugate "blank-uri"
`strip.white`	(conditional to `sep`) pentru `TRUE`, sterge spatiile in plus dinaintea si dupa variabilele de tip caracter
`blank.lines.skip`	pentru `TRUE`, ignora liniile "blank"
`comment.char`	caracter ce defineste comentariile din fisierul de date, restul liniei de dupa acest caracter este ignorat (pentru a dezactiva acest argument, utilizati `comment.char = ""`)

Variantele `read.table` sunt eficiente din moment ce au diferite valori implicite:

```
read.csv(file, header = TRUE, sep = ",", quote="\"", dec=".",
         fill = TRUE, ...)
read.csv2(file, header = TRUE, sep = ";", quote="\"", dec=",",
          fill = TRUE, ...)
read.delim(file, header = TRUE, sep = "\t", quote="\"", dec=".",
           fill = TRUE, ...)
```

```
read.delim2(file, header = TRUE, sep = "\t", quote="\"", dec=",",
            fill = TRUE, ...)
```

Functia `scan` este mai flexibila decat `read.table`. O diferenta consta in posibilitatea specificarii tipului variabilelor, ca de exemplu:

```
> mydata <- scan("data.dat", what = list("", 0, 0))
```

citeste in fisierul data.dat trei variabile, prima este de tip caracter iar urmatoarele doua sunt de tip numeric. O alta diferenta importanta este aceea ca `scan()` poate fi utilizat pentru crearea diferitelor obiecte, vectori, matrici, secvente de date, liste, ... In exemplul de mai sus, `mydata` este o lista de trei vectori. In mod implicit, daca `what` este omis, `scan()` creaza un vector numeric. Daca datele citite nu corespund tipului asteptat (nici cel implicit, nici cel specificat de `what`), este afisat un mesaj de eroare. Optiunile sunt urmatoarele:

```
scan(file = "", what = double(0), nmax = -1, n = -1, sep = "",
     quote = if (sep=="\n") "" else "'\"", dec = ".",
     skip = 0, nlines = 0, na.strings = "NA",
     flush = FALSE, fill = FALSE, strip.white = FALSE, quiet = FALSE,
     blank.lines.skip = TRUE, multi.line = TRUE, comment.char = "",
     allowEscapes = TRUE)
```

`file`	numele fisierului (intre ""), posibil si calea sa (the symbol \ nu este permis si trebuie sa fie inlocuit de /, chiar si in Windows), sau cu acces la distanta la un fisier de tip URL (http://...); daca `file=""`, datele sunt introduse prin tastatura (accesul este incheiat de o linie blank)
`what`	specifica tipul datelor (implicit numeric)
`nmax`	numarul datelor de citit, sau, daca `what` este de tip lista, numarul liniilor de citit (implicit, `scan` citeste datele pana la sfarsitul fisierului)
`n`	numarul datelor de citit (implicit, fara limita)
`sep`	campul separator utilizat in fisier
`quote`	caracterele utilizate pentru citarea variabilelor de tip caracter
`dec`	caracterul utilizat pentru zecimale
`skip`	numarul de linii omise inainte de citirea datelor
`nlines`	numarul de linii de citit
`na.string`	valoarea atribuita datelor lipsa (convertita ca `NA`)
`flush`	o valoare logica, pentru `TRUE`, `scan` sare la linia urmatoare odata ce numarul de coloane a fost atins (permite utilizatorului sa adauge comentarii in fisierul de date)
`fill`	daca `TRUE` si toate liniile nu au acelasi numar de variabile, sunt adaugate "blank-uri"
`strip.white`	(conditional to `sep`) pentru `TRUE`, sterge spaiile in plus dinainte si dupa variabilele de tip caracter
`quiet`	o valoare logica, pentru `FALSE`, `scan` afiseaza o linie ce arata campurile care au fost citite
`blank.lines.skip`	pentru `TRUE`, ignora liniile blank
`multi.line`	daca `what` este de tip lista, specifica daca variabilele aceleiasi inregistrari sunt afisate pe o singura linie in fisier (`FALSE`)
`comment.char`	un caracter ce defineste comentariile in fisierul de date, restul liniei ce urmeaza dupa acest caracter este ignorat (in mod implicit este dezactivat)
`allowEscapes`	precizeaza care dintre C-style nu este (e.g., '\t') procesat (cel implicit) sau citit ca si verbatim

Functia `read.fwf` poate fi utilizata pentru citirea unor date intr-un fisier in *format de dimensiune fixa*:

```
read.fwf(file, widths, header = FALSE, sep = "\t",
         as.is = FALSE, skip = 0, row.names, col.names,
         n = -1, buffersize = 2000, ...)
```

Optiunile sunt aceleasi ca pentru `read.table()`, cu exceptia `widths` care specifica dimensiunea campurilor (`buffersize` este numarul maxim de linii citite simultan). De exemplu, daca un fisier numit data.txt contine datele indicate in partea dreapta, datele pot fi citite cu urmatoarea comanda:

```
A1.501.2
A1.551.3
B1.601.4
B1.651.5
C1.701.6
C1.751.7
```

```
> mydata <- read.fwf("data.txt", widths=c(1, 4, 3))
> mydata
  V1   V2  V3
1  A 1.50 1.2
```

```
2  A 1.55 1.3
3  B 1.60 1.4
4  B 1.65 1.5
5  C 1.70 1.6
6  C 1.75 1.7
```

3.3 Salvarea datelor

Functia `write.table` scrie intr-un fisier un obiect, in mod caracteristic o secventa de date dar si alte tipuri de obiecte (vector, matrice, ...). Argumentele si optiunile sunt urmatoarele:

```
write.table(x, file = "", append = FALSE, quote = TRUE, sep = " ",
            eol = "\n", na = "NA", dec = ".", row.names = TRUE,
            col.names = TRUE, qmethod = c("escape", "double"))
```

`x`	numele obiectului ce urmeaza a fi scris
`file`	numele fisierului (in mod implicit obiectul este afisat pe ecran)
`append`	pentru `TRUE` adauga datele fara sa le stearga pe acelea posibil existente in fisier
`quote`	un vector de tip numeric sau logic: pentru `TRUE` variabilele de tip caracter si cele de tip factor sunt scrise intre `""`, altfel vectorul numeric indica numarul de variabile de scris intre `""` (in ambele cazuri numele variabilelor sunt scrise intre `""` dar nu si pentru `quote = FALSE`)
`sep`	separatorul de campuri utilizat in fisier
`eol`	caracterul utilizat la sfarsitul fiecarei linii (`"\n"`)
`na`	caracterul utilizat pentru date lipsa
`dec`	caracterul utilizat pentru zecimale
`row.names`	o valoare logica ce indica daca numele liniilor sunt scrise in fisier
`col.names`	numele coloanelor
`qmethod`	specifica, pentru `quote=TRUE`, modul in care ghilimelele `"` incluse in variabilele de tip caracter sunt tratate: pentru `"escape"` (sau `"e"`, implicit) fiecare `"` este inlocuit de `\"`, pentru `"d"` fiecare `"` este inlocuit de `""`

Pentru a scrie mai simplu un obiect intr-un fisier, poate fi utilizata comanda `write(x, file="data.txt")`, unde `x` este numele obiectului (care poate fi vector, matrice, sau un sir). Exista doua optiuni: `nc` (sau `ncol`) care defineste numarul de coloane din fisier (in mod implicit `nc=1` daca `x` este de tip caracter, `nc=5` pentru alte tipuri) si `append` (de tip logic) pentru a adauga datele fara stergerea celor posibil existente in fisier (`TRUE`) sau stergerea lor daca fisierul exista deja (`FALSE`, in mod implicit).

Pentru a inregistra un grup de obiecte de orice tip, putem utiliza comanda `save(x, y, z, file= "xyz.RData")`. Pentru a usura transferul de date dintre diferite aparate, poate fi utilizata optiunea `ascii = TRUE`. Datele (care sunt numite in aceasta faza *workspace* in jargon R) pot fi incarcate mai tarziu in memorie cu `load("xyz.RData")`. Functia `save.image()` este un shortcut pentru `save(list =ls(all=TRUE), file=".RData")`.

3.4 Generarea datelor

3.4.1 Secvente regulate

O secventa regulata de obiecte integer, de exemplu de la 1 la 30, poate fi generata astfel:

```
> x <- 1:30
```

Vectorul rezultat `x` are 30 de elemente. Operatorul ‘`:`’ are prioritate printre operatorii aritmetici in cadrul unei expresii:

```
> 1:10-1
 [1] 0 1 2 3 4 5 6 7 8 9
> 1:(10-1)
[1] 1 2 3 4 5 6 7 8 9
```

Functia `seq` poate genera secvente de numere reale dupa cum urmeaza:

```
> seq(1, 5, 0.5)
[1] 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0
```

unde primul numar indica inceputul secventei, al doilea sfarsitul, iar al treilea cresterea utilizata pentru generarea secventei. Se mai poate utiliza si:

```
> seq(length=9, from=1, to=5)
[1] 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0
```

Se pot atribui direct valorile utilizand functia `c`:

```
> c(1, 1.5, 2, 2.5, 3, 3.5, 4, 4.5, 5)
[1] 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0
```

De asemenea este posibil, daca se doreste introducerea unor date prin tastatura, sa se utilizeze functia `scan` cu optiunile implicite precum urmeaza:

```
> z <- scan()
1: 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0
10:
Read 9 items
> z
[1] 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0
```

Functia `rep` creaza un vector cu toate elementele identice:

```
> rep(1, 30)
 [1] 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
```

Functia `sequence` creaza o serie de secvente de obiecte integer terminata fiecare cu numerele date ca argumente:

```
> sequence(4:5)
[1] 1 2 3 4 1 2 3 4 5
> sequence(c(10,5))
 [1]  1  2  3  4  5  6  7  8  9 10  1  2  3  4  5
```

Functia `gl` (*eng. generates levels*) este foarte folositoare intrucat genereaza serii regulate de factori. Utilizarea acestei functii este redata `gl(k, n)`, unde `k` este numarul de niveluri (sau clase) si `n` este numarul de raspunsuri in fiecare nivel. Pot fi utilizate doua optiuni: `length` pentru a specifica numarul de date generate si `labels` pentru a specifica numele nivelurilor factorului. Exemple:

```
> gl(3, 5)
 [1] 1 1 1 1 1 2 2 2 2 2 3 3 3 3 3
Levels:  1 2 3
> gl(3, 5, length=30)
 [1] 1 1 1 1 1 2 2 2 2 2 3 3 3 3 3 1 1 1 1 1 2 2 2 2 2 3 3 3 3 3
Levels:  1 2 3
> gl(2, 6, label=c("Male", "Female"))
 [1] Male   Male   Male   Male   Male   Male
 [7] Female Female Female Female Female Female
Levels:  Male Female
> gl(2, 10)
 [1] 1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 2 2
Levels:  1 2
> gl(2, 1, length=20)
 [1] 1 2 1 2 1 2 1 2 1 2 1 2 1 2 1 2 1 2 1 2
Levels:  1 2
> gl(2, 2, length=20)
 [1] 1 1 2 2 1 1 2 2 1 1 2 2 1 1 2 2 1 1 2 2
Levels:  1 2
```

`expand.grid()` creaza o secventa de date cu toate combinatiile de vectori sau factori dati ca argumente:

```
> expand.grid(h=c(60,80), w=c(100, 300), sex=c("Male", "Female"))
   h   w    sex
1 60 100   Male
2 80 100   Male
3 60 300   Male
4 80 300   Male
5 60 100 Female
6 80 100 Female
7 60 300 Female
8 80 300 Female
```

3.4.2 Secvente aleatoare

teorema	**functia**
Gaussian (normal)	`rnorm(n, mean=0, sd=1)`
exponential	`rexp(n, rate=1)`
gamma	`rgamma(n, shape, scale=1)`
Poisson	`rpois(n, lambda)`
Weibull	`rweibull(n, shape, scale=1)`
Cauchy	`rcauchy(n, location=0, scale=1)`
beta	`rbeta(n, shape1, shape2)`
'Student' (t)	`rt(n, df)`
Fisher–Snedecor (F)	`rf(n, df1, df2)`
Pearson (χ^2)	`rchisq(n, df)`
binomial	`rbinom(n, size, prob)`
multinomial	`rmultinom(n, size, prob)`
geometric	`rgeom(n, prob)`
hipergeometric	`rhyper(nn, m, n, k)`
logistic	`rlogis(n, location=0, scale=1)`
lognormal	`rlnorm(n, meanlog=0, sdlog=1)`
negativ binomial	`rnbinom(n, size, prob)`
uniform	`runif(n, min=0, max=1)`
statistica Wilcoxon	`rwilcox(nn, m, n)`, `rsignrank(nn, n)`

In statistica este necesar sa se poata genera date aleatoare, iar R poate face asta pentru o gama larga de functii de densitate de probabilitate. Aceste functii sunt de forma `rfunc(n, p1, p2, ...)`, unde *`func`* indica probabilitatea distributiei, `n` numarul de date generate, iar `p1`, `p2`, ... sunt valorile parametrilor distributiei. Tabelul de mai sus ofera detalii pentru fiecare tip de distributie si valorile posibile implicite (daca nicio valoare implicita nu este indicata, inseamna ca parametrul trebuie precizat de catre utilizator).

Majoritatea acestor functii au echivalente obtinute prin inlocuirea literei `r` cu `d`, `p` sau `q` pentru a obtine, densitatea de probabilitate (`dfunc(x, ...)`), distributia cumulativa de probabilitate (`pfunc(x, ...)`), respectiv valoarea quantilei (`qfunc(p, ...)`, cu $0 <$ `p` < 1). Ultimele seturi de functii pot fi utilizate pentru a gasi valorile critice sau P-values ale testelor statistice. Spre exemplu, valorile critice pentru testul t bilateral urmand o distributie normala de 5% au limitele:

```
> qnorm(0.025)
[1] -1.959964
> qnorm(0.975)
[1] 1.959964
```

Pentru testul t unilateral, `qnorm(0.05)` si `1 - qnorm(0.95)` vor fi utilizate in functie de forma ipotezei alternative.

Valoarea P-value a unui test, cu $\chi^2 = 3.84$ si $df = 1$, este:

```
> 1 - pchisq(3.84, 1)
[1] 0.05004352
```

3.5 Manipularea obiectelor

3.5.1 Crearea obiectelor

Anterior am prezentat diferite metode de creare a obiectelor utilizand operatorul de atribuire; tipul si categoria obiectelor create astfel sunt in general implicit determinate. Este posibila crearea unui obiect si specificarea modului sau, a lungimii, categoriei, etc. Aceasta maniera este interesanta din perspectiva manipularii obiectelor. Este posibila, spre exemplu, crearea unui obiect 'gol' si modificarea elementelor sale in mod succesiv, ceea ce este mai eficient decat combinarea elementelor sale cu `c()`. Sistemul de indexare poate fi folosit aici, asa cum vom vedea mai tarziu (p. 28).

Poate fi de asemenea foarte convenabila crearea unor obiecte din altele deja existente. De exemplu, daca se doreste adecvarea unei serii de modele, se pune formula intr-o lista, iar apoi se extrag succesiv elementele pentru a le insera in functia `lm`.

In aceasta etapa a studierii R-ului, interesul pentru invatarea urmatoarelor functionalitati este atat practic cat si didactic. Constructia explicita a obiectelor ofera o intelegere mai buna a structurii lor si ne permite sa avansam catre niste notiuni anterior mentionate.

Vector. Functia `vector`, care are doua argumente `mode` si `length`, creaza un vector ale carui elemente au o valoare dependenta de tipul specificat ca argument: 0 pentru numeric, `FALSE` pentru logic, sau `""` pentru caracter. Functiile urmatoare au exact acelasi efect si au pentru un singur argument lungimea vectorului: `numeric()`, `logical()`, si `character()`.

