Einführung in die Statistik-Umgebung R

Erste Kapitel, im Aufbau. Deutsch mit einigen englischen Abschnitten

Werner Stahel, Seminar für Statistik

ETH Zürich

September 2009

© Reproduktion für kommerzielle Zwecke
nur mit schriftlicher Bewilligung des Seminars für Statistik

Diese Unterlagen führen in die Statistik-Sprache S ein, die dem kommerziellen Programm S-Plus und der freien Software R zugrunde liegt. Da sich die Einführung nur auf die grundlegenden Strukturen bezieht, gilt das meiste hier Geschriebene für beide Implementationen.

Für den Zertifikatskurs in angewandter Statistik existieren weiterführende Unterlagen, die für die Themen der Blöcke jeweils die nützlichen Funktionen beschreiben.

Inhalt

1 Introduction **1**

1.1 What is R? 1

1.2 Other Statistical Software 1

1.3 Ziele 2

1.4 Einführende Beispiele 2

1.5 Using R 3

1.6 Scripts and Editors 5

2 Grundlagen **7**

2.1 Vektoren 7

2.2 Arithmetik 8

2.3 Vektoren von Text 9

2.4 Logische Vektoren 9

2.5 Elemente auswählen 10

2.6 Matrizen 11

3 Einfache Statistik **14**

3.1 Einfache Statistik-Funktionen 14

3.2 Tests 15

3.3 Modell-Formeln 16

4 Graphics **17**

4.1 Overview 17

4.2 Scatterplot 17

4.3 Boxplot 19

4.4 Adding Points and Lines to a Plot 19

4.5 Adding Text to a Plot 20

4.6 Interacting with a Plot 21

1 Introduction

1.1 What is R?

- R is a software environment for statistical data analysis.
- R is based on commands to be typed. It implements a programming language, called the **S language**, which was developped for efficient statistical data analysis and for implementing statistical methods with limited effort.
- There is an inofficial **menu based interface** called R-Commander, which contains a collection of basic statistical methods. It may be expanded by more advanced users to include methods used in their environment. This interface generates commands and submits them to the system. We will not use it here since our goal is to enable the reader to do more flexible analyses.
- **Menus** have the drawback that it is difficult to store or remember which buttons have to be pushed to get a certain result. **Commands** can be stored and thereby be used to document the analysis and allow for easy repetition with changed data, options, or other variations.
- R is **free software,** available from `http://www.r-project.org` and maintained for the operating systems Linux, Mac OS X, Windows. Therefore, every one man consulting service ...
- ... and every student and researcher who has no guts to write applications for money to purchase and maintain the system. It has therefore become **the language for exchanging new methods among researchers**. It gives everybody access to the newly developed tools.

1.2 Other Statistical Software

- **S-Plus:** This system is also based on the S language. There are differences, however, such that one could say that S-Plus and R are two dialects of this language. S-Plus is commercial, which makes it more attractive for companies who want to buy support. It features a menu system, which is another advantage if it should be a standard software for a wide range of users.
- **SPSS:** This system is well known and highly developed. It contains a large collection of standard procedures, and several more advanced ones in the direction of social sciences.
- **SAS:** This is the classical, large statistical package – also the most expensive general package. It has developped into management of data bases and other general computer tasks. It handles large data sets, and is sometimes best for complicated analyses.

- **Systat:** Analysis of Variance, easy-to-use graphics system.
- There are many more packages, e.g. several that are common in econometrics.
- **Excel** also contains statistical methods, but they are quite limited. We do not recommend to start statistical analyses in Excel. It can profitably be used to get the dataset ready.
- **Matlab** is a system for mathematical calculations. The statistical methods are limited in both content and implementation quality. The "paradigm" is very similar to the S language, as it implements a kind of language that has similar structure as the S language but is less flexible and misses useful concepts.