Factor. Un factor include nu doar valorile corespunzatoare variabilei categoriale, ci si diferitele niveluri posibile ale acelei variabile (chiar daca nu exista in date). Functia `factor` creaza un factor cu urmatoarele optiuni:

```
factor(x, levels = sort(unique(x), na.last = TRUE),
       labels = levels, exclude = NA, ordered = is.ordered(x))
```

`levels` specifica posibilele niveluri ale factorului (in mod implicit valorile unice ale vectorului `x`), `labels` defineste numele nivelurilor, `exclude` valorile lui `x` pentru excluderea din niveluri si `ordered` este un argument logic ce specifica daca nivelurile factorului sunt ordonate. Rechemarea lui `x` este de tip numeric sau caracter. Urmeaza cateva exemple.

```
> factor(1:3)
[1] 1 2 3
Levels:  1 2 3
```

```
> factor(1:3, levels=1:5)
[1] 1 2 3
Levels:  1 2 3 4 5
> factor(1:3, labels=c("A", "B", "C"))
[1] A B C
Levels:  A B C
> factor(1:5, exclude=4)
[1] 1  2  3  NA 5
Levels:  1 2 3 5
```

Functia `levels` extrage posibilele niveluri ale unui factor:

```
> ff <- factor(c(2, 4), levels=2:5)
> ff
[1] 2 4
Levels:  2 3 4 5
> levels(ff)
[1] "2" "3" "4" "5"
```

Matrice. O matrice este de fapt un vector cu un atribut aditional (dim) care la randul lui este un vector numeric de lungime 2 si defineste numarul de linii si coloane ale matricii. O matrice poate fi creata cu functia `matrix`:

```
matrix(data = NA, nrow = 1, ncol = 1, byrow = FALSE,
       dimnames = NULL)
```

Optiunea `byrow` indica daca valorile date de `data` trebuie sa completeze succesiv coloanele (varianta implicita) sau liniile (pentru `TRUE`). Optiunea `dimnames` permite atribuirea de nume liniilor si coloanelor.

```
> matrix(data=5, nr=2, nc=2)
     [,1] [,2]
[1,]    5    5
[2,]    5    5
> matrix(1:6, 2, 3)
     [,1] [,2] [,3]
[1,]    1    3    5
[2,]    2    4    6
> matrix(1:6, 2, 3, byrow=TRUE)
     [,1] [,2] [,3]
[1,]    1    2    3
[2,]    4    5    6
```

O alta modalitate de creare a unei matrici este atribuirea de valori corespunzatoare atributului dim (care este initial `NULL`):

```
> x <- 1:15
> x
 [1]  1  2  3  4  5  6  7  8  9 10 11 12 13 14 15
> dim(x)
NULL
> dim(x) <- c(5, 3)
> x
     [,1] [,2] [,3]
[1,]    1    6   11
[2,]    2    7   12
[3,]    3    8   13
[4,]    4    9   14
[5,]    5   10   15
```

Secventa de date. Am vazut pana acum ca o secventa de date este creata implicit de functia `read.table`; de asemenea este posibila crearea unei secvente de date cu functia `data.frame`. Vectorii astfel inclusi in secventa de date trebuie sa fie de aceeasi lungime, sau daca unul dintre ei este mai scurt, este "reciclat" de un anumit numar de ori:

```
> x <- 1:4; n <- 10; M <- c(10, 35); y <- 2:4
> data.frame(x, n)
  x  n
1 1 10
2 2 10
3 3 10
4 4 10
> data.frame(x, M)
  x  M
1 1 10
2 2 35
3 3 10
4 4 35
> data.frame(x, y)
Error in data.frame(x, y) :
    arguments imply differing number of rows: 4, 3
```

Daca un factor este inclus in secventa de date, trebuie sa fie de aceeasi lungime cu vectorul(vectorii). Este posibila schimbarea numelor coloanelor cu, spre exemplu, `data.frame(A1=x, A2=n)`. De asemenea se pot atribui nume liniilor cu optiunea `row.names` care trebuie sa fie, bineinteles, un vector de tip caracter si cu lungimea egala cu numarul de linii ale secventei de date. De retinut ca secventele de date au un atribut dim similar cu matricile.

List. O lista este creata intr-un mod similar cu secventele de date prin functia `list`. Nu exista nicio limitare asupra obiectelor care sa poata fi inclusa.

Spre deosebire de `data.frame()`, numele obiectelor nu sunt luate implicit; atribuirea vectorilor `x` si `y` se ilustreaza in exemplul urmator:

```
> L1 <- list(x, y); L2 <- list(A=x, B=y)
> L1
[[1]]
[1] 1 2 3 4

[[2]]
[1] 2 3 4

> L2
$A
[1] 1 2 3 4

$B
[1] 2 3 4

> names(L1)
NULL
> names(L2)
[1] "A" "B"
```

Serii de timp. Functia `ts` creaza un obiect de clasa `"ts"` dintr-un vector (serii de timp singulare) sau dintr-o matrice (serii de timp multivariate) si cateva optiuni care caracterizeaza seriile. Optiunile, cu valorile implicite, sunt urmatoarele:

```
ts(data = NA, start = 1, end = numeric(0), frequency = 1,
   deltat = 1, ts.eps = getOption("ts.eps"), class, names)
```

`data`	un vector sau o matrice
`start`	timpul primei observatii, fie ca este un numar sau un vector de doua numere intregi (vezi exemplul de mai sus)
`end`	timpul ultimei observatii specificat in acelasi mod ca si `start`
`frequency`	numarul de observatii pe unitate de timp
`deltat`	fractiunea perioadei de esantionare dintre observatii succesive (ex. `1/12` pentru date lunare); doar o `frequency` sau `deltat` trebuie atribuite
`ts.eps`	toleranta pentru comparatia seriilor. Frecventele sunt considerate egale daca diferentele lor sunt mai mici decat `ts.eps`
`class`	clasa atribuita obiectului; cea implicita este `"ts"` pentru o serie singulara si `c("mts", "ts")` pentru serii multivariate
`names`	un vector de tip caracter cu numele seriilor individuale in cazul seriilor multivariate; in mod implicit numele coloanelor `data` sau `Series 1`, `Series 2`, ...

Cateva exemple de serii de timp create cu `ts`:

```
> ts(1:10, start = 1959)
Time Series:
Start = 1959
End = 1968
Frequency = 1
 [1]  1  2  3  4  5  6  7  8  9 10
> ts(1:47, frequency = 12, start = c(1959, 2))
     Jan Feb Mar Apr May Jun Jul Aug Sep Oct Nov Dec
1959       1   2   3   4   5   6   7   8   9  10  11
1960  12  13  14  15  16  17  18  19  20  21  22  23
1961  24  25  26  27  28  29  30  31  32  33  34  35
1962  36  37  38  39  40  41  42  43  44  45  46  47
> ts(1:10, frequency = 4, start = c(1959, 2))
     Qtr1 Qtr2 Qtr3 Qtr4
1959         1    2    3
1960    4    5    6    7
1961    8    9   10
> ts(matrix(rpois(36, 5), 12, 3), start=c(1961, 1), frequency=12)
         Series 1 Series 2 Series 3
Jan 1961        8        5        4
Feb 1961        6        6        9
Mar 1961        2        3        3
Apr 1961        8        5        4
May 1961        4        9        3
Jun 1961        4        6       13
```

```
Jul 1961        4        2        6
Aug 1961       11        6        4
Sep 1961        6        5        7
Oct 1961        6        5        7
Nov 1961        5        5        7
Dec 1961        8        5        2
```

Expresia. Obiectele de tip expresie au un rol fundamental in R. O expresie este o serie de caractere care au sens pentru R. Toate comenzile valide sunt expresii. Atunci cand o comanda este introdusa direct prin tastatura, este*evaluata* de catre R si executata daca este valida. In multe cazuri, este necesara construirea unei expresii fara evaluarea ei: aceasta este ceea ce executa functia `expression`. Este, de asemenea, posibila evaluarea ulterioara a expresiei cu `eval()`.

```
> x <- 3; y <- 2.5; z <- 1
> exp1 <- expression(x / (y + exp(z)))
> exp1
expression(x/(y + exp(z)))
> eval(exp1)
[1] 0.5749019
```

Expresiile pot fi utilizate, odata cu alte obiecte, la includerea ecuatiilor in grafice (p. 44). O expresie poate fi creata dintr-o variabila de tip caracter. Cateva functii recunosc expresiile ca argumente, de exemplu `D` care returneaza derivate partiale:

```
> D(exp1, "x")
1/(y + exp(z))
> D(exp1, "y")
-x/(y + exp(z))^2
> D(exp1, "z")
-x * exp(z)/(y + exp(z))^2
```

3.5.2 Convertirea obiectelor

Cititorul a realizat cu siguranta ca diferentele dintre cateva tipuri de obiecte sunt mici; prin urmare este logic ca este posibila convertirea unui obiect dintr-un tip in altul prin schimbarea unor atribute ale sale. O asemenea conversie va fi efectuata cu o functie de tipul `as.`*`something`*. R (versiunea 2.1.0) are, in pachetele base si utils, 98 astfel de functii, astfel ca nu vom aprofunda aceste detalii aici.

Rezultatul unei conversii depinde, evident, de atributele obiectului convertit. In general, conversia urmeaza reguli intuitive. Pentru conversia tipurilor, tabelul urmator ofera o privire de ansamblu.

Conversie in	Functia	Reguli
numeric	`as.numeric`	`FALSE` → 0
		`TRUE` → 1
		`"1"`, `"2"`, ... → 1, 2, ...
		`"A"`, ... → `NA`
logic	`as.logical`	0 → `FALSE`
		other numbers → `TRUE`
		`"FALSE"`, `"F"` → `FALSE`
		`"TRUE"`, `"T"` → `TRUE`
		other characters → `NA`
caracter	`as.character`	1, 2, ... → `"1"`, `"2"`, ...
		`FALSE` → `"FALSE"`
		`TRUE` → `"TRUE"`

Exista functii speciale pentru convertirea tipurilor obiectelor (`as.matrix`, `as.ts`, `as.data.frame`, `as.expression`, ...). Aceste functii vor modifica alte atribute in afara de tip in timpul conversiei. Rezultatele sunt, din nou, intuitive in general. O situatie frecvent intalnita este conversia factorilor in valori numerice. In acest caz, R face conversia cu o codare numerica a nivelurilor factorului:

```
> fac <- factor(c(1, 10))
> fac
[1] 1 10
Levels:  1 10
> as.numeric(fac)
[1] 1 2
```

Aceasta are inteles atunci cand se considera un factor de tip caracter:

```
> fac2 <- factor(c("Male", "Female"))
> fac2
[1] Male   Female
Levels: Female Male
> as.numeric(fac2)
[1] 2 1
```

De retinut ca rezultatul nu este `NA`, asa cum ar fi fost de asteptat conform tabelului de mai sus.

Pentru a converti factorul de tip numeric intr-un vector numeric cu pastrarea nivelurilor asa cum erau specificate, trebuie convertit intai in caracter, apoi in numeric.

```
> as.numeric(as.character(fac))
[1] 1 10
```

Aceasta procedura este foarte utila daca intr-un fisier o variabila numerica are si valori nenumerice. Am vazut ca `read.table()` intr-o asemenea situatie data, va citi, implicit, aceasta coloana ca si factor.

3.5.3 Operatori

Anterior am observat ca exista trei tipuri principale de operatori in R[10]

Operatori					
Aritmetici		De comparatie		Logici	
`+`	adunare	`<`	mai mic	`! x`	NU logic
`-`	scadere	`>`	mai mare	`x & y`	SI logic
`*`	inmultire	`<=`	mai mic sau egal	`x && y`	id.
`/`	impartire	`>=`	mai mare sau egal	`x | y`	SAU logic
`^`	ridicare la putere	`==`	egal	`x || y`	id.
`%%`	modul	`!=`	diferit de	`xor(x, y)`	SAU exclusiv
`%/%`	impartire cu rest				

Operatorii aritmetici si de comparatie actioneaza asupra a doua elemente (`x + y`, `a < b`). Operatorii aritmetici actioneaza nu doar asupra variabilelor de tip numeric sau complex, dar si asupra variabilelor logice; in cazul din urma, valorile logice sunt fortat transformate in numerice. Operatorii de comparatie pot fi aplicati oricarui tip: ei returneaza una sau cateva valori logice.

Operatorii logici sunt aplicati unui (`!`) sau unor obiecte de tip logic si returneaza una (sau mai multe) valori logice. Operatorii "SI" si "SAU" exista sub doua forme: cel simplu actioneaza asupra fiecarui element din obiect si returneaza tot atatea valori logice cate comparatii s-au facut; cel dublu opereaza asupra primului element al obiectului.

Este necesara utilizarea operatorului "SI" pentru a specifica o inegalitate de tipul $0 < x < 1$ care va fi codata prin: `0 < x & x < 1`. Expresia `0 < x < 1` este valida, dar nu va returna rezultatul asteptat: din moment ce operatorii sunt identici, vor fi executati succesiv de la stanga la dreapta. Comparatia `0 < x` este executata prima si returneaza o valoare de tip logic care este apoi comparata cu 1 (`TRUE` sau `FALSE < 1`): in aceasta situatie, valoarea logica este implicit transformata in tip numeric (`1` sau `0 < 1`).

```
> x <- 0.5
> 0 < x < 1
[1] FALSE
```

Operatorii de comparatie opereaza pe *fiecare* element al ambelor obiecte de comparat (recicland valorile celei mai scurte daca este necesar) si astfel returneaza un obiect de aceeasi lungime. Pentru a compara 'in intregime' doua obiecte, sunt disponibile doua functii: `identical` si `all.equal`.

[10] Caracterele urmatoare sunt de asemenea operatori in R: `$`, `@`, `[`, `[[`, `:`, `?`, `<-`, `<<-`, `=`, `::`. Un tabel de operatori ce descrie regulile cu precadere poate fi gasit cu `?Syntax`.

```
> x <- 1:3; y <- 1:3
> x == y
[1] TRUE TRUE TRUE
> identical(x, y)
[1] TRUE
> all.equal(x, y)
[1] TRUE
```

Functia `identical` compara reprezentarea interna a datelor si returneaza `TRUE` daca obiectele sunt identice si `FALSE` in caz contrar. Functia `all.equal` compara "egalitatea apropiata" a doua obiecte si returneaza `TRUE` sau afiseaza un sumar al diferentelor. Cea de-a doua functie ia in considerare aproximarea calculului procesului atunci cand compara valori numerice. Compararea valorilor numerice pe un computer este uneori plina de suprize!

```
> 0.9 == (1 - 0.1)
[1] TRUE
> identical(0.9, 1 - 0.1)
[1] TRUE
> all.equal(0.9, 1 - 0.1)
[1] TRUE
> 0.9 == (1.1 - 0.2)
[1] FALSE
> identical(0.9, 1.1 - 0.2)
[1] FALSE
> all.equal(0.9, 1.1 - 0.2)
[1] TRUE
> all.equal(0.9, 1.1 - 0.2, tolerance = 1e-16)
[1] "Mean relative  difference: 1.233581e-16"
```

3.5.4 Accesarea valorilor unui obiect: sistemul de indexare

Sistemul de indexare este o cale eficienta si flexibila de a accesa in mod selectiv elementele unui obiect; poate fi atat *numeric* cat si *logic*. Pentru a accesa, spre exemplu, a treia valoare a unui vector `x`, introducem `x[3]` care poate fi folosit atat pentru a extrage cat si pentru a schimba aceasta valoare:

```
> x <- 1:5
> x[3]
[1] 3
> x[3] <- 20
> x
[1]  1  2 20  4  5
```

Chiar indexul poate fi un vector de tip numeric:

```
> i <- c(1, 3)
```

```
> x[i]
[1]  1 20
```

Daca `x` este o matrice sau o secventa de date, valoarea liniei i si a coloanei j este accesata cu `x[i, j]`. Pentru a accesa toate valorile ale unei anumite linii sau coloane, trebuie sa se omita indexul corespunzator (fara a uita virgula!):

```
> x <- matrix(1:6, 2, 3)
> x
     [,1] [,2] [,3]
[1,]    1    3    5
[2,]    2    4    6
> x[, 3] <- 21:22
> x
     [,1] [,2] [,3]
[1,]    1    3   21
[2,]    2    4   22
> x[, 3]
[1] 21 22
```

Cu siguranta ati observat ca ultimul rezultat este un vector si nu o matrice. R va returna implicit un obiect cu dimensiunea cea mai mica posibila. Acest fapt se poate schimba cu optiunea `drop` a carei valoare implicita este `TRUE`:

```
> x[, 3, drop = FALSE]
     [,1]
[1,]   21
[2,]   22
```

Acest sistem de indexare este schematizat in siruri, cu un numar de indici egal cu numarul de dimensiuni ale sirului (de exemplu, un sir de dimensiune 3: `x[i, j, k]`, `x[, , 3]`, `x[, , 3, drop = FALSE]`, si asa mai departe). Poate fi util de retinut ca indexarea se face cu paranteze patrate, in timp ce parantezele rotunde sunt utilizate pentru argumentele unei functii:

```
> x(1)
Error: couldn't find function "x"
```

Indexarea poate fi utilizata de asemenea pentru a suprima unul sau mai multe linii sau coloane utilizand valori negative. De exemplu, `x[-1, ]` va suprima prima linie, in timp ce `x[-c(1, 15), ]` va face acelasi lucru pentru linia 1 si linia 15. Utilizand matricea definita mai sus:

```
> x[, -1]
     [,1] [,2]
[1,]    3   21
[2,]    4   22
```

```
> x[, -(1:2)]
[1] 21 22
> x[, -(1:2), drop = FALSE]
     [,1]
[1,]   21
[2,]   22
```

Pentru vectori, matrici si siruri, este posibila accesarea valorilor unui element cu o expresie de comparatie ca in indexul:

```
> x <- 1:10
> x[x >= 5] <- 20
> x
 [1]  1  2  3  4 20 20 20 20 20 20
> x[x == 1] <- 25
> x
 [1] 25  2  3  4 20 20 20 20 20 20
```

O utilizare practica a indexarii logice este, de exemplu, posibilitatea selectarii elementelor cu sot ale unei variabile intregi:

```
> x <- rpois(40, lambda=5)
> x
 [1]  5  9  4  7  7  6  4  5 11  3  5  7  1  5  3  9  2  2  5  2
[21]  4  6  6  5  4  5  3  4  3  3  3  7  7  3  8  1  4  2  1  4
> x[x %% 2 == 0]
 [1] 4 6 4 2 2 2 4 6 6 4 4 8 4 2 4
```

Prin urmare, acest sistem de indexare utilizeaza valorile logice returnate, in exemplele de mai sus, prin operatori de comparatie. Aceste valori logice pot fi calculate in prealabil, urmand sa fie reciclate daca este necesar:

```
> x <- 1:40
> s <- c(FALSE, TRUE)
> x[s]
 [1]  2  4  6  8 10 12 14 16 18 20 22 24 26 28 30 32 34 36 38 40
```

Indexarea logica poate fi utilizata si cu secvente de date, insa cu grija, din moment ce coloane diferite din secventa de date pot avea tipuri diferite.