1.3 Ziele

a !!!

b Some introductions into R or the S language go through the different concepts in a systematic way according to the structure of the language. These notes aim at starting from those notions that are needed in practice first to achieve useful results immediately. Therefore, we first introduce how a dataset is represented in R – even though this is in fact a rather complicated structure – but postpone an exact description of the concept until later. Thus, common ways to use the system can be practiced from the start, and complications are discussed only when needed. If you prefer a more mathematical, systematic treatment, you should find other introductory texts on the web. Those documentations will also be useful as systematic references once you have worked through this script.

c The participants and readers should be able to conduct statistical analyses as they will know how to handle R and how to get the necessary information for finding and using specific methods. They should have the basic knowledge for exploiting the flexibility of the system by programming and writing their own functions.

1.4 Einführende Beispiele

a **Daten, data.frame.** Statistische Auswertungen gehen in den meisten Fällen von einer „Datentabelle" oder **Datenmatrix** aus. In einer Zeile dieser Tabelle stehen die Werte aller **Variablen** (oder Merkmale), die zu einer **Beobachtung** gehören. In S sind sie in einem so genannten `data.frame` gespeichert. Die Variablen können numerisch (quantitativ) oder nominal (kategorial) sein (oder sogar komplexe Zahlen).

b **Daten einlesen.** Um den ersten Datensatz für das System verfügbar zu machen, rufen wir die S-Funktion `read.table` auf. Der Befehl

```
> d.sport <- read.table(
    "http://stat.ethz.ch/Teaching/Datasets/WBL/sport.dat",header=TRUE)
```

liest die Daten der Textdatei "sport.dat" von der angegebenen Internetseite und speichert sie unter dem Namen `d.sport` ab.

Mit diesem Befehl greifen Sie über das Internet direkt auf den vom Seminar für Stati-

c **Datensatz** `d.sport` Nun tippen wir

```
> d.sport
```

in die R-Console. Dann erscheint auf dem Bildschirm

```
           weit kugel hoch  disc stab speer punkte
OBRIEN     7.57 15.66  207 48.78  500 66.90   8824
BUSEMANN   8.07 13.60  204 45.04  480 66.86   8706
DVORAK     7.60 15.82  198 46.28  470 70.16   8664
:          :    :      :   :      :   :       :
:          :    :      :   :      :   :       :
:          :    :      :   :      :   :       :
CHMARA     7.75 14.51  210 42.60  490 54.84   8249
```

d **Eine Variable auswählen**

```
> d.sport[,"kugel"]
```

wählt die Variable "kugel" aus. (Die eckigen Klammern wählen Teile von data.frames und anderen „Objekten " aus.

e **Ein Histogramm.** Die Funktion `hist` zeichnet ein Histogramm in ein Grafik-Fenster:

```
> hist(d.sport[,"kugel"])
```

Im R wird ein solches Fenster automatisch geöffnet, wenn noch keines „aktiv" ist. (In älteren S-Plus-Versionen müsste man eine Funktion aufrufen, z.B. `wingraph()` oder `motif()`.)

f **Streudiagramme.** Eine der grundlegendsten grafischen Darstellungen ist sicher das Streudiagramm.

```
> plot(d.sport[,"kugel"], d.sport[,"speer"])
```

trägt die Werte der Variablen `kugel` in x-Richtung und `speer` in y-Richtung auf.

g **Streudiagramm-Matrix.**

```
> pairs(d.sport)
```

erzeugt eine ganze Matrix von Streudiagrammen nach dem Prinzip „jede Variable der Datenmatrix `d.sport` gegen jede ".

1.5 Using R

a Let us resume basic characteristics of using R.

- Within a window running R, you will see the prompt >. You type a command and get a result and a new prompt.

stik für den Weiterbildungslehrgang zur Verfügung gestellten Datensatz „sport.dat" zu. Sie könnten den Datensatz auch zuerst auf Ihrer Hard-Disc speichern – indem Sie ihn auf der Webseite anklicken und dann mittels `Datei/Speichern` an einem geeigneten Ort, z. B. in einem Ordner `C:/EigeneDateien/Datasets` ablegen. Der Befehl zum Einlesen des Datensatzes lautet dann: `d.sport <- read.table("C:/EigeneDateien/Datasets/sport.dat", header=TRUE)`.

An incomplete statement can be continued on the next line
```
> plot(d.sport[,"kugel"],
+ d.sport[,"speer"])
```

- R stores **"objects"** in your **"workspace"**:
  `> d.sport <- read.table(...)`
  defines the object `d.sport`. More specifically, `d.sport` is a "**data.frame**".

- Objects have names like `a, fun, d.sport` . Names start by a letter and are continued by letters or digits. The dot (.) and underscore (_) are treated like letters. Blanks and special characters terminate the name. Upper and lower case letters are distinct.

  There are, of course, some reserved names, like `if`, `for`, `break`. The system will issue an error message if you try to use one of them to store your own stuff. Then, there are some hazards: You can overwrite basic functions or constants (as by `pi <- 5`).

- R provides a huge number of functions and other objects. This is the treasure! There are many functions which are part of the "core system", and even more which are provided by advanced users in so-called "packages" – and remain under their responsibility. We will come back to this point later.

b An R statement consists of

- a name of an object only. This makes the system display the object.

- a call to a function or an arithmetic expression. This leads to a graphical or numerical result (or sometimes to a "side effect" like changing an option).

- an assignment, consisting of a name, the arrow `<-`, and a call to a function or arithmetic expression
  ```
  > a <- 2*pi/360
  > mn <- mean(d.sport[,"kugel"])
  ```
  stores the mean of `d.sport[,"kugel"]` under the name `mn`.
  Note. The assignment can be denoted by `=`, but we do not recommend this since it may lead to confusion.

c **Funktions-Aufruf.** Funktions-Aufrufe sind das zentrale Geschäft der Datenanalyse mit S.

Funktionen haben **obligatorische Argumente**, die das Programm braucht, um etwas Sinnvolles zu tun, beispielsweise die Daten, die benützt werden sollen. Zusätzlich gibt es meistens **freiwillige Argumente**. Werden diese weggelassen, so rechnet das Programm mit festgelegten, sinnvollen „Weglasswerten", so genannten Defaults. Durch die Angabe von freiwilligen Argumenten können die festgelegten Defaults variiert werden. Beispielsweise kennt `hist` ein freiwilliges Argument `nclass`.

```
> hist(d.sport[,"kugel"], nclass=10)
```

produziert ein Histogramm mit ungefähr 10 Klassen.

d **Help.** Wir wollen die Argumente der Funktionen nicht auswendig lernen. Wenn man

```
> help(hist)
```

oder

```
> ?hist
```

eintippt, erscheint in einem Fenster eine Beschreibung der Funktion `hist` und all ihrer Argumente – allerdings mit viel Jargon, den Sie noch nicht verstehen müssen.

Oft hilft es, sich das Beispiel anzusehen, das auf der Help-Seite angeführt wird. Man kann das in R automatisch ausführen mit

```
> example(hist)
```

e **Objekte.** Mit der Zeit werden sich in Ihrem "workspace" immer mehr Objekte ansammeln, die Sie gespeichert haben. Eine Liste ihrer Namen erhalten Sie mit
`> objects()`
Wenn Sie eines oder einige löschen möchten (`a1` und `data`), schreiben Sie
`> rm(a1, data)`
Man kann auch viele aufs Mal löschen, siehe später.

f **Session beenden.** Tippen Sie

```
> q()
```

bevor Sie den Computer abschalten. Das System fragt: `Save workspace image?` Wenn Sie `y` antworten, werden Ihnen in der nächsten Session alle „Objekte", die Sie in dieser Session erzeugt haben, wieder zur Verfügung stehen – und das ist wohl für die Übungen gut so. Antworten Sie also `y`. Bei Datenanalysen ist es nicht unbedingt empfehlenswert, siehe später.

1.6 Scripts and Editors

a Instead of typing commands into the R window, you can generate commands by an **editor** and then "send" them to the R window – and later modify (correct) them and send again.

b **Text Editors supporting R.** The following editors support the use of R by supplying "buttons" to send the current line or the marked region of text to the R window.