In cazul listelor, accesarea diferitelor elemente (care pot fi orice tip de obiect) este efectuata fie cu paranteze patrate simple fie cu duble: diferenta este ca prin parantezele simple se returneaza o lista, in timp ce parantezele duble *extrag* obiectul dintr-o lista. Rezultatul poate fi indexat asa cum s-a prezentat anterior pentru vectori, matrici, etc. Spre exemplu, daca al treilea obiect al unei liste este vector, valoarea i a sa poate fi accesata utilizand `my.list[[3]][i]`, daca este un sir de dimensiune 3 utilizand `my.list[[3]][i, j, k]` si asa mai departe. O alta diferenta este aceea ca `my.list[1:2]` va returna o lista cu primele doua elemente din lista originala, desi `my.list[[1:2]]` nu va da rezultatul asteptat.

3.5.5 Accesarea valorilor unui obiect cu nume

Numele sunt etichete ale elementelor unui obiect, prin urmare sunt de tip caracter. Ele sunt in general atribute optionale. Exista cateva tipuri de nume (*names*, *colnames*, *rownames*, *dimnames*).

Numele unui vector sunt memorate intr-un vector de aceeasi lungime cu obiectul si pot fi accesate cu functia `names`.

```
> x <- 1:3
> names(x)
NULL
> names(x) <- c("a", "b", "c")
> x
a b c
1 2 3
> names(x)
[1] "a" "b" "c"
> names(x) <- NULL
> x
[1] 1 2 3
```

Pentru matrici si secvente de date, *colnames* si *rownames* sunt etichetele pentru coloane si, respectiv linii. Acestea pot fi accesate atat cu functiile lor corespunzatoare, cat si cu `dimnames` care returneaza o lista cu ambii vectori.

```
> X <- matrix(1:4, 2)
> rownames(X) <- c("a", "b")
> colnames(X) <- c("c", "d")
> X
  c d
a 1 3
b 2 4
> dimnames(X)
[[1]]
[1] "a" "b"

[[2]]
[1] "c" "d"
```

Pentru siruri, numele dimensiunilor pot fi accesate cu `dimnames`:

```
> A <- array(1:8, dim = c(2, 2, 2))
> A
, , 1

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

```
[2,]    2    4

, , 2

     [,1] [,2]
[1,]    5    7
[2,]    6    8

> dimnames(A) <- list(c("a", "b"), c("c", "d"), c("e", "f"))
> A
, , e

  c d
a 1 3
b 2 4

, , f

  c d
a 5 7
b 6 8
```

Daca elementele unui obiect au nume, acestea pot fi extrase utilizandule sub forma de indici. De fapt, aceasta poarta numele de 'subsetting' mai degraba decat 'extraction' din moment ce sunt pastrate atributele obiectului original. De exemplu, daca o secventa de date `DF` contine variabilele `x`, `y` si `z`, comanda `DF["x"]` va returna o secventa de date doar cu `x`; `DF[c("x", "y")]` va returna o secventa de date cu ambele variabile. Aceasta functioneaza si cu liste daca elementele acesteia au nume.

Asa cum constata cititorul, indexul utilizat aici este un vector de tip caracter. Ca si vectorii numerici sau logici observati mai sus, acest vector poate fi definit in prealabil si apoi utilizat pentru extragere. Pentru a extrage un vector sau un factor dintr-o secventa de date, se poate utiliza operatorul `$` (e.g., `DF$x`). Acesta functioneaza si in cazul listelor.

3.5.6 Editorul de date

Se poate utiliza o fila grafica pentru editarea unui obiect de "date". De exemplu, daca `X` este o matrice, comanda `data.entry(X)` va lansa un editor grafic si se vor putea modifica valori prin selectarea celulelor respective, or to addsau se vor putea adauga coloane noi sau linii.

Functia `data.entry` modifica direct obiectul dat ca argument fara sa fie nevoie sa i se atribuie rezultatul. Pe de alta parte, functia `de` returneaza o lista cu obiectele date ca argumente si posibil modificate. Acest rezultat este afisat pe ecran in mod implicit, insa, ca pentru majoritatea functiilor, poate fi atribuit unui obiect.

Detaliile privind utilizarea editorului de date depind de sistemul de operare.

3.5.7 Functii aritmetice simple

Exista numeroase functii in R pentru a manipula datele. Deja am studiat-o pe cea mai simpla, `c` care concateneaza obiectele listate in paranteze. De exemplu:

```
> c(1:5, seq(10, 11, 0.2))
 [1]  1.0  2.0  3.0  4.0  5.0 10.0 10.2 10.4 10.6 10.8 11.0
```

Vectorii pot fi manipulati cu expresii aritmetice clasice:

```
> x <- 1:4
> y <- rep(1, 4)
> z <- x + y
> z
[1] 2 3 4 5
```

Pot fi adunati vectori de lungimi diferite; in acest caz, este reciclat cel mai scurt vector. Exemple:

```
> x <- 1:4
> y <- 1:2
> z <- x + y
> z
[1] 2 4 4 6
> x <- 1:3
> y <- 1:2
> z <- x + y
Warning message:
longer object length
 is not a multiple of shorter object length in: x + y
> z
[1] 2 4 4
```

De remercat ca R returneaza un mesaj de atentionare si nu un mesaj de eroare, chiar daca operatia a fost efectuata. Daca vrem sa adunam (sau sa inmultim) aceeasi valoare tuturor elementelor unui vector:

```
> x <- 1:4
> a <- 10
> z <- a * x
> z
[1] 10 20 30 40
```

Functiile disponibile in R pentru manipularea datelor sunt prea numeroase pentru a fi enumerate aici. Se pot gasi toate functiile matematice de baza (`log`, `exp`, `log10`, `log2`, `sin`, `cos`, `tan`, `asin`, `acos`, `atan`, `abs`, `sqrt`, ...), functiile speciale (`gamma`, `digamma`, `beta`, `besselI`, ...), ca si alte diverse

functii utilizate in statistica. Cateva dintre aceste functii sunt prezentate in tabelul urmator.

`sum(x)`	suma elementelor lui `x`
`prod(x)`	produsul elementelor lui `x`
`max(x)`	maximul elementelor lui `x`
`min(x)`	minimul elementelor lui `x`
`which.max(x)`	returneaza indexul celui mai mare element al lui `x`
`which.min(x)`	returneaza indexul celui mai mic element al lui `x`
`range(x)`	id. than `c(min(x), max(x))`
`length(x)`	numarul elementelor lui `x`
`mean(x)`	media elementelor lui `x`
`median(x)`	mediana elementelor lui `x`
`var(x)` sau `cov(x)`	dispersia elementelor lui `x` (calculata cu $n-1$); daca `x` este o matrice sau o secventa de date, matricea varianta-covarianta este calculata
`cor(x)`	matricea corelatie a lui `x` daca este o matrice sau o secventa de date (1 daca `x` este un vector)
`var(x, y)` sau `cov(x, y)`	dispersia dintre `x` si `y`, sau dintre coloanele lui `x` si ale lui `y` daca sunt matrici sau secvente de date
`cor(x, y)`	corelatie liniara intre `x` si `y`,sau matricea corelatiei daca sunt matrici sau secvente de date

Aceste functii returneaza o singura valoare (deci un vector de lungime unu), cu exceptia `range` care returneaza un vector de lungime doi, si `var`, `cov`, si `cor` care pot returna o matrice. Functiile urmatoare returneaza rezultate mai complexe.

`round(x, n)`	rotunjeste elementele lui `x` cu `n` zecimale
`rev(x)`	inverseaza elementele lui `x`
`sort(x)`	sorteaza elementele lui `x` in ordine crescatoare; pentru sortare in ordine descrescatoare: `rev(sort(x))`
`rank(x)`	ordoneaza elementele lui `x`
`log(x, base)`	calculeaza logaritmul lui `x` in baza `base`
`scale(x)`	daca `x` este o matrice, centreaza si reduce datele; doar pentru centrare se foloseste optiunea `center=FALSE`, doar pentru reducere `scale=FALSE` (in mod implicit `center=TRUE, scale=TRUE`)
`pmin(x,y,...)`	un vector cu elementul i reprezentand minimul dintre `x[i]`, `y[i]`, ...
`pmax(x,y,...)`	id. pentru maxim
`cumsum(x)`	un vector cu elementul i reprezentand suma de la `x[1]` la `x[i]`
`cumprod(x)`	id. pentru produs
`cummin(x)`	id. pentru minim
`cummax(x)`	id. pentru maxim
`match(x, y)`	returneaza un vector de aceeasi lungime cu `x` cu elementele lui `x` care se afla in `y` (`NA` altfel)
`which(x == a)`	returneaza un vector cu indicii lui `x` operatorul de comparatie este adevarat (`TRUE`), in acest exemplu valorile lui `i` pentru care `x[i] == a` (argumentul acestei functii trebuie sa fie o variabila de tip logic)
`choose(n, k)`	calculeaza combinari de k luate cate n repetari $= n!/[(n-k)!k!]$
`na.omit(x)`	suprima observatiile cu date lipsa (`NA`) (suprima linia corespunzatoare daca `x` este o matrice sau o secventa de date)

`na.fail(x)`	returneaza un mesaj de eroare daca `x` contine cel putin un `NA`
`unique(x)`	daca `x` este un vector sau o secventa de date, returneaza un obiect similar insa u elementele duble suprimate
`table(x)`	returneaza un tabel cu numerele diferitelor valori ale lui `x` (specific pentru cele de tip integer sau factor)
`table(x, y)`	tabel de contingenta al lui `x` si `y`
`subset(x, ...)`	returneaza o selectie a lui `x` privitoare la criteriul (. . . , specifica comparatiilor : `x$V1 < 10`); daca `x` este o secventa de date, optiunea `select` permita ca variabilele sa fie pastrate (sau restranse folosind un semn de minus)
`sample(x, size)`	reesantioneaza aleatoriu si fara inlocuire `size` elemente din vectorul `x`, optiunea `replace = TRUE` permite reesantionarea fara inlocuire

3.5.8 Calcul matriceal

R ofera facilitati pentru calcule si manipulari ale matricilor. Functiile `rbind` si `cbind` imbina matrici tinand cont de linii sau coloane, respectiv:

```
> m1 <- matrix(1, nr = 2, nc = 2)
> m2 <- matrix(2, nr = 2, nc = 2)
> rbind(m1, m2)
     [,1] [,2]
[1,]    1    1
[2,]    1    1
[3,]    2    2
[4,]    2    2
> cbind(m1, m2)
     [,1] [,2] [,3] [,4]
[1,]    1    1    2    2
[2,]    1    1    2    2
```

Operatorul care realizeaza produsul a doua matrici este '`%*%`'. De exemplu, considerand cele doua matrici `m1` si `m2` de mai sus:

```
> rbind(m1, m2) %*% cbind(m1, m2)
     [,1] [,2] [,3] [,4]
[1,]    2    2    4    4
[2,]    2    2    4    4
[3,]    4    4    8    8
[4,]    4    4    8    8
> cbind(m1, m2) %*% rbind(m1, m2)
     [,1] [,2]
[1,]   10   10
[2,]   10   10
```

Transpusa unei matrici este efectuata cu functia `t`; aceasta functie este valabila si pentru secvente de date.

Functia `diag` poate fi utilizata pentru a extrage sau a modifica diagonala unei matrici, sau pentru a construi diagonala unei matrici.

```
> diag(m1)
[1] 1 1
> diag(rbind(m1, m2) %*% cbind(m1, m2))
[1] 2 2 8 8
> diag(m1) <- 10
> m1
     [,1] [,2]
[1,]   10    1
[2,]    1   10
> diag(3)
     [,1] [,2] [,3]
[1,]    1    0    0
[2,]    0    1    0
[3,]    0    0    1
> v <- c(10, 20, 30)
> diag(v)
     [,1] [,2] [,3]
[1,]   10    0    0
[2,]    0   20    0
[3,]    0    0   30
> diag(2.1, nr = 3, nc = 5)
     [,1] [,2] [,3] [,4] [,5]
[1,]  2.1  0.0  0.0    0    0
[2,]  0.0  2.1  0.0    0    0
[3,]  0.0  0.0  2.1    0    0
```

R are si cateva functii speciale pentru calcule cu matrici. Putem mentiona `solve` pentru inversarea unei matrici, `qr` pentru descompunere, `eigen` pentru calculul numarului caracteristic si vectorului propriu, si `svd` pentru descompunerea valorilor singulare.

4 Grafice in R

R ofera o varietate remarcabila de grafice. Pentru a va face o idee, puteti incerca `demo(graphics)` sau `demo(persp)`. Nu putem detalia aici posibilitatile R-ului in materie de grafice, din moment ce fiecare functie grafica are un numar mare de optiuni ce fac foarte flexibila producerea de grafice.

Modul in care functioneaza functiile grafice provine mai ales de la schema prezentata la inceputul acestui document. Rezultatul unei functii grafice nu poate fi atribuit unui obiect[11] insa este trimis unui *instrument grafic*. Un instrument grafic este o fereastra grafica sau un fisier.

Exista doua tipuri de functii grafice: *functii de grafice prin puncte de nivel ridicat* care creaza un grafic nou, si *functii de grafice prin puncte de nivel scazut* care adauga elemente unui grafic existent. Graficele sunt produse cu referire la *parametri grafici* care sunt definiti in mod implicit si pot fi modificati cu functia `par`.

Vom vedea in primul rand cum se gestioneaza graficele si instrumentele grafice; apoi vom detalia oarecum functiile grafice si parametrii. Apoi vom vedea un exemplu practic de utilizare a acestor functionalitati in producerea graficelor. In incheiere, vom expune pachetele grid si lattice ale caror functionare este diferita de cele mentionate anterior.

4.1 Gestionarea graficelor

4.1.1 Deschiderea catorva instrumente grafice

Atunci cand este executata o functie grafica, daca nu este deschis un instrument grafic, R deschide o fereastra grafica in care afiseaza graficul. Un instrument grafic poate fi deschis cu functia potrivita. Lista instrumentelor grafice disponibile depinde de sistemul de operare. Ferestrele grafice sunt numite `X11` in Unix/Linux si `ferestre` in Windows. In toate cazurile, se poate deschide o fereastra grafica prin comanda `x11()` care functioneaza si in Windows din cauza unui nume de imprumut referitor la comanda `windows()`. Un instrument grafic care este un fisier va fi deschis cu o functie specifica formatului: `postscript()`, `pdf()`, `png()`, ... Lista cu instrumente grafice disponibile poate fi afisata cu `?device`.

Ultimul instrument deschis devine instrumentul grafic activ pe care toate graficele ulterioare sunt afisate. Functia `dev.list()` afiseaza lista instrumentelor deschise:

```
> x11(); x11(); pdf()
```

[11] Exista cateva exceptii: `hist()` si `barplot()` produce si rezultate numerice de tip lista sau matrici.