- WinEdt: http://www.winedt.com/
- Emacs: http://www.gnu.org/software/emacs/, enhanced by
  ESS: http://stat.ethz.ch/ESS/
- Tinn-R: http://www.sciviews.org/Tinn-R/ . This editor is used in the exercises done in class.
- For Mac: ...

c The Tinn-R Window

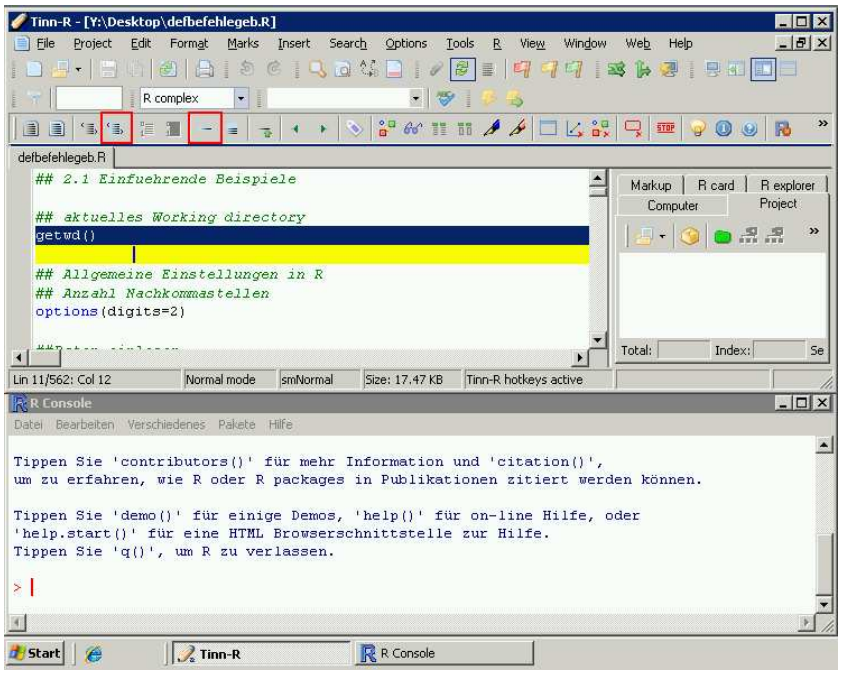

2 Grundlagen

2.1 Vektoren

a **Vektoren erzeugen.** Ein Vektor ist eine Zusammenfassung von Zahlen zu einem Objekt. Wir haben oben `d.sport[,"kugel"]` benützt. Hier speichern wir diese Variable hier als `t.v` ab.

```
> t.v  <- d.sport[,"kugel"]
> t.v
[1] 15.66 13.60 15.82 15.31 16.32 14.01 13.53 14.71 16.91 15.57 14.85
[12] 15.52 16.97 14.69 14.51
```

zeigt die Werte der Variablen `kugel` für alle Beobachtungen. Die Zahlen in eckigen Klammern am Anfang der Zeilen geben an, dem wie vielten Element des Vektors die erste Zahl auf der Zeile entspricht; 15.52 ist also der Wert der 12. Beobachtung.

b Man kann einem Vektor auch direkt Werte zuweisen, und zwar mit der Funktion `c` (concatenate):

```
> t.a  <- c(3.1, 5, -0.7, 0.9, 1.7)
```

(Die Funktion `c` folgt nicht dem üblichen Schema der Argumente: Man kann beliebig viele Argumente eingeben; sie werden alle zusammengehängt zum Resultat.)

c Die **Funktion** `seq` erzeugt Zahlenfolgen mit gleicher Differenz,

```
> seq(0,3,by=0.5)
[1]  0.0  0.5  1.0  1.5  2.0  2.5  3.0
```

Für die wichtigsten Folgen dieser Art – aufeinanderfolgende ganze Zahlen – gibt es das spezielle Zeichen `:`

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

ist das Gleiche wie `seq(1,9,by=1)` oder `seq(1,9)`.

d Die **Funktion** `rep` erzeugt Vektoren mit immer wieder gleichen Zahlen. Die einfachste Version ist

```
> rep(0.7,5)
[1]  0.7  0.7  0.7  0.7  0.7
```

Es geht aber auch flexibler,

```
> rep(c(1,3,5),length=8)
[1]  1  3  5  1  3  5  1  3
```

e Nun soll für solche Vektoren auch etwas ausgewertet werden. Tabelle 2.1.e zeigt einige Funktionen, die auf numerische Vektoren anwendbar sind.

Aufruf, Beispiel	Bedeutung
`length(t.v)`	Länge, Anzahl Elemente
`rev(t.v)`	umgekehrte Reihenfolge
`sort(t.v)`	(aufsteigend) sortierte Elemente
`rank`	Ränge der Elemente
`unique`	alle verschiedenen Elemente
`sum(t.v)`	Summe aller Elemente
`cumsum(t.v)`	Kumulative Summen
`mean(t.v)`	arithmetisches Mittel der Elemente
`var(t.v)`	empirische Varianz
`range(t.v)`	Wertebereich

Tabelle 2.1.e: Wichtige Funktionen für numerische Vektoren

2.2 Arithmetik

a Selbstverständlich kann man mit S auch rechnen,

```
> 2+5
[1]  7
```

Die Grundoperationen heissen `+ , - , * , /` . Das Zeichen ^ bedeutet „hoch“.

b Auf Vektoren werden die Operationen **elementweise** angewandt,

```
> (2:5) ^ c(2,3,1,0)
[1]   4  27  4  1
```

Die **Prioritäten** der Operationen sind die üblichen. Klammern setzen ist im Zweifelsfall sehr nützlich.

c Der eine der beiden Operanden kann nur eine Zahl sein,

```
> (2:5) ^ 2
[1]   4   9  16   25
```

Sind beide Operanden Vektoren, aber von unterschiedlicher Länge, so wird der kürzere auf die Länge des längeren gebracht, indem er zyklisch wiederverwendet wird,

```
> (1:5)-(0:1)
[1] 1 1 3 3 5
```

Weil es hier nicht aufgeht, produziert S die Warnung,

```
Warning message:
longer object length is not a multiple of shorter object length in:
(1:5) - (0:1)
```

(Das kann nützlich sein – ungeschickt, wenn es zufälligerweise aufgeht und die Warnung nützlich gewesen wäre!)

Siehe auch `help("Arithmetic")`.

2.3 Vektoren von Text

a **Alphanumerische Vektoren.** Wie jede Programmiersprache kann auch S mit „Wörtern“ oder „character strings“ umgehen. Einen Vektor von strings erhält man zum Beispiel so:

```
> t.b  <- c("Andi" "Bettina", "Christian")
```

b Eine nützliche Funktion ist `paste`, die ihre Argumente nötigenfalls in solche Strings verwandelt und dann zusammenhängt,

```
> paste("ABC","XYZ",17)
[1]   "ABC XYZ 17"
```

Was zwischen den Strings steht, lässt sich mit dem Argument `sep` verändern (Weglasswert ist ein Leerschlag),

```
> paste("ABC","IJK","XYZ",sep=":")
[1]   "ABC:IJK:XYZ"
```

Keine Trennung erhält man, wenn man `sep=""` setzt.

c Wenn die Argumente Vektoren sind, entsteht wieder ein Vektor,

```
> paste(c("a","b","c"),1:3)
[1]   "a 1"   "b 2"   "c 3"
```

Wenn man alle Elemente eines Vektors zusammenhängen will, muss man das Argument `collapse` brauchen:

```
> paste(letters, collapse="; ")
[1] "a; b; c; d; e; f; g; h; i; j; k; l; m; n; o; p; q; r; s; t; u; v; w;
x; y; z"
```

hängt das (im System unter `letters` gespeicherte) Alphabet zusammen.

d Die Funktion `paste` ist also sehr flexibel. Wie `c` hat sie beliebig viele Argumente. Deshalb müssen die speziellen Argumente `sep` und `collapse` – von denen man jeweils nur eines benützen kann – mit ihren Namen angesprochen werden.

2.4 Logische Vektoren

a Neben numerischen und alphanumerischen Vektoren gibt es logische, deren Elemente nur die Werte `TRUE` oder `FALSE` haben können. Sie werden sich im nächsten Abschnitt als sehr nützlich erweisen. Sie entstehen meistens durch Vergleichsoperationen,

```
> (1:5)>=3
[1]   FALSE   FALSE   TRUE   TRUE   TRUE
```

Für das erste und zweite Element von `(1:5)` ist die Ungleichung *nicht* erfüllt (`FALSE`), für die letzten drei ist sie erfüllt (`TRUE`).

b Die **Vergleichsoperationen** werden geschrieben als `<, <=, >, >=, ==, !=`. Beachten Sie, dass das „vergleichende Gleich“ mit zwei Gleichheitszeichen geschrieben werden muss, da das einfache = zur Identifikation der Argumente von Funktionen gebraucht wird und auch gleich wie das Zuweisungssymbol `<-` benützt werden kann.