```
> dev.list()
X11 X11 pdf
  2   3   4
```

Cifrele afisate sunt numerele instrumentului care trebuie utilizat pentru a schimba instrumentul activ. Pentru a afla instrumentul activ:

```
> dev.cur()
pdf
  4
```

si pentru a schimba instrumentul activ:

```
> dev.set(3)
X11
  3
```

Functia `dev.off()` inchide un instrument: in mod implicit este inchis instrumentul activ, in caz contrar acesta este cel al carui numar este dat ca argument al functiei. R afiseaza apoi numarul noului instrument activ:

```
> dev.off(2)
X11
  3
> dev.off()
pdf
  4
```

Doua caracteristici specifice versiunii de Windows a R-ului merita a fi mentionate: un instrument Windows Metafile care poate si deschis cu functia `win.metafile`, si un meniu "History" afisat atunci cand fereastra grafica este selectata ce permite inregistrarea tuturor graficelor intocmite in timpul unei sesiuni (in mod implicit, sistemul de inregistrare este oprit; utilizatorul il poate porni facand click pe "Recording" in acest meniu).

4.1.2 Impartirea unui grafic

Functia `split.screen` imparte instrumentul graficului activ. De exemplu:

```
> split.screen(c(1, 2))
```

imparte instrumentul in doua parti care pot fi selectate cu `screen(1)` sau `screen(2)`; `erase.screen()` sterge ultimul grafic desenat. O parte din instrument poate fi impartita la randul ei cu `split.screen()` ducand la posibilitatea de a face aranjamente mai complexe.

Aceste functii sunt incompatibile cu altele (sum ar fi `layout` sau `coplot`) si nu trebuie utilizate in cadrul mai multe instrumente grafice. Utilizarea lor trebuie sa se limiteze, spre exemplu, la explorarea grafica a datelor.

Functia `layout` imparte fereastra grafica activa in cateva parti in care graficele vor fi afisate succesiv. Argumentul sau principal este o matrice cu numere intregi ce indica numerele "sub-ferestrelor". De exemplu, pentru a imparti instrumentul in patru parti egale:

```
> layout(matrix(1:4, 2, 2))
```

De asemenea este posibila crearea acestei matrici inainte, permitand o vizualizare mai buna a modului de impartire a instrumentului:

```
> mat <- matrix(1:4, 2, 2)
> mat
     [,1] [,2]
[1,]    1    3
[2,]    2    4
> layout(mat)
```

Pentru a vizualiza impartirea creata, se poate utiliza functia `layout.show` cu numarul de sub-ferestre ca argument (in acest caz 4). In acest exemplu, vom avea:

```
> layout.show(4)
```

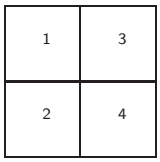

Exemplele urmatoare ilustreaza cateva dintre posibilitatile oferite de `layout()`.

```
> layout(matrix(1:6, 3, 2))
> layout.show(6)
```

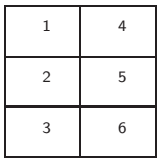


```
> layout(matrix(1:6, 2, 3))
> layout.show(6)
```

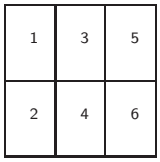


```
> m <- matrix(c(1:3, 3), 2, 2)
> layout(m)
> layout.show(3)
```

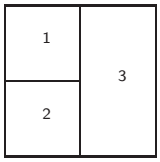

In toate aceste exemple, nu am utilizat optiunea `byrow` a functiei `matrix()`, sub-ferestrele fiind asftel numerotate sub forma de coloane; se poate specifica doar `matrix(..., byrow=TRUE)` astfel incat sub-ferestrele sa fie numerotate sub forma de randuri. Numerele din matrice pot fi alocate in orice ordine, de exemplu, `matrix(c(2, 1, 4, 3), 2, 2)`.

In mod implicit, `layout()` imparte instrumentul in inaltimi si latimi fixe: aceasta se poate modifica prin optiunile `widths` si `heights`. Aceste dimensiuni sunt date in mod relativ[12]. Exemple:

```
> m <- matrix(1:4, 2, 2)
> layout(m, widths=c(1, 3),
            heights=c(3, 1))
> layout.show(4)
```

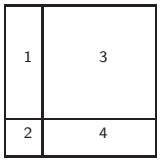


```
> m <- matrix(c(1,1,2,1),2,2)
> layout(m, widths=c(2, 1),
            heights=c(1, 2))
> layout.show(2)
```

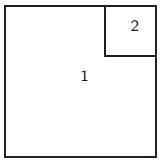

In cele din urma, numerele din matrice pot include zero-uri oferind posibilitatea de a face impartiri complexe (sau chiar esoterice).

```
> m <- matrix(0:3, 2, 2)
> layout(m, c(1, 3), c(1, 3))
> layout.show(3)
```

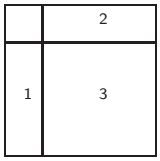


```
> m <- matrix(scan(), 5, 5)
1:  0 0 3 3 3 1 1 3 3 3
11:  0 0 3 3 3 0 2 2 0 5
21:  4 2 2 0 5
26:
Read 25 items
> layout(m)
> layout.show(5)
```

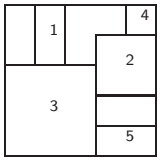

[12] Ele pot fi date in centimetri, vezi `?layout`.

4.2 Functiile grafice

In cele ce urmeaza vom face o prezentare generala a functiilor grafice de nivel ridicat din R.

`plot(x)`	grafic al valorilor lui `x` (pe axa y) ordonate pe axa x
`plot(x, y)`	grafic bidimensional al lui `x` (pe axa x) si `y` (pe axa y)
`sunflowerplot(x, y)`	id. insa punctele de coordonate similare sunt desenate ca o floare ce are numarul de petale egal cu numarul de puncte
`pie(x)`	grafic circular
`boxplot(x)`	boxplot
`stripchart(x)`	grafic al valorilor lui `x` pe o linie (o alternativa la `boxplot()` pentru esantioanele de dimensiuni mici)
`coplot(x~y | z)`	grafic bidimensional al lui `x` si `y` pentru valori individuale (sau interval de valori) ale lui `z`
`interaction.plot (f1, f2, y)`	pentru `f1` si `f2` factori, graficele mediilor lui `y` (pe axa y) raportate la valorile lui `f1` (pe axa x) si ale lui `f2` (curbe diferite); optiunea `fun` permite alegerea unei sumarizari statistice a lui `y` (in mod implicit `fun=mean`)
`matplot(x,y)`	grafic bidimensional a primei coloane a lui `x` *vs.* a primei coloane a lui `y`, a doua a lui `x` *vs.* a doua a lui `y`, etc.
`dotchart(x)`	pentru `x` secventa de date, face graficul de tip puncte (grafice ingramadite linie de linie si coloana de coloana)
`fourfoldplot(x)`	vizualizeaza, cu sferturi de cerc, relatia dintre doua variabile dihotomice pentru populatii diferite (`x` trebuie sa fie un sir cu `dim=c(2, 2, k)`, sau o matrice cu `dim=c(2, 2)` pentru $k = 1$)
`assocplot(x)`	grafic Cohen–Friendly ce arata abaterile de la indenepdenta randurilor si coloanelor intr-un tabel de contingenta bidimensional
`mosaicplot(x)`	grafic 'mozaic' al valorilor reziduale ale unei regresii logaritmice a unui tabel de contingenta
`pairs(x)`	pentru `x` matrice sau secventa de date, creaza toate graficele bivariate posibile dintre coloanele lui `x`
`plot.ts(x)`	pentru `x` obiect de clasa `"ts"`, creaza graficul lui `x` raportate la timp, `x` poate fi multivariat insa seriile trebuie sa aiba aceleasi frecvente si date
`ts.plot(x)`	id. insa `x` este multivariat iar seriile pot avea date diferite si trebuie sa aiba aceeasi frecventa
`hist(x)`	histograma frecventelor lui `x`
`barplot(x)`	histograma valorilor lui `x`
`qqnorm(x)`	cuantilele lui `x` raportate la valorile asteptate sub o regula normala
`qqplot(x, y)`	cuantilele lui `y` raportate la cuantilele lui `x`
`contour(x, y, z)`	grafic contur (datele sunt interpolate pentru a desena curbele), `x` si `y` trebuie sa fie vectori si `z` trebuie sa fie matrice astfel incat `dim(z)=c(length(x), length(y))` (`x` si `y` pot fi omise)
`filled.contour (x, y, z)`	id. insa zonele dintre contururi sunt colorate, existand si o legenda a culorilor
`image(x, y, z)`	id. insa zona curenta este reprezentata prin culori
`persp(x, y, z)`	id. insa in perspectiva
`stars(x)`	pentru `x` matrice sau secventa de date, creaza un grafic cu segmente sau o stea in care fiecare rand al lui `x` este reprezentat de o stea iar coloanele sunt lungimile segmentelor

`symbols(x, y, ...)`	deseneaza, la coordonatele date de `x` si `y`, simboluri (cercuri, patrate, dreptunghiuri, stele, termometre sau "boxplot-uri") ale caror dimensiuni, culori, etc, sunt specificate de argumente suplimentare
`termplot(mod.obj)`	graficul efectelor (partiale) ale unui model de regresie (`mod.obj`)

Pentru fiecare functie, optiunile pot fi gasite in suportul on-line din R. cateva dintre aceste optiuni sunt identice pentru cateva functii grafice; mai jos sunt prezentate cele principale (cu valorile posibile implicite):

`add=FALSE`	if `TRUE` suprapune graficul peste cel anterior (daca acesta exista)
`axes=TRUE`	if `FALSE` nu deseneaza axele si caseta
`type="p"`	specifica tipul graficului, `"p"`: puncte, `"l"`: linii, `"b"`: puncte unite prin linii, `"o"`: id. insa liniile sunt peste puncte, `"h"`: linii verticale, `"s"`: trepte, datele sunt reprezentate prin varful liniilor verticale, `"S"`: id. insa datele sunt reprezentate prin baza liniilor verticale
`xlim=, ylim=`	specifica limitele de jos si de sus a axelor, de exemplu cu `xlim=c(1, 10)` sau `xlim=range(x)`
`xlab=, ylab=`	denumeste axele; trebuie sa fie variabile de tip caracter
`main=`	titlul principal; trebuie sa fie variabila de tip caracter
`sub=`	subtitlu (scris cu un font mai mic)

4.3 Comenzi de grafice de nivel scazut

R are un set de functii grafice care afecteaza un grafic deja existent: ele sunt numite *comenzi de grafice de nivel scazut*. Iata care sunt principalele:

`points(x, y)`	adauga puncte (poate fi utilizata optiunea `type=`)
`lines(x, y)`	id. insa adauga linii
`text(x, y, labels, ...)`	adauga text dat de `labels` la coordonatele (`x`,`y`); o varianta des folosita este: `plot(x, y, type="n"); text(x, y, names)`
`mtext(text, side=3, line=0, ...)`	adauga text dat de `text` la marginea specificata de `side` (vezi `axis()` mai jos); `line` specifica linia din zona graficului
`segments(x0, y0, x1, y1)`	deseneaza linii de la punctele (`x0`,`y0`) la punctele (`x1`,`y1`)
`arrows(x0, y0, x1, y1, angle= 30, code=2)`	id. cu sageti catre punctele (`x0`,`y0`) daca `code=2`, catre punctele (`x1`,`y1`) daca `code=1`, sau ambele daca `code=3`; `angle` controleaza unghiul dintre axa sagetii si limita capului sagetii
`abline(a,b)`	deseneaza o linie de panta `b` si segment `a`
`abline(h=y)`	deseneaza o linie orizontala la ordonata `y`
`abline(v=x)`	deseneaza o linie verticala la abcisa `x`
`abline(lm.obj)`	deseneaza linia regresiei data de `lm.obj` (vezi sectiunea 5)

`rect(x1, y1, x2, y2)`	deseneaza un dreptunghi ale carui limite din stanga, dreapta, sus si jos sunt `x1`, `x2`, `y1`, si respectiv `y2`
`polygon(x, y)`	deseneaza un poligon ce uneste punctele de coordonate date de `x` si `y`
`legend(x, y, legend)`	adauga legenda la punctul (`x`,`y`) cu simbolurile date de `legend`
`title()`	adauga un titlu si optional un subtitlu
`axis(side, vect)`	adauga o axa la baza (`side=1`), in stanga (`2`), sus (`3`), sau in dreapta (`4`); `vect` (optional) abcisa (sau ordonatele) unde sunt desenate marcajele
`box()`	adauga o caseta in jurul graficului curent
`rug(x)`	deseneaza datele `x` pe axa x ca linii verticale mici
`locator(n, type="n", ...)`	returneaza coordonatele (x, y) pe care utilizatorul a facut click cu mouse-ul de `n` ori pe grafic; de asemenea deseneaza simboluri (`type="p"`) sau linii (`type="l"`) referitoare la parametri grafici optionali (`...`); in mod implicit nu este desenat nimic (`type="n"`)

De remercat posibilitatea de a adauga expresii matematice pe un grafic cu `text(x, y, expression(...))`, acolo unde functia `expression` transforma argumentele sale intr-o ecuatie matematica De exemplu,

```
> text(x, y, expression(p == over(1, 1+e^-(beta*x+alpha))))
```

va afisa, pe grafic, urmatoare ecuatie la punctul de coordonate (x, y):

$$\mathrm{p} = \frac{1}{1 + \mathrm{e}^{-(\beta \mathrm{x} + \alpha)}}$$

Pentru a include o variabila intr-o expresie putem utiliza functiile `substitute` si `as.expression`; de exemplu pentru a include valoarea lui R^2 (calculata anterior si memorata intr-un obiect numit `Rsquared`):

```
> text(x, y, as.expression(substitute(R^2==r, list(r=Rsquared))))
```

va afisa pe grafic la punctul de coordonate (x, y):

$$\mathrm{R}^2 = 0.9856298$$

Pentru a afisa doar trei zecimale, comanda se poate modifica dupa cum urmeaza:

```
> text(x, y, as.expression(substitute(R^2==r,
+                           list(r=round(Rsquared, 3)))))
```

si va afisa:

$$\mathrm{R}^2 = 0.986$$

In cele din urma, pentru a scrie R cu font italic:

```
> text(x, y, as.expression(substitute(italic(R)^2==r,
+                           list(r=round(Rsquared, 3)))))
```

$$R^2 = 0.986$$

4.4 Parametri grafici

In plus fata de comenzile de grafice de nivel scazut, prezentarea graficelor poate fi imbunatatita cu prezentarea parametrilor grafici. Acestia pot fi utilizati fie ca optiuni ale functiilor grafice (insa nu functioneaza pentru toate), sau impreuna cu functia `par` pentru a schimba permanent parametrii grafici, astfel ca graficele consecutive vor fi desenate in raport cu parametrii specificati de utilizator. Spre exemplu, comanda urmatoare:

```
> par(bg="yellow")
```

va avea ca rezultat desenarea graficelor consecutive cu un fundal galben. Exista 73 de parametri grafici, cativa dintre ei avand functii similare. Lista completa a acestor parametri poate fi citita cu `?par`; in urmatorul tabel sunt prezentati cei mai uzuali.

`adj`	controleaza alinierea textului fata de limita stanga a textului astfel incat `0` este aliniat stanga, `0.5` este centrat, `1` este aliniat dreapta, valorile > 1 muta textul inspre stanga, iar valorile negative inspre dreapta; pentru doua valori date (e.g., `c(0, 0)`) a doua controleaza alinierea verticala fata de nivelul textului
`bg`	specifica culoarea fundalului (e.g., `bg="red"`, `bg="blue"`; lista celor 657 de culori disponibile este afisata cu `colors()`)
`bty`	controleaza tipul casetei desenate in jurul graficului, valorile permise fiind: `"o"`, `"l"`, `"7"`, `"c"`, `"u"` ou `"]"` (caseta arata conform caracterului corespunzator); pentru `bty="n"` caseta nu este trasata
`cex`	o valoarea ce controleaza dimensiunea textului si simbolurilor fata de cele implicite; parametrii urmatori au acelasi control pentru numerele de pe axe, `cex.axis`, etichetele axelor, `cex.lab`, titlu, `cex.main`, si subtitlu, `cex.sub`
`col`	controleaza culoarea simbolurilor; ca si pentru `cex` exista: `col.axis`, `col.lab`, `col.main`, `col.sub`
`font`	o valoare integer care controleaza stilul textului (`1`: normal, `2`: italic, `3`: bold, `4`: bold italic); ca si pentru `cex` exista: `font.axis`, `font.lab`, `font.main`, `font.sub`
`las`	o valoare integer care controleaza orientarea etichetelor axelor (`0`: paralel cu axele, `1`: orizontal, `2`: perpendicular pe axe, `3`: vertical)
`lty`	controleaza tipul liniilor, poate fi de tip integer (`1`: neintrerupt, `2`: striat (eng. dashed), `3`: punctat (eng. dotted), `4`: striat si punctat (eng. dotdash), `5`: punctat lung (eng. longdash), `6`: punctat de doua ori (eng. twodash)), sau de tip sir de pana la 8 caractere (intre `"0"` si `"9"`) care specifica alternativ lungimea, in puncte sau pixeli, a elementelor desenate si ale spatiilor goale, de exemplu `lty="44"` ca avea acelasi efect cu `lty=2`
`lwd`	o valoare numerica ce controleaza lungimea liniilor
`mar`	un vector de 4 valori numerice care controleaza spatiul dintre axe si limita graficului de forma `c(bottom, left, top, right)`, valorile implicite sunt `c(5.1, 4.1, 4.1, 2.1)`
`mfcol`	un vector de forma `c(nr,nc)` care imparte fereastra graficului intr-o matrice cu `nr` linii si `nc` coloane, graficele fiind apoi desenate in coloane (vezi sectiunea 4.1.2)
`mfrow`	id. insa graficele sunt apoi desenate in linie (vezi sectiunea 4.1.2)
`pch`	controleaza tipul simbolului, fie ca este un integer intre 1 si 25, sau orice alt caracter fara `""` (Fig. 2)

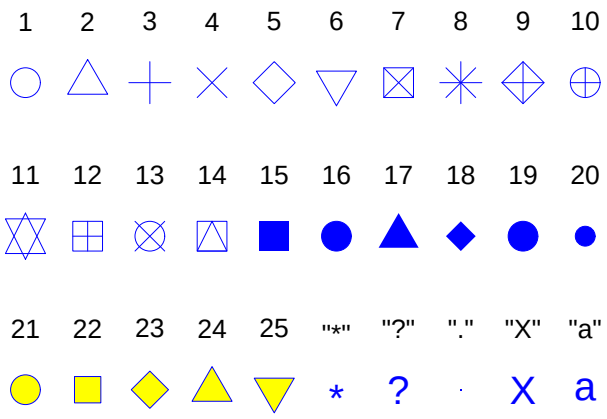

Figure 2: Simbolurile de reprezentare grafica in R (`pch=1:25`). Culorile au fost obtinute cu optiunile `col="blue", bg="yellow"`, a doua optiune are efect numai asupra simbolurilor 21–25. Poate fi utilizat orice caracter (`pch="*"`, `"?"`, `"."`, ...).

`ps`	o valoarea de tip integer ce controleaza dimensiunea in puncte a textului si simbolurilor
`pty`	un caracter ce specifica tipul zonei reprezentate grafic, `"s"`: patrat (eng. square), `"m"`: maximal
`tck`	o valoare care specifica lungimea marcajelor de pe axe ca parte a celei mai mici lungimi sau inaltimi a graficului; pentru `tck=1` este desenata o grila
`tcl`	id. insa ca parte a inaltimii unei linii de text (in mod implicit `tcl=-0.5`)
`xaxt`	pentru `xaxt="n"` axa x este setata insa nu desenata (util impreuna cu `axis(side=1, ...)`)
`yaxt`	pentru `yaxt="n"` axa y este setata insa nu desenata (util impreuna cu `axis(side=2, ...)`)

4.5 Un exemplu practic

Pentru a ilustra functionalitatile grafice ale lui R, vom considera un exemplu simplu de grafic bidimensional de 10 perechi de variabile aleatoare. Aceste valori au fost generate cu:

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

Graficul dorit va fi obtinut cu `plot()`; se va introduce comanda:

```
> plot(x, y)
```

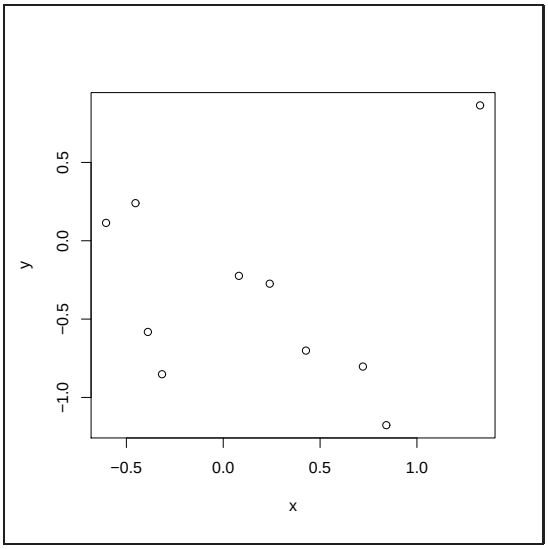

Figure 3: Functia `plot` utilizata fara optiuni.

iar graficul va fi reprezentat in instrumentul grafic activ. Rezultatul este aratat in Fig. 3. In mod implicit, R creaza grafice intr-un mod "inteligent": spatiile dintre marcajele de pe axe, plasarea etichetelor, etc, sunt calculate astfel incat graficul rezultat sa fie cat mai inteligibil posibil.

Cu toate acestea, utilizatorul poate schimba modul in care este prezentat un grafic, de exemplu, pentru a il adapta la un sablon editorial, sau pentru a ii oferi o amprenta personala pentru o discutie/prezentare. Cel mai simplu mod de a schimba prezentarea unui grafic este de a adauga optiuni care sa modifice argumentele implicite. In exemplul nostru, putem modifica semnificativ figura dupa cum urmeaza:

```
plot(x, y, xlab="Ten random values", ylab="Ten other values",
     xlim=c(-2, 2), ylim=c(-2, 2), pch=22, col="red",
     bg="yellow", bty="l", tcl=0.4,
     main="How to customize a plot with R", las=1, cex=1.5)
```

Rezultatul este in Fig. 4. Vom detalia fiecare optiune folosita. In primul rand, `xlab` si `ylab` schimba etichetele axelor care, in mod implicit, au fost numele variabilelor. Apoi, `xlim` si `ylim` ne permit sa definim limitele pe ambele axe[13]. Parametrul grafic `pch` este utilizat aici ca o optiune: `pch=22` specifica un patrat cu fundal si contur ce pot fi diferite si care sunt date de`col` si respectiv `bg`. Tabelul de parametri grafici prezinta intelesul modificarilor executate de `bty`, `tcl`, `las` si `cex`. In cele din urma, un titlu poate fi adaugat cu optiunea `main`.

[13]In mod implicit, R adauga 4% pe fiecare parte a limitei axei. Acesta manifestare poate fi alterata prin setarea parametrilor grafici `xaxs="i"` si `yaxs="i"` (pot fi trecuti ca optiuni in `plot()`).

Figure 4: Functia `plot` utilizata cu optiunile.

Parametrii grafici si functiile de grafice de nivel scazut ne permit sa avansam in prezentarea unui grafic. Asa acum am vazut anterior, cativa parametri grafici nu pot fi trecuti ca argumente intr-o functie ca `plot`. Vom modifica acum cativa dintre acesti parametri cu `par()`, asadar este necesara introducerea catorva comenzi. Atunci cand parametri grafici sunt schimbati, este utila salvarea valorilor initiale in prealabil pentru a le putea reda ulterior. Mai jos sunt prezentate comenzile utilizate pentru a obtine Fig. 5.

```
opar <- par()
par(bg="lightyellow", col.axis="blue", mar=c(4, 4, 2.5, 0.25))
plot(x, y, xlab="Ten random values", ylab="Ten other values",
     xlim=c(-2, 2), ylim=c(-2, 2), pch=22, col="red", bg="yellow",
     bty="l", tcl=-.25, las=1, cex=1.5)
title("How to customize a plot with R (bis)", font.main=3, adj=1)
par(opar)
```

Vom detalia actiunile rezultate din aceste comenzi. In primul rand, parametrii grafici impliciti sunt copiati intr-o lista numita aici `opar`. Vor fi modificati apoi trei parametri: `bg` pentru culoarea fundalului, `col.axis` pentru culoarea numerelor de pe axe si `mar` pentru dimensiunile marginilor din jurul zonei graficului. Graficul este desenat intr-un mod asemanator Fig. 4. Modificarile marginilor permit utilizarea spatiului din jurul zonei graficului. Titlul este adaugat aici cu functia grafica de nivel scazut `title` care permite utilizarea unor parametrii ca argumente fara a modifica restul graficului. In cele din urma, parametrii grafici initiali sunt redati cu ultima comanda.

Acum, controlul este total! In Fig. 5, R inca determina cateva lucruri, cum ar fi numarul de marcaje de pe axe, sau spatiul dintre titlu si zona graficului.

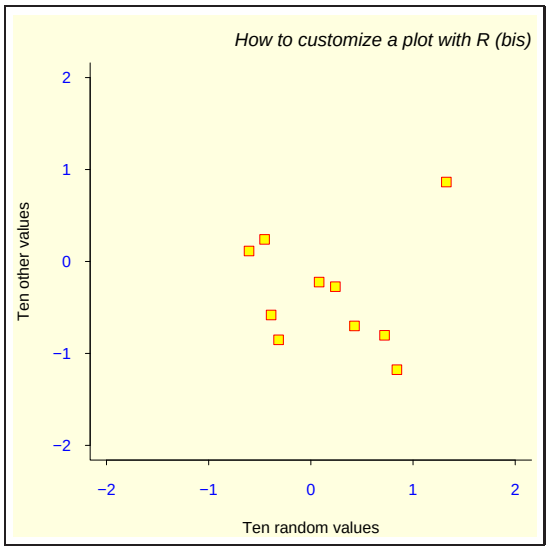

Figure 5: Functiile `par`, `plot` si `title`.

Vom vedea in cele ce urmeaza cum sa controlam total prezentarea graficului. Modalitatea utilizata aici este de a reprezenta un grafic "gol"(eng. blank) cu `plot(..., type="n")`, apoi de a adauga puncte, axe, etichete, etc, cu functii grafice de nivel scazut. Vom considera cateva aranjamente cum ar fi schimbarea culorii zonei graficului. Comenzile sunt prezentate mai jos, iar graficul rezultat se afla in Fig. 6.

```
opar <- par()
par(bg="lightgray", mar=c(2.5, 1.5, 2.5, 0.25))
plot(x, y, type="n", xlab="", ylab="", xlim=c(-2, 2),
     ylim=c(-2, 2), xaxt="n", yaxt="n")
rect(-3, -3, 3, 3, col="cornsilk")
points(x, y, pch=10, col="red", cex=2)
axis(side=1, c(-2, 0, 2), tcl=-0.2, labels=FALSE)
axis(side=2, -1:1, tcl=-0.2, labels=FALSE)
title("How to customize a plot with R (ter)",
      font.main=4, adj=1, cex.main=1)
mtext("Ten random values", side=1, line=1, at=1, cex=0.9, font=3)
mtext("Ten other values", line=0.5, at=-1.8, cex=0.9, font=3)
mtext(c(-2, 0, 2), side=1, las=1, at=c(-2, 0, 2), line=0.3,
      col="blue", cex=0.9)
mtext(-1:1, side=2, las=1, at=-1:1, line=0.2, col="blue", cex=0.9)
par(opar)
```

Ca si mai inainte, parametrii grafici impliciti sunt salvati, iar culoarea fundalului si marginile sunt modificate. Graficul este apoi desenat cu `type="n"` pentru a nu trasa puncetele, `xlab="", ylab=""` pentru a nu scrie etichetele

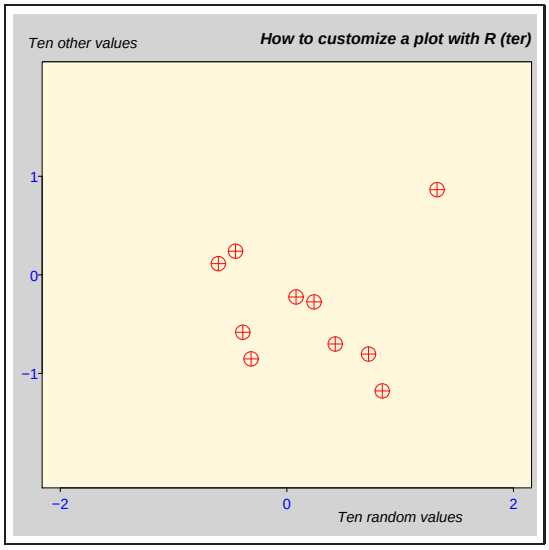

Figure 6: Un grafic "hand-made".

axelor, iar `xaxt="n", yaxt="n"` pentru a nu desena axele. Va rezulta crearea cadranului din jurul zonei graficului, si definirea axelor fata de `xlim` si `ylim`. De remercat ca am fi putut utiliza optiunea `axes=FALSE` insa in acest caz nici axele nici cadrulnu ar fi putut fi desenate.

Elementele sunt apoi adaugate in zona graficului definita cu cateva functii grafice de nivel scazut. Inainte de a adauga punctele, culoarea din interiorul zonei graficului este schimbata cu `rect()`: dimensiunile dreptunghiului sunt selectate astfel incat sa fie considerabil mai mare decat zona graficului.

Punctele sunt reprezentate cu `points()`; a fost utilizat un nou simbol. Axele sunt adaugate cu `axis()`: vectorul dat ca argument secund specifica coordonatele marcajelor. Optiunea `labels=FALSE` specifica ca nu poate fi scrisa nicio eticheta langa marcaje. Aceasta optiune accepta si un vector de tip caracter, spre exemplu `labels=c("A", "B", "C")`.

Titlul este adaugat cu `title()`, insa fontul este putin modificat. Notatiile de pe axe sunt scrise cu `mtext()` (*text marginal*). Primul argument al acestei functii este un vector de tip caracter ce urmeaza a fi scris. Optiunea `line` indica distanta de la zona graficului (in mod implicit `line=0`) `la` coordonata. A doua apelare a functiei `mtext()` utilizeaza valoarea implicita a lui `side` (3). Celelalte doua apelari ale functiei `mtext()` trec ca prim argument un vector numeric: acesta va fi convertit in caracter.

4.6 Pachetele grid si lattice

Pachetele grid si lattice implementeaza sistemele de tip grila si latice. Grila este un nou mod grafic cu sistem propriu de parametri grafici care sunt distincti fata de cei studiati anterior. Principalele doua diferente dintre grila si graficele

de baza sunt:

- un mod mai flexibil de a imparti instrumentele grafice utilizand *viewports* care poate fi superior (obiectele grafice pot fi chiar impartite intre zone distincte predefinite ale unui spatiu de afisare, de ex., sageti);
- obiectele grafice (*grob*) pot fi modificate sau sterse dintr-un grafic fara a fi necesara re-desenarea intregului grafic (asa cum se cere in cazul graficelor de baza).

Graficele de tip grila nu pot fi de obicei unite sau combinate cu graficele de baza (Pachetul gridBase trebuie utilizat pentru aceasta). In orice caz, este posibila utilizarea ambelor moduri grafice in aceeasi sesiune in cadrul aceluiasi instrument grafic.

Latice este in fond implementarea in cadrul R a graficelor Trellis din S-PLUS. Trellis este un mod de vizualizare a datelor multidimensionale in mod special corespunzator explorarii relatiilor sau interactiunilor dintre variabile[14]. Principala ideea din spatele latice (si al Trellis) este aceea a graficelor de conditionari multiple: un grafic bidimensional va fi impartit in cateva grafice tinand cont de valorile unei a treia variabile. Functia `coplot` utilizeaza o modalitate similara, insa latice ofera functionalitati mai vaste. Latice utilizeaza modul grafic de tip grila.

Cele mai multe functii din lattice considera o formula ca principalul lor argument[15], de exemplu `y ~ x`. Formula `y ~ x | z` presupune ca graficul lui `y` raportat la `x` sa fie reprezentat in cateva grafice tinand cont de valorile lui `z`.

Tabelul urmator prezinta principalele functii ale pachetului lattice. Formula data ca argument este formula tipic necesara, insa toate aceste functii accepta o formula conditionala (`y ~ x | z`) ca argument principal; in ultimul caz, un grafic multiplu, raportat la valorile lui `z`, este reprezentat asa cum se va vedea in exemplele de mai jos.

[14] http://cm.bell-labs.com/cm/ms/departments/sia/project/trellis/index.html

[15] `plot()` accepta de asemenea o formula ca argument principal: pentru `x` si `y` doi vectori de aceeasi lungime, `plot(y ~ x)` si `plot(x, y)` vor genera grafice identice.

`barchart(y ~ x)`	histograma valorilor lui `y` in raport cu cele ale lui `x`
`bwplot(y ~ x)`	grafic "box-and-whiskers"
`densityplot(~ x)`	graficul functiilor de densitate
`dotplot(y ~ x)`	grafic punctat Cleveland (grafice ingramadite linie de linie si coloana de coloana)
`histogram(~ x)`	histograma frecventelor lui `x`
`qqmath(~ x)`	cuantilele lui `x` raportate la valorile asteptate sub o distributie teoretica
`stripplot(y ~ x)`	grafic unidimensional, `x` trebuie sa fie numeric, `y` poate fi un factor
`qq(y ~ x)`	cuantile pentru compararea a doua distributii, `x` trebuie sa fie numeric, `y` trebuie sa fie numeric, caracter sau factor insa trebuie sa aiba doua 'niveluri'
`xyplot(y ~ x)`	grafice bidimensionale (cu multe functionalitati)
`levelplot(z ~ x*y)` `contourplot(z ~ x*y)`	grafic colorat al valorilor lui `z` la coordonatele date de `x` si `y` (`x`, `y` si `z` au toate aceeasi lungime)
`cloud(z ~ x*y)`	grafic de perspectiva 3-D (puncte)
`wireframe(z ~ x*y)`	id. (suprafata)
`splom(~ x)`	matrice de grafice bidimensionale
`parallel(~ x)`	grafic de coordonate paralele

In continuare vom vedea cateva exemple pentru a ilustra cateva aspecte ale pachetului lattice. Pachetul se incarca in memorie prin comanda `library(lattice)` astfel incat functiile sa poata fi accesate.

Vom incepe cu graficele functiilor de densitate. Asemenea grafice pot fi create cu `densityplot(~ x)` care va reprezenta o curba a functiei de densitate empirica cu punctele corespunzatoare observatiilor pe axa x (similar cu `rug()`). Exemplul nostru va fi putin mai complicat pe fiecare grafic cu superpozitia curbelor densitatii empirice si a celor prezise prin regula normala. Este necesara folosirea argumentului `panel` care defineste ce e reprezentat pe fiecare grafic. Comenzile sunt urmatoarele:

```
n <- seq(5, 45, 5)
x <- rnorm(sum(n))
y <- factor(rep(n, n), labels=paste("n =", n))
densityplot(~ x | y,
            panel = function(x, ...) {
                panel.densityplot(x, col="DarkOliveGreen", ...)
                panel.mathdensity(dmath=dnorm,
                                  args=list(mean=mean(x), sd=sd(x)),
                                  col="darkblue")
            })
```

Primele trei linii ale comenzii genereaza un esantion aleatoriu de variabile normal independente care este impartit in sub-esantioane de marime egala cu 5, 10, 15, ..., si 45. Apoi se apeleaza functia `densityplot` ce produce cate un grafic pentru fiecare sub-esantion. `panel` ia ca argument o functie. In exemplul nostru, am definit o functie care apeleaza doua functii pre-definite in lattice: `panel.densityplot` pentru a desena functia de densitate empirica si `panel.mathdensity` pentru a desena functia de densitate prezisa de regula

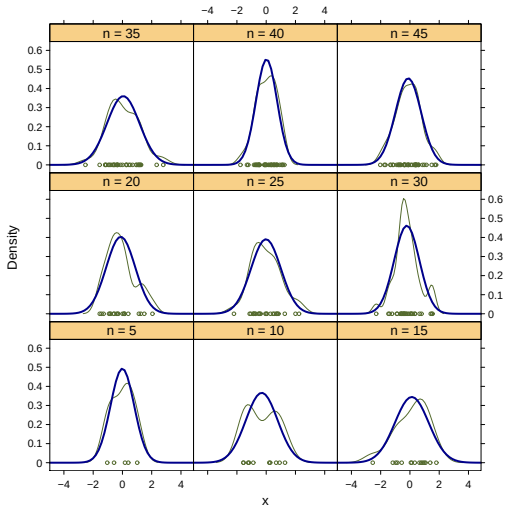

Figure 7: Functia `densityplot`.

normala. Functia `panel.densityplot` este chemata in mod implicit daca nu este dat niciun argument in `panel`: comanda `densityplot (~ x | y)` ar rezulta in acelasi grafic similar Fig. 7 insa fara curbele albastre.

Exemplele urmatoare sunt preluate, mai mult sau mai putin modificate, din suportul pachetului lattice si utilizeaza cateva seturi de date disponibile in R: localizarile a 1000 de cutremure in apropierea insulelor Fiji si cateva masuratori ale florilor facute pe trei specii de iris.

Fig. 8 arata localizarea geografica a cutremurelor raportate la adancime. Comenzile necesarepentru acest grafic sunt urmatoarele:

```
data(quakes)
mini <- min(quakes$depth)
maxi <- max(quakes$depth)
int <- ceiling((maxi - mini)/9)
inf <- seq(mini, maxi, int)
quakes$depth.cat <- factor(floor(((quakes$depth - mini) / int)),
                      labels=paste(inf, inf + int, sep="-"))
xyplot(lat ~ long | depth.cat, data = quakes)
```

Prima comanda incarca setul de date `quakes` in memorie. Urmatoarele cinci comenzi creaza un factor prin impartirea adancimii (variabila `depth`) in noua intervale egale: nivelurile acestui factor sunt etichetate cu cea mai mica si cea mai mare limita a acestor intervale. Apoi se poate chema functia `xyplot` cu formula corespunzatoare si argumentul `data` ce indica unde functia `xyplot` trebuie sa caut variabilele[16].

[16] `plot()` nu poate lua ca argument `data`, locatia variabilelor trebuie mentionata explicit, de exemplu `plot(quakes$long ~ quakes$lat)`.

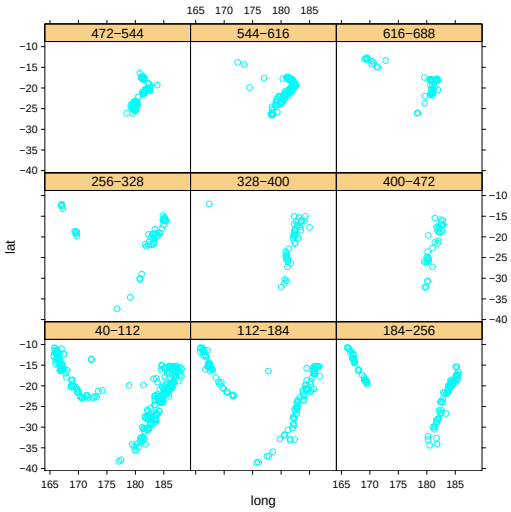

Figure 8: Functia `xyplot` cu setul de date"quakes"(cutremure).

In cazul setului de date `iris`, intrepatrunderea in cadrul diferitelor este suficient de mica astfel incat pot fi reprezentate grafic ca in figura (Fig. 9). Comenzile sunt urmatoarele:

```
data(iris)
xyplot(
  Petal.Length ~ Petal.Width, data = iris, groups=Species,
  panel = panel.superpose,
  type = c("p", "smooth"), span=.75,
  auto.key = list(x = 0.15, y = 0.85)
)
```

Apelarea functiei `xyplot` este un pic mai complexa in cazul de fata decat in cel anterior si utilizeaza cateva optiuni detaliate in cele ce urmeaza. Optiunea `groups`, asa cum ii sugereaza numele, defineste grupuri care vor fi utilizate de alte optiuni. Am vazut deja optiunea `panel` care defineste modul in care diferitele grupuri vor fi reprezentate pe grafic: am utilizat o functie pre-definita `panel.superpose` pentru a suprapune grupurile pe acelasi grafic. Nu este trecuta nicio optiune in `panel.superpose`, culorile implicite vor fi utilizate pentru a distinge grupurile. Optiunea `type`, similar `plot()`, specifica modul in care datele sunt reprezentate, insa aici putem da cateva argumente ca vector: `"p"` pentru a desena punctele si `"smooth"` pentru a desena o curba aplatizata al carei grad de aplatizare este specificat de `span`. Optiunea `auto.key` adauga o legenda graficului: este necesara mentionarea, sub forma de lista, a coordonatelor in care legenda va fi reprezentata. De remercat ca aceste coordonate sunt legate de dimensiunea graficului (adica in [0, 1]).

Acum vom ilustra functia `splom` cu acelasi set de date iris. Urmatoarele comenzi au fost utilizate pentru a crea Fig. 10:

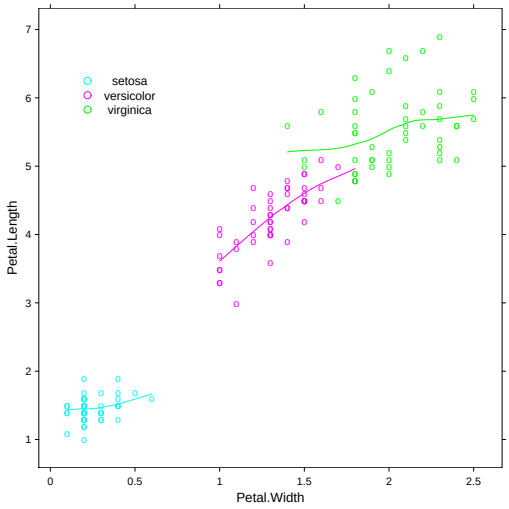

Figure 9: Functia `xyplot` cu setul de date "iris".

```
splom(
  ~iris[1:4], groups = Species, data = iris, xlab = "",
  panel = panel.superpose,
  auto.key = list(columns = 3)
)
```

Principalul argument este de data aceasta o matrice (primele patru coloane ale setului `iris`). Rezultatul este setul de grafice bidimensionale posibile dintre coloanele matricii, ca in cazul functiei `pairs`. In mod implicit, `splom` adauga textul "Scatter Plot Matrix" sub axa x: pentru a evita acest lucru, a fost utilizata optiunea `xlab=""`. Celelalte optiuni sunt similare cu exemplul anterior, cu exceptia `columns = 3` pentru `auto.key` care este specificata astfel incat legenda sa fie afisata pe trei coloane.

Fig. 10 ar putea fi creata cu `pairs()`, insa ultima functie nu poate crea grafice conditionale ca in Fig. 11. Codul utilizat este relativ simplu:

```
splom(~iris[1:3] | Species, data = iris, pscales = 0,
      varnames = c("Sepal\nLength", "Sepal\nWidth", "Petal\nLength"))
```

Intrucat sub-graficele sunt relativ mici, am adaugat doua optiuni pentru a imbunatati lizibilitatea figurii: `pscales = 0` sterge marcajele de pe axe (toate sub-graficele sunt desenate pe aceeasi scala), iar numele variabilelor au fost redefinite pentru a le afisa pe doua linii (`"\n"` codul pentru o linie goala intr-un sir de tip caracter).

Ultimul exemplu foloseste metoda coordonatelor paralele pentru analiza exploratorie a datelor multidimensionale. Variabilele sunt aranjate pe o axa (e.g., the y-axis), iar valorile observate sunt reprezentate pe cealalta axa (variabilele sunt masurate similar, de ex., prin standardizarea lor). Valorile diferite

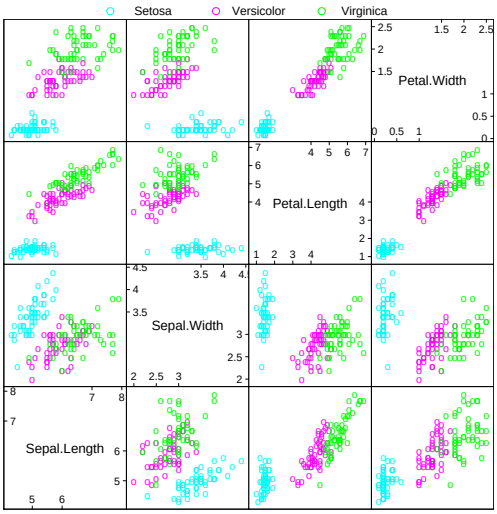

Figure 10: Functia `splom` cu setul de date “iris” (1).

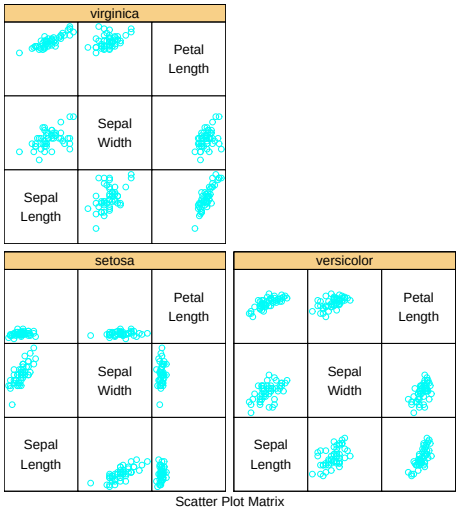

Figure 11: Functia `splom` cu setul de date “iris” (2).

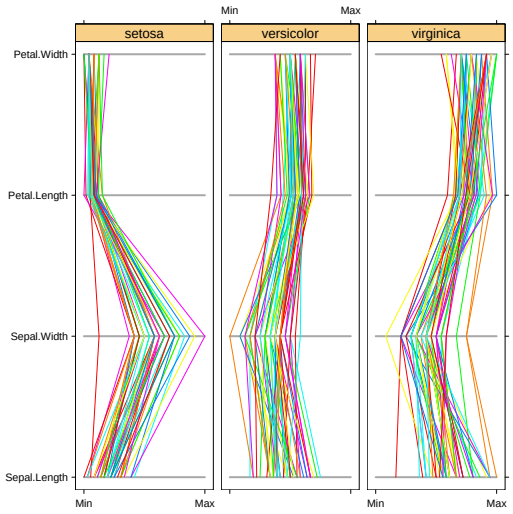

Figure 12: Functia `parallel` cu setul de date “iris”.

ale aceleiasi observatii sunt unite printr-o linie. Folosind setul de date `iris`, Fig. 12 este obtinuta prin urmatorul cod:

```
parallel(~iris[, 1:4] | Species, data = iris, layout = c(3, 1))
```

5 Analiza statistica in R

Mai mult decat crearea de grafice, este imposibil sa avansam in detalierea posibilitatilor oferite de R in privinta analizelor statistice. Scopul este de a oferi cateva referinte pentru a contura o idee asupra particularitatilor R-ului in a efectua analiza de date.

Pachetul stats contine functii pentru o gama larga de analize statistice de baza: teste clasice, modele liniare (inclusiv regresii liniare, modele liniare generalizate si analiza variantei), distributii, sumarizari statistice, clustere ierarhice, analiza seriilor de timp, metoda celor mai mici patrate si analiza statistica multidimensionala. Alte metode statistice sunt disponibile in multe alte pachete. Cateva dintre ele sunt distribuite odata cu instalarea de baza a R-ului si sunt etichetate ca *recommended*, (recomandate) iar multe alte pachete sunt *contributed* (contribuite) si trebuie instalate de catre utilizator.

Vom incepe cu un exemplu simplu care nu cere niciun alt pachet in afara de stats pentru a introduce modalitatea generala de analiza de date in R. Apoi, vom detalia cateva notiuni, *formula* (eng. formulae) si *functii generale* (eng. generic functions), care sunt utile indiferent de tipul de analiza efectuata. Vom incheia cu o prezentare generala a pachetelor.

5.1 Un exemplu simplu de analiza a variantei

Functia pentru analiza variantei in pachetul stats este `aov`. Pentru a o exemplifica, vom considera un set de date distribuite cu R: `InsectSprays`. Sase insecticide au fost testate; variabila de raspuns a fost numarul de insecte. Fiecare insecticid a fost testat de 12 ori, astfel au rezultat 72 de observatii. Nu vom considera explorarea grafica a datelor, insa ne vom focusa pe o simpla analiza a variantei variabilei de raspuns in raport cu insecticidul. Dupa incarcarea datelor din memorie cu functia `data`, analiza este efectuata dupa o extragere de radical a variabilei de raspuns:

```
> data(InsectSprays)
> aov.spray <- aov(sqrt(count) ~ spray, data = InsectSprays)
```

Principalul (si cel obligatoriu) argument al functiei `aov` este o formula care specifica variabila de raspuns in partea stanga a simbolului tilde `~` si variabila independenta in partea dreapta. Optiunea `data = InsectSprays` specifica faptul ca variabilele trebuie sa se afle in secventa de date `InsectSprays`. Aceasta sintaxa este echivalenta cea de mai jos:

```
> aov.spray <- aov(sqrt(InsectSprays$count) ~ InsectSprays$spray)
```

sau cu (in cazul in care cunoastem numerele coloanelor variabilelor):

```
> aov.spray <- aov(sqrt(InsectSprays[, 1]) ~ InsectSprays[, 2])
```

Este de preferat sa utilizam prima sintaxa intrucat este mai clara.

Rezultatele nu sunt afisate din moment ce sunt atribuite obiectului numit `aov.spray`. Apoi vom utiliza cateva functii pentru a extrage rezultatele, spre exemplu `print` pentru a afisa un scurt sumar al analizei (in special parametri estimati) si `summary` pentru a afisa mai multe detalii (inclusiv testele statistice):