Siehe auch `help("Comparison")`.

c Die logischen Operationen heissen `&` (und), | (oder), `!` (nicht).

```
> t.i <- (t.v>2)&(t.v<5)
```

ergibt `TRUE` an den *Stellen der Elemente* von `t.v`, deren Werte zwischen 2 und 5 liegen.

2.5 Elemente auswählen

a In der Statistik will man oft nur Teile von gesammelten Daten bearbeiten. Wir haben oben schon eine Spalte oder eine Zeile eines data.frames ausgewählt (Abschnitt 1.4.d). Die Auswahl erfolgt mit den eckigen Klammern `[ ]`. Diese werden auch gebraucht, um Teile von Vektoren zu erhalten.

b Es gibt 3 Varianten:

- Indices (ganze Zahlen):

```
> t.v[c(1,3,5)]
[1] 15.66 15.82 16.32
```

```
> d.sport[c(1,3,5),1:3]
```

```
           weit kugel hoch
OBRIEN     7.57 15.66  207
DVORAK     7.60 15.82  198
HAMALAINEN 7.48 16.32  198
```

Man kann auch Elemente weglassen, indem man negative Zahlen verwendet:
`> d.sport[-(3:12),c("kugel","punkte")]`

```
        kugel punkte
OBRIEN   15.66   8824
BUSEMANN 13.60   8706
CHMARA   14.51   8249
```

- Logische Vektoren:

```
> t.a[c(TRUE,FALSE,TRUE,TRUE,FALSE,FALSE)]
[1] 3.1 -0.7 0.9
```

```
> d.sport[t.v > 16,c(2,7)]
```

```
           kugel punkte
HAMALAINEN 16.32   8613
PENALVER   16.91   8307
SMITH      16.97   8271
```

Der logische Vektor muss gleich viele Elemente haben wie der Vektor, aus dem ausgewählt wird, oder wie das data.frame Zeilen resp. Spalten hat.

- Bei data.frames kann man die Namen der Zeilen oder Spalten benützen:

```
> d.sport[c("OBRIEN","DVORAK"),c("kugel","speer","punkte")]

       kugel speer punkte
OBRIEN 15.66 66.90   8824
DVORAK 15.82 70.16   8664
```

Elemente von Vektoren können auch Namen haben(siehe `?names`). Man kann schreiben

```
> t.a <- c(a=2, b=-1, c=pi, d=5)

> t.a["c"]

[1] 3.14159
```

c **Bemerkung**: Wenn man eine einzige Variable eines data.frames bearbeiten oder benützen will, kann man auch mit Hilfe des Dollarzeichens auf sie zugreifen:

```
> d.sport$kugel
```

ruft die Variable `kugel` des data.frames `d.sport` auf, genau wie `d.sport[,"kugel"]`.

2.6 Matrizen

a Matrizen sind eine vereinfachte Version von Dataframes. Sie können nur Daten vom gleichen Typ (mode, siehe unten) enthalten, also entweder nur numerische, nur logische oder nur character Daten.

b Matrizen werden mit der Funktion `matrix` erzeugt,

```
> t.m1 <- matrix(1:10, nrow=2)
> t.m1

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

c Man sieht, dass die Matrix spaltenweise mit den als erstes Argument gegebenen Daten gefüllt wird. Will man zeilenweise füllen, dann setzt man das Argument `byrow=TRUE`. Man kann statt der Zeilenzahl `nrow` auch die Spaltenzahl `ncol` angeben – oder beides:

```
> matrix(0, nrow=2, ncol=3)

     [,1] [,2] [,3]
[1,]    0    0    0
[2,]    0    0    0
```

d Ein Dataframe kann man **in eine Matrix verwandeln** mit `as.matrix`, beispielsweise

```
> t.sportmat <- as.matrix(d.sport)
```

Wenn allerdings nur eine Spalte kategoriell (ein „Faktor“) ist, wird die ganze Matrix eine character-Matrix. Die Funktion `data.matrix` dagegen codiert solche Variablen durch ganze Zahlen und liefert immer eine numerische Matrix.

e Matrizen entstehen auch, wenn man Spalten oder Zeilen mit den Funktionen `cbind` respektive `rbind` „zusammenklebt“.