```
> aov.spray
Call:
   aov(formula = sqrt(count) ~ spray, data = InsectSprays)

Terms:
                    spray Residuals
Sum of Squares  88.43787  26.05798
Deg. of Freedom        5        66

Residual standard error: 0.6283453
Estimated effects may be unbalanced
> summary(aov.spray)
            Df Sum Sq Mean Sq F value    Pr(>F)
spray        5 88.438  17.688  44.799 < 2.2e-16 ***
Residuals   66 26.058   0.395
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
```

Trebuie amintit ca tastarea numelui unui obiect ca o comanda este similara cu `print(aov.spray)`. O reprezentare grafica a rezultatelor poate fi facuta cu `plot()` sau `termplot()`. Inainte de a tasta `plot(aov.spray)` vom imparti graficele in patru parti astfel incat cele patru grafice diagnostic sa fie create pe acelasi grafic. Comenzile sunt urmatoarele:

```
> opar <- par()
> par(mfcol = c(2, 2))
> plot(aov.spray)
> par(opar)
> termplot(aov.spray, se=TRUE, partial.resid=TRUE, rug=TRUE)
```

iar graficele rezultate se afla in figurile 13 si 14.

5.2 Formulele

Formulele sunt elementul-cheie in analizele statistice in R: notatia utilizata este aceeasi pentru (aproape) toate functiile. O formula este in mod caracteristic de forma `y ~ model` unde `y` este raspunsul analizat si *`model`* este un set de

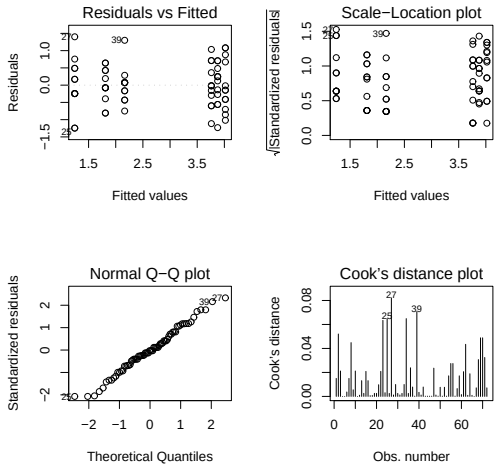

Figure 13: Reprezentarea grafica a rezultatelor functiei `aov` cu `plot()`.

termeni pentru care cativa parametri urmeaza sa fie estimati. Acesti termeni sunt separati cu simboluri aritmetice insa aici au un sens particular.

`a+b`	efectul aditiv al lui `a` si `b`
`X`	daca `X` este o matrice, aceasta specifica un efect aditiv al fiecarei coloane, adica `X[,1]+X[,2]+...+X[,ncol(X)]`; cateva dintre coloane pot fi selectate cu indici numerici (ex., `X[,2:4]`)
`a:b`	efectul de impartire dintre `a` si `b`
`a*b`	efecte aditive si de impartire (identice cu `a+b+a:b`)
`poly(a, n)`	polinomul `a` de gradul n
`^n`	include toate impartirile pana la n, ex. `(a+b+c)^2` este identic cu `a+b+c+a:b+a:c+b:c`
`b %in% a`	efectele lui `b` sunt incluse in `a` (identic cu `a+a:b`, sau `a/b`)
`-b`	sterge efectul lui `b`, de exemplu: `(a+b+c)^2-a:b` este identic cu `a+b+c+a:c+b:c`
`-1`	`y~x-1` este o regresie prin origine (id. pentru `y~x+0` sau `0+y~x`)
`1`	`y~1` adecveaza un model fara efecte (doar termenul liber - eng. intercept)
`offset(...)`	adauga un efect modelului fara a estima vreun parametru (e.g., `offset(3*x)`)

Observam ca operatorii aritmetici din R au sensuri diferite intr-o formula fata de sensul pe care il au in expresii. De exemplu, formula `y~x1+x2` defineste modelul $y = \beta_1 x_1 + \beta_2 x_2 + \alpha$, nu (daca operatorul `+` ar avea sensul obisnuit) $y = \beta(x_1+x_2)+\alpha$. Pentru a include operatiile aritmetice intr-o formula, putem utiliza functia `I`: formula `y~I(x1+x2)` defineste modelul $y = \beta(x_1+x_2)+\alpha$. In

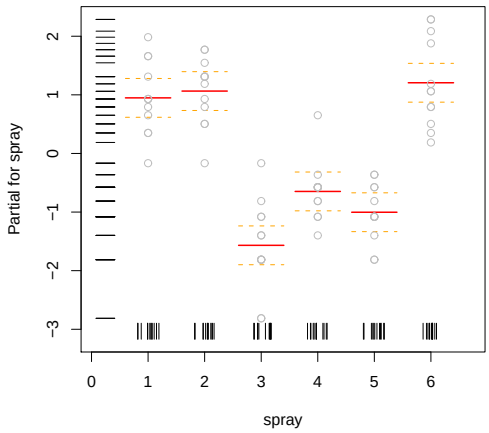

Figure 14: Reprezentarea grafica a rezultatelor functiei `aov` cu `termplot()`.

mod similar, pentru a defini modelul $y = \beta_1 x + \beta_2 x^2 + \alpha$, vom utiliza formula `y ~ poly(x, 2)` (nu `y ~ x + x^2`). In orice caz, este posibila includerea unei functii intr-o formula pentru a transforma o variabila asa cum am vazut mai sus in exemplul cu analiza variantei sprayurilor de insecte.

Pentru analize de variante, `aov()` accepta o sintaxa particulara pentru a defini efectele aleatoare. De exemplu, `y ~ a + Error(b)` se refera la efectele aditive ale termenului fix `a` si ale celui aleator `b`.

5.3 Functii generice

Ne amintim faptul ca functiile R actioneaza asupra atributelor obiectelor posibil trecute ca si argumente. *Clasa* este un atribut care are nevoie de putina atentie aici. Este un lucru obisnuit ca functiile statistice din R sa returneze un obiect cu acelasi nume ca si clasa sa (de ex., `aov` returneaza un obiect de clasa `"aov"`, `lm` returneaza un obiect de clasa `"lm"`). Functiile pe care le putem utiliza ulterior pentru a extrage rezultatele vor actiona asupra clasei obiectului. Aceste functii sunt denumite functii *generice*.

De exemplu, functia utilizata cel mai frecvent pentru a extrage rezultatele din analize este `summary` care afiseaza rezutatele detaliate. Indiferent daca obiectul dat ca argument este de clasa `"lm"` (model liniar) sau `"aov"` (analiza variantei), este evident ca informatia afisata nu va fi aceeasi. Avantajul functiilor generice este ca sintaxa este aceeasi pentru toate clasele.

Un obiect ce contine rezultatele unei analize este in general o lista, iar modul in care este afisat este determinat de clasa lui. Am studiat deja aceasta notiune conform careia actiunea unei functii depinde de tipul de obiect dat

ca argument. Este o caracteristica specifica R[17]. Tabelul urmator prezinta principalele functii generice ce pot fi utilizate pentru a extrage informatia din obiectele rezultate dintr-o analiza. Varianta utilizata in mod obisnuit a acestor functii este:

```
> mod <- lm(y ~ x)
> df.residual(mod)
[1] 8
```

`print`	returneaza un sumar pe scurt
`summary`	returneaza un sumar detaliat
`df.residual`	returneaza numarul rezidual de grade de libertate
`coef`	returneaza coeficientii estimati (uneori cu abaterile standard corespunzatoare)
`residuals`	returneaza reziduurile
`deviance`	returneaza abaterea medie patratica de selectie
`fitted`	returneaza valorile adecvate
`logLik`	calculeaza logaritm din probabilitate si numarul parametrilor
`AIC`	calculeaza criteriul Akaike sau AIC (depinde de `logLik()`)

O functie precum `aov` sau `lm` returneaza o lista cu elemente diferite corespunzatoare rezultatelor analizei. Daca luam exemplul nostru de analiza a variantei cu setul de date `InsectSprays`, putem vedea structura obiectului returnat de `aov`:

```
> str(aov.spray, max.level = -1)
List of 13
 - attr(*, "class")= chr [1:2] "aov" "lm"
```

O alta modalitate de a vizualiza aceasta structura este afisarea numelor obiectului:

```
> names(aov.spray)
 [1] "coefficients"  "residuals"     "effects"
 [4] "rank"          "fitted.values" "assign"
 [7] "qr"            "df.residual"   "contrasts"
[10] "xlevels"       "call"          "terms"
[13] "model"
```

Elementele pot fi apoi extrase asa cum am vazut deja:

```
> aov.spray$coefficients
(Intercept)      sprayB      sprayC      sprayD
  3.7606784   0.1159530  -2.5158217  -1.5963245
     sprayE      sprayF
 -1.9512174   0.2579388
```

[17] Exista peste 100 de functii generice in R.

`summary()` creaza de asemenea o lista care, in cazul `aov()`, este un tabel de teste:

```
> str(summary(aov.spray))
List of 1
 $ :Classes anova  and 'data.frame':    2 obs. of  5 variables:
  ..$ Df     : num [1:2] 5 66
  ..$ Sum Sq : num [1:2] 88.4 26.1
  ..$ Mean Sq: num [1:2] 17.688  0.395
  ..$ F value: num [1:2] 44.8   NA
  ..$ Pr(>F) : num [1:2] 0 NA
 - attr(*, "class")= chr [1:2] "summary.aov" "listof"
> names(summary(aov.spray))
NULL
```

Functiile generice nu actioneaza in general asupra obiectelor: ele apeleaza functia potrivita referitoare la clasa argumentului. O functie apelata de una generica este o *metoda* in jargonul R. In mod schematic, o metoda este construita ca *`generic.cls`*, unde *`cls`* este clasa obiectului. De exemplu, in cazul `summary`, putem afisa metodele corespunzatoare:

```
> apropos("^summary")
 [1] "summary"               "summary.aov"
 [3] "summary.aovlist"       "summary.connection"
 [5] "summary.data.frame"    "summary.default"
 [7] "summary.factor"        "summary.glm"
 [9] "summary.glm.null"      "summary.infl"
[11] "summary.lm"            "summary.lm.null"
[13] "summary.manova"        "summary.matrix"
[15] "summary.mlm"           "summary.packageStatus"
[17] "summary.POSIXct"       "summary.POSIXlt"
[19] "summary.table"
```

Putem observa diferenta pentru aceasta functie generica in cazul unei regresii liniare, comparativ cu analiza variantei, printr-un mic exemplu simulat:

```
> x <- y <- rnorm(5)
> lm.spray <- lm(y ~ x)
> names(lm.spray)
 [1] "coefficients"  "residuals"     "effects"
 [4] "rank"          "fitted.values" "assign"
 [7] "qr"            "df.residual"   "xlevels"
[10] "call"          "terms"         "model"
> names(summary(lm.spray))
 [1] "call"          "terms"         "residuals"
 [4] "coefficients"  "sigma"         "df"
 [7] "r.squared"     "adj.r.squared" "fstatistic"
[10] "cov.unscaled"
```

Tabelul urmator arata cateva functii generice care executa analize suplimentare ale unui obiect rezultat dintr-o alta analiza, principalul argument fiind obiectul din urma, insa in unele cazuri este necesar inca un argument, spre exemplu`predict` sau `update`.

`add1`	testeaza in mod succesiv toti termenii care pot fi adaugati unui model
`drop1`	testeaza in mod succesiv toti termenii care pot fi eliminati dintr-un model
`step`	selecteaza un model cu AIC (apeleaza `add1` si `drop1`)
`anova`	calculeaza tabelul analizei variantei sau abaterea media patratica pentru unul sau mai multe modele
`predict`	calculeaza valorile estimate pentru date noi intr-un model adecvat
`update`	re-adecveaza un model cu o noua formula sau date noi

Exista si cateva functii-utilitate care extrag informatii dintr-un obiect sau formula a unui model, cum ar fi `alias` care gaseste termenii dependenti liniar intr-un model liniar specificat de o formula.

In final, exista bineinteles, functii grafice precum `plot` care afiseaza diverse diagnostice, sau `termplot` (vezi exemplul de mai sus); desi aceasta din urma nu este functie generica, apeleaza `predict`.

5.4 Pachete

Tabelul urmator prezinta pachetele *standard* care sunt distribuite cu instalarea de baza a R. Cateva sunt incarcate in memorie atunci cand R este pornit; aceasta lista se poate afisa cu functia `search`:

```
> search()
[1] ".GlobalEnv"        "package:methods"
[3] "package:stats"     "package:graphics"
[5] "package:grDevices" "package:utils"
[7] "package:datasets"  "Autoloads"
[9] "package:base"
```

Celelalte pachete pot fi utilizate dupa ce sunt incarcate:

```
> library(grid)
```

Lista functiilor dintr-un pachet poate fi afisata cu:

```
> library(help = grid)
```

sau prin rasfoirea suportului in format html. Informatia referitoare la fiecare functie poate fi accesata asa cum am prezentat anterior. (p. 7).

Package	Description
base	functii de baza R
datasets	seturi de date de baza R
grDevices	instrumente grafice pentru grafice de baza si grafice tip retea
graphics	grafice de baza
grid	grafice tip retea
methods	definitia metodelor si claselor pentru obiecte R si instrumente de programare
splines	functii si clase pentru regresia tip "spline"
stats	functii statistice
stats4	functii statistice ce utilizeaza clase S4
tcltk	functii pentru interfata R cu elemente de interfata grafica cu utilizatorul ale Tcl/Tk
tools	instrumente pentru dezvoltarea si administrarea pachetelor
utils	functii utilitare R

Multe pachete *contribuite* sunt adaugate listei de metode de analiza statistica disponibile in R. Ele sunt distribuite separat si trebuie instalate si incarcate in R. Lista completa a pachetelor contribuite, cu descrierile corespunzatoare, este disponibila pe site-ul CRAN [18]. Cateva dintre aceste pachete sunt *recomandate* intrucat acopera metodele statistice frecvent utilizate in analiza de date. Pachetele recomandate sunt deseori distribuite cu instalarea de baza a R. Ele sunt descrise pe scurt in tabelul urmator.

Pachet	Descriere
boot	metode de re-esantionare si bootstraping
class	metode de clasificare
cluster	metode de clustering
foreign	functii pentru citirea datelor stocate in diferite formate (S3, Stata, SAS, Minitab, SPSS, Epi Info)
KernSmooth	metode pentru liniarizare kernel si estimarea densitatii (inclusiv kernel-uri bidimensionale)
lattice	Grafice tip retea (Trellis)
MASS	contine multe functii, instrumente si seturi de date din bibliotecile "Statistica moderna aplicata cu S" de Venables & Ripley
mgcv	modele aditive generalizate
nlme	modele liniare si neliniare de efecte mixte
nnet	retele neurale si modele logistice liniare multinomiale
rpart	partitionare recursiva
spatial	analize spatiale ("kriging", covarianta spatiala, ...)
survival	analiza datelor de supravietuire

[18] http://cran.r-project.org/src/contrib/PACKAGES.html

Exista alte doua colectii principale de pachete R: Omegahat Project for Statistical Computing[19] care se axeaza pe aplicatii web-based si interfete intre software-uri si limbaje, si Bioconductor Project[20] specializat in aplicatii bioinformatice (in special pentru analiza micro-datelor).

Procedura de instalare a unui pachet depinde de sistemul de operare si de tipul de instalare a R - din surse sau fisiere binare precompilate. In situatia din urma, este recomandata utilizarea pachetelor pre-compilate disponibile pe website-ul CRAN. In Windows, fisierul binar Rgui.exe are un meniu numit "Packages" ce permite instalarea pachetelor prin internet de pe website-ul CRAN, sau din fisiere tip arhiva de pe diskul local.

Daca R a fost compilat, un pachet poate fi instalat din sursa sa care este distribuita ca un fisier cu extensia '.tar.gz'. Spre exemplu, daca dorim sa instalam pachetul `gee`, vom descarca intai fisierul gee_4.13-6.tar.gz (numarul 4.13-6 indica versiunea pachetului; in general este disponibila pe CRAN o singura versiune). Vom tasta apoi in sistem (nu in R) comanda:

```
R CMD INSTALL gee_4.13-6.tar.gz
```

Exista cateva functii generale utile pentru a gestiona pachetele, cum ar fi: `installed. packages`, `CRAN.packages`, sau `download.packages`. De asemnenea este util sa tastam frecvent comanda:

```
> update.packages()
```

care verifica versiunile pachetelor instalate cu cele disponibile pe CRAN (aceasta comanda poate fi apelata din meniul "Packages" in Windows). Utilizatorul poate apoi sa actualizeze pachetele cu versiuni mai recente decat cele instalate pe computer.

[19] http://www.omegahat.org/R/
[20] http://www.bioconductor.org/

6 Programarea cu R in pratica

Acum, dupa ce am prezentat o vedere de ansamblu asupra functionalitatilor R-ului, ne vom intoarce la limbaj si programare. Vom vedea cateva idei simple care pot fi utilizate in practica.

6.1 Bucle si vectorizari

Un avantaj al lui R fata de alte software-uri cu meniuri pull-down menus este posibilitatea programarii seriilor de analize simple care vor fi executate in mod succesiv. Acest aspect este comun tuturor limbajelor de calculatoare, insa R are cateva caracteristici particulare ce fac programarea mai usoara pentru non-specialisti.

Ca si alte limbaje, R are cateva *structuri de control* care sunt diferite fata de cele din limbajul C. Sa presupunem ca avem un vector `x`, si pentru fiecare element al lui `x` cu valoarea `b`, dorim sa atribuim valoarea 0 unei alte variabile `y`, altfel 1. Vom crea intai un vector `y` de aceeasi lungime cu `x`:

```
y <- numeric(length(x))
for (i in 1:length(x)) if (x[i] == b) y[i] <- 0 else y[i] <- 1
```

Cateva instructiuni pot fi executate daca sunt plasate in interiorul acoladelor:

```
for (i in 1:length(x)) {
    y[i] <- 0
    ...
}

if (x[i] == b) {
    y[i] <- 0
    ...
}
```

O alta situatie posibila este executarea unei instructiuni cat timp o anumita conditie este adevarata:

```
while (myfun > minimum) {
    ...
}
```

Cu toate acestea, buclele si structurile de control pot fi evitate in majoritatea situatiilor datorita unei caracteristici a R-ului: *vectorizarea*. Vectorizarea face ca buclele sa fie implicite in expresie, si exista multe cazuri pentru a ilustra acest lucru. Vom considera adunarea a doi vectori:

```
> z <- x + y
```

Aceasta adunare poate fi scrisa cu o bucla, asa cum este posibil in majoritatea limbajelor:

```
> z <- numeric(length(x))
> for (i in 1:length(z)) z[i] <- x[i] + y[i]
```

In acest caz, este necesar sa cream in prealabil un vector `z` datorita utilizarii sistemului de indexare. Realizam ca aceasta bucla explicita va functiona doar daca `x` si `y` au aceeasi lungime: trebuie schimbat daca aceasta conditie nu este indeplinita, cu toate ca prima expresie va functiona in toate situatiile.

Executiile conditionale (`if ... else`) pot fi evitate prin utilizarea indexarii logice; ne vom intoarce la exemplul anterior:

```
> y[x == b] <- 0
> y[x != b] <- 1
```

In afara de faptul ca sunt mai simple, expresiile vectorizate sunt mai eficiente din punct de vedere al computerizarii, in special pentru date de dimensiuni mari.

Exista si cateva functii de tipul 'apply' care evita scrierea buclelor. `apply` actioneaza asupra randurilor si/sau coloanelor unei matrici, sintaxa sa fiind `apply(X, MARGIN, FUN, ...)`, unde `X` este o matrice, `MARGIN` arata daca se considera randurile (`1`), coloanele (`2`), sau ambele (`c(1, 2)`), `FUN` este o functie (sau un operator, insa in acest caz trebuie specificat in paranteze) pentru aplicare, iar `...` sunt alte argumente optionale pentru `FUN`. In cele ce urmeaza prezentam un exemplu simplu.

```
> x <- rnorm(10, -5, 0.1)
> y <- rnorm(10, 5, 2)
> X <- cbind(x, y)  # the columns of X keep the names "x" and "y"
> apply(X, 2, mean)
        x         y
-4.975132  4.932979
> apply(X, 2, sd)
        x         y
0.0755153 2.1388071
```

`lapply()` actioneaza asupra unei liste: sintaxa sa este similara cu cea a functiei`apply` si returneaza o lista.

```
> forms <- list(y ~ x, y ~ poly(x, 2))
> lapply(forms, lm)
[[1]]

Call:
```

```
FUN(formula = X[[1]])

Coefficients:
(Intercept)            x
     31.683        5.377


[[2]]

Call:
FUN(formula = X[[2]])

Coefficients:
(Intercept)  poly(x, 2)1  poly(x, 2)2
     4.9330       1.2181      -0.6037
```

`sapply()` este o varianta flexibila a functiei `lapply()`, care poate avea ca argument un vector sau o matrice, si returneaza rezultatul intr-o forma mai prietenoasa pentru utilizator, in general un tabel.

6.2 Scrierea unui program in R

In mod caracteristic, un program R este scris intr-un fisier salvat in format ASCII si denumit cu extensia '.R'. O situatie tipica in care un program este necesar este atunci cand utilizatorul doreste sa execute aceleasi secvente de instructiuni de cateva ori. In primul nostru exemplu, dorim sa cream acelasi grafic pentru trei specii diferite de pasari, datele aflandu-se in trei fisiere diferite. Vom proceda pas cu pas si vom vedea diferite moduri de a programa aceasta problema simpla.

In primul rand, vom crea programul nostru in cel mai intuitiv mod prin executarea in mod sucesiv a comenzilor necesare, avand grija sa impartim in prealabil instrumentul grafic.

```
layout(matrix(1:3, 3, 1))              # partition the graphics
data <- read.table("Swal.dat")         # read the data
plot(data$V1, data$V2, type="l")
title("swallow")                       # add a title
data <- read.table("Wren.dat")
plot(data$V1, data$V2, type="l")
title("wren")
data <- read.table("Dunn.dat")
plot(data$V1, data$V2, type="l")
title("dunnock")
```

Caracterul '#' este utilizat pentru a adauga comentarii intr-un program: R va trece apoi la linia urmatoare.

Problema acestui program este ca poate deveni destul de lung daca dorim sa adaugam alte specii. Mai mult decat atat, cateva comenzi sunt executate de cateva ori, astfel ca pot fi grupate impreuna si executate dupa schimbarea catorva argumente. Strategia aplicata aici este atribuirea acestor argumente unor vectori de tip caracter, si utilizarea indecsilor pentru accesarea acestor valori diferite.

```
layout(matrix(1:3, 3, 1))                # partition the graphics
species <- c("swallow", "wren", "dunnock")
file <- c("Swal.dat" , "Wren.dat", "Dunn.dat")
for(i in 1:length(species)) {
    data <- read.table(file[i])          # read the data
    plot(data$V1, data$V2, type="l")
    title(species[i])                    # add a title
}
```

De remarcat ca aici nu exista ghilimele inainte si dupa `file[i]` in `read.table()` din moment ce acest argument este de tip caracter.

Programul nostru este acum mai compact. Este mai simplu sa adaugam alte specii din moment ce vectorii ce contin speciile si numele fisierelor se afla la inceputul programului.

Programele de mai sus vor functiona corect daca fisierele de date '.dat' sunt localizate in folderul de lucru al R, altfel utilizatorul trebuie fie sa schimbe folderul de lucru, fie sa specifice calea in program (spre exemplu: `file <- "/home/paradis/data/Swal.dat"`). Daca programul este scris in fisierul Mybirds.R, va fi apelat prin tastarea urmatoarei comenzi:

```
> source("Mybirds.R")
```

Ca pentru orice date de intrare provenite dintr-un fisier, este necesar sa specificam calea de acces daca fisierul nu se afla in folderul de lucru

6.3 Scrierea functiilor proprii

Am constatat deja ca majoritatea executiilor in R sunt facute prin functii ale caror argumente sunt trecute intre paranteze. Utilizatorii pot scrie propriile lor functii, iar acestea vor avea exact aceleasi proprietati ca celelalte functii din R.

Scrierea propriilor functii permite o utilizare eficienta, flexibila si rationala a R-ului. Ne vom intoarce la exemplul nostru de citire a catorva date urmate de reprezentare grafica. daca dorim sa facem aceasta operatie in situatii diferite, poate fi o idee buna sa scriem o functie:

```
myfun <- function(S, F)
{
    data <- read.table(F)
```

```
    plot(data$V1, data$V2, type="l")
    title(S)
}
```

Pentru a fi executata, aceasta functie trebuie sa fie incarcata in memorie, iar aceasta se poate realiza in cateva moduri. Liniile functiei pot fi introduse direct din tastatura, ca orice alta comanda, sau copiate cu copy-paste dintr-un editor. Daca functia a fost salvata intr-un fisier text, poate fi incarcata cu `source()` ca orice alt program. Daca utilizatorul doreste sa incarce cateva functii de fiecare data cand R este lansat, acestea pot fi salvate intr-un spatiu de lucru `.RData` care va fi incarcat in memorie daca se afla in folderul de lucru. O alta posibilitate este de a configura fisierul '.Rprofile' sau 'Rprofile' (vezi `?Startup` pentru detalii). In cele din urma, este posibila crearea unui pachet, insa acest aspect nu va fi prezentat aici (vezi manualul "Writing R Extensions").

Odata ce functia este incarcata, vom putea sa citim datele si sa le reprezentam grafic printr-o singura comanda, spre exemplu cu `myfun("swallow", "Swal.dat")`. Astfel, avem acum o a treia versiune a programului nostru:

```
layout(matrix(1:3, 3, 1))
myfun("swallow", "Swal.dat")
myfun("wren", "Wrenn.dat")
myfun("dunnock", "Dunn.dat")
```

Putem utiliza de asemenea `sapply()`, ceea ce conduce la a patra versiune a programului:

```
layout(matrix(1:3, 3, 1))
species <- c("swallow", "wren", "dunnock")
file <- c("Swal.dat" , "Wren.dat", "Dunn.dat")
sapply(species, myfun, file)
```

In R, nu este necesara declararea variabilelor utilizate in cadrul functiei. Atunci cand o functie este executata, R utilizeaza o regula denumita *domeniu lexic - eng. lexical scoping* pentru a decide daca un obiect este local functiei sau global. Pentru a intelege acest mecanism, vom considera functia simpla de mai jos:

```
> foo <- function() print(x)
> x <- 1
> foo()
[1] 1
```

Denumirea `x` nu este utilizata pentru a crea un obiect in cadrul `foo()`, asa incat R va cauta in mediul *propriu* daca exista un obiect denumit `x`, si va afisa valoarea sa (altfel, un mesaj de eroare este afisat, iar executia este intrerupta).

Daca `x` este utilizat ca nume al unui obiect in cadrul unei functii, valoarea lui `x` nu este utilizata in mediul global.

```
> x <- 1
> foo2 <- function() { x <- 2; print(x) }
> foo2()
[1] 2
> x
[1] 1
```

De aceasta data `print()` utilizeaza obiectul `x` care este definit in cadrul mediului sau, adica a mediului `foo2`.

Cuvantul "*propriu*" de mai sus este important. In cele doua functii date ca exemplu, exista *doua* medii: cel global si cel al functiei `foo` sau `foo2`. Daca sunt trei sau mai multe medii in serie, cautarea obiectelor este facuta progresiv de la un anumit mediu la cel propriu, si asa mai departe, pana la cel global.

Sunt doua moduri de specificare a argumentelor unei functii: dupa pozitiile lor sau dupa numele lor (numite si *argumente caracterizate*). De exemplu, vom considera o functie cu trei argumente:

```
foo <- function(arg1, arg2, arg3) {...}
```

`foo()` poate fi executata fara a utiliza numele `arg1`, ..., daca obiectele corespunzatoare sunt plasate in pozitia corecta, de exemplu: `foo(x, y, z)`. In orice caz, pozitia nu are importanta daca numele argumentelor sunt utilizate, de ex. `foo(arg3 = z, arg2 = y, arg1 = x)`. O alta caractristica a functiilor R-ului este posibilitatea utilizarii valorilor implicite in definitiile lor. Spre exemplu:

```
foo <- function(arg1, arg2 = 5, arg3 = FALSE) {...}
```

Comenzile `foo(x)`, `foo(x, 5, FALSE)`, si `foo(x, arg3 = FALSE)` vor avea exact acelasi rezultat. Utilizarea valorilor implicite in definitia unei functii este folositoare, in special atunci cand se folosesc argumente caracterizate (de ex. schimbarea unei singure valori implicite cum ar fi `foo(x, arg3 = TRUE)`).

Pentru a conclude aceasta sectiune, vom vedea un alt exemplu care nu este pur statistic, insa ilustreaza flexibilitatea R-ului. Consideram ca dorim sa studiem comportamentul unui model neliniar: modelul lui Ricker definit de:

$$N_{t+1} = N_t \exp\left[r\left(1 - \frac{N_t}{K}\right)\right]$$

Acest model este larg utilizat in dinamica populatiei, in special in cea a pestilor. Utilizand o functie, dorim sa simulam acest model cu privire la rata cresterii r si numarul initial al populatiei N_0 (capacitatea maxima K este adesea egala cu 1 iar aceasta valoare va fi luata ca implicita); rezultatele vor fi afisate ca grafic de numere raportate la timp. Vom adauga o optiune pentru a permite utilizatorului sa afiseze doar numerele in ultimii cativa pasi (in mod implicit toate rezultatele vor fi reprezentate grafic). Functia de mai jos poate executa aceasta analiza numerica a modelului Ricker.

```
ricker <- function(nzero, r, K=1, time=100, from=0, to=time)
{
    N <- numeric(time+1)
    N[1] <- nzero
    for (i in 1:time) N[i+1] <- N[i]*exp(r*(1 - N[i]/K))
    Time <- 0:time
    plot(Time, N, type="l", xlim=c(from, to))
}
```

Incercati cu:

```
> layout(matrix(1:3, 3, 1))
> ricker(0.1, 1); title("r = 1")
> ricker(0.1, 2); title("r = 2")
> ricker(0.1, 3); title("r = 3")
```

7 Literatura de specialitate R

Manuale. Cateva manuale sunt integrate in R_HOME/doc/manual/:

- *An Introduction to R* [R-intro.pdf],
- *R Installation and Administration* [R-admin.pdf],
- *R Data Import/Export* [R-data.pdf],
- *Writing R Extensions* [R-exts.pdf],
- *R Language Definition* [R-lang.pdf].

Fisierele pot fi in formate diferite (pdf, html, texi, ...) in functie de tipul instalarii.

FAQ. R este distribuit si cu sectiunea FAQ (*Frequently Asked Questions*) localizata in folderul R_HOME/doc/html/. O versiune a R-FAQ este in mod regulat actualizata pe site-ul CRAN:

http://cran.r-project.org/doc/FAQ/R-FAQ.html

Resurse on-line Site-ul CRAN Web gazduieste cateva documente, resurse bibliografice si linkuri catre alte site-uri. Exista si o lista de publicatii (carti si articole) despre R sau metode statistice[21] si cateva documente si tutoriale scrise de catre utilizatorii R [22].

Liste de adrese Exista patru liste de discutii despre R; pentru a va abona, a trimite un mesaj, sau a citi arhivele accesati: http://www.R-project.org/mail.html.

Lista generala de discutii 'r-help' este o sursa interesanta de informatii pentru utilizatorii R (celelalte trei liste sunt dedicate anuntarilor de noi versiuni si sunt pentru dezvoltatori). Multi utilizatori au trimis catre 'r-help' functii sau programe care pot fi gasite in arhive. Daca intampinati o problema in R, este important sa parcurgeti urmatorii pasi inainte de a trimite un mesaj catre 'r-help':

1. cititi cu atentie suportul on-line (utilizand motorul de cautare);
2. cititi R-FAQ;
3. cautati in arhivele 'r-help' la adresa mai sus mentionata, sau utilizand unul dintre motoarele de cautare dezvoltate pe cateva site-uri[23];
4. cititi "ghidul de postare"[24] inainte de a trimite o intrebare.

[21] http://www.R-project.org/doc/bib/R-publications.html
[22] http://cran.r-project.org/other-docs.html
[23] Adresele acestor site-uri sunt enumerate la http://cran.r-project.org/search.html
[24] http://www.r-project.org/posting-guide.html

R News. Jurnalul electronic *R News* isi propune sa fie o punte de legatura intre listele de discutii electronice si publicatiile stiintifice traditionale. Prima editie a fost publicata in ianuarie 2001[25].

Citarea R intr-o publicatie Daca doriti sa faceti referire catre R intr-o publicatie, trebuie sa citati urmatoarea referinta:

> R Development Core Team (2005). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, URL: http://www.R-project.org.

[25] http://cran.r-project.org/doc/Rnews/