```
> cbind(4:6,13:15)
     [,1] [,2]
[1,]    4   13
[2,]    5   14
[3,]    6   15
```

f Mit den Funktionen `nrow(t.m)`, `ncol(t.m)`, `dim(t.m)` erhält man die Anzahl der Zeilen, der Spalten und von beides zusammen.

```
> dim(t.m)
[1] 2 5
```

g **Auswahl von Elementen** genau wie bei Dataframes:

```
> t.m1[2,1:3]
[1] 2 4 6
```

Damit die Auswahl auch hier mit Namen von Spalten oder Zeilen erfolgen kann, müssen solche Namen zuerst zugeordnet werden, siehe `?dimnames`.

h **Arrays.** Arrays sind „höherdimensionale Matrizen“. Man erzeugt sie mit der Funktion `array`. Wir wollen hier nicht näher auf diese Objekte eingehen – sie werden selten gebraucht.

i **Matrix-Multiplikation.** Die S-Sprache unterstützt ein Denken in Vektoren und Matrizen statt in einzelnen Zahlen. Die grundlegende Operation für Matrizen ist die Multiplication. Sie wird durch die Zeichen-Kombination `%*%` verlangt,

```
> t.m1 %*% t(t.m2)
     [,1] [,2]
[1,]   95  220
[2,]  110  260
```

j Einer der beiden Operanden kann auch ein Vektor sein. Er wird dann als einspaltige oder einzeilige Matrix behandelt, wenn das eine ausführbare Multiplikation ergibt.

k **Matrix-Funtionen.** S enthält alle wichtigen Funktionen für lineare Algebra. Eine Auswahl zeigt Tabelle **??**.

Aufruf, Beispiel	Bedeutung
`t(mat)`	Transponierte Matrix
`diag(mat)`	Diagonale einer Matrix
`diag(vec)`	generiert eine Diagonalmatrix mit Diagonale `vec`
`diag(5)`	Einheitsmatrix der Dimension 5
`solve(mat)`	Inverse Matrix
`svd(mat)`	singular value decomposition

Tabelle 2.6.k: Wichtige Funktionen für Matrizen

3 Einfache Statistik

3.1 Einfache Statistik-Funktionen

a Hier wollen wir einige Statistik-Funktionen von S vorstellen, die für grundlegende Problemstellungen wie Ein- und Zwei-Stichproben-Test gebraucht werden.

b **Tabellen.** Die Funktion `table` zählt, wie oft jeder Wert vorkommt,

```
> table(d.blast[,"loc"])

L1 L2 L3 L4 L5 L6
14 10 14 10 24 24
```

Der Ort `L1` kam also beispielsweise im Datensatz 14 Mal vor.

c Will man stetige Daten zuerst klassieren, dann ist die Funktion `cut` nützlich,

```
> t.speer  <- cut(d.sport[,"speer"],seq(50,75,5))
> table(t.speer)
(50,55] (55,60] (60,65] (65,70] (70,75]
      3       2       3       6       1
```

Ähnliches erreicht man – weniger gut lesbar – mit der Funktion `hist` und Argument `plot=FALSE`,

```
> hist(d.sport[,"speer"], plot=FALSE)
```

(Die Klassengrenzen werden hier gerade gleich gewählt wie oben!)

d Die Funktion `table` erstellt auch zweidimensionale Tabellen, so genannte Kontingenztafeln,

```
> t.kugel  <- cut(d.sport[,"kugel"],seq(13,17,1))
> table(t.kugel, t.speer)
         t.speer
t.kugel   (50,55] (55,60] (60,65] (65,70] (70,75]
  (13,14]       0       0       0       2       0
  (14,15]       3       0       0       2       0
  (15,16]       0       0       2       2       1
  (16,17]       0       2       1       0       0
```

– nur leider ohne Randsummen und Prozentwerte.

e **Numerische Beschreibung.**

Schätzung eines „Lokations-Parameters“:

```
> mean(x) ;  median(x)
```

Varianz: `var(x)`

Korrelation:

```
> cor(d.sport[,"kugel"], d.sport[,"speer"])
[1] -0.146
```

Korrelations-Matrix:

```
> t.cor <- cor(d.sport[,1:3])
> round(100*t.cor)

      weit kugel hoch
weit   100   -63   34
kugel  -63   100   -9
hoch    34    -9  100
```

3.2 Tests

a **Tests und Vertrauensintervalle.** Für Tests und Vertrauensintervalle für den Parameter der Binomial-Verteilung ist die Funktion `binom.test` da:

```
> binom.test(3,20, p=0.4)
```

gibt ein ausführliches Resultat mit P-Wert des Tests auf $\pi = 0.4$ und mit einem Vertrauensintervall.

b Für **zwei unabhängige Stichproben** liefert `wilcox.test` die Resultate des Rangsummentests und `t.test` diejenigen des t-Tests,

```
> t.hh  <- d.sport[,"hoch"]>200
> t.kugel  <- d.sport[,"kugel"]
> wilcox.test(t.kugel[t.hh],t.kugel[!t.hh])
        Wilcoxon rank sum test
data:  t.kugel[t.hh] and t.kugel[!t.hh]
W = 20, p-value = 0.4559
alternative hypothesis: true mu is not equal to 0

> t.test(t.kugel[t.hh],t.kugel[!t.hh], var.equal = TRUE)

        Two Sample t-test

data:  t.kugel[t.hh] and t.kugel[!t.hh]
t = -0.8066, df = 13, p-value = 0.4344
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -1.694  0.773
```

```
sample estimates:
mean of x mean of y
    15.01     15.47
```

Für gepaarte Stichproben oder eine einzelne Stichprobe liefern die gleichen Funktionen mit dem Argument `paired=TRUE` die Resultate.

3.3 Modell-Formeln

a Ein wesentlicher Teil der Statistik befasst sich damit, Zusammenhänge zwischen Variablen zu untersuchen. In der statistischen Regressions- und Varianzanalyse werden dazu Modelle aufgestellt. Um solche Modelle für die Software festzulegen, gibt es eine eigene „Sprache“ oder Syntax, die nicht nur in der S-Sprache verwendet wird.

Diese Formel-Sprache kann auch dazu benützt werden, grafische Darstellungen zu verlangen. Wir führen sie deshalb schon hier ein – wenigstens die einfachsten „Ausdrücke“, lange bevor wir auf die eigentlichen Modelle zu sprechen kommen.

b Eine einfache Formel sieht so aus:

```
kugel ~ speer + weit
```

Jede Formel enthält das Zeichen ‘∼’ (Tilde). Links davon steht die Zielvariable (`kugel`), rechts stehen die „Eingangs-Variablen“ (`speer`, `weit`) des Modells. In Streudiagrammen wird die Zielvarible schliesslich vertikal, die Eingangs-Variablen werden horizontal aufgetragen. Die einzelnen Variablen auf der rechten Seite werden durch ein ‘`+`’ voneinander getrennt – obwohl hier keine Variablen zusammengezählt werden.

Mehr über Formeln folgt im Kapitel über Regression.

c Eine Formel kann auch in der üblichen Weise abgespeichert werden. Sie bleibt eine Formel, also eine Art Satz in der Formel-Sprache. Erst wenn sie einer Funktion übergeben wird, die damit etwas anfangen kann, werden daraus wieder Werte von Variablen, also konkrete Zahlen.

d Ein Beispiel einer solchen Funktion ist `plot`:

```
> plot(kugel ~ speer, data=d.sport)
```

!!!

4 Graphics

4.1 Overview

a Several R graphics functions have been presented so far:

```
> plot(d.sport[,"kugel"], d.sport[,"speer"],
+  xlab="ball push", ylab="javelin", pch=7)
> plot(punkte ~ kugel+speer, data=d.sport)
> pairs(d.sport)
> boxplot(sleep[1:10,"extra"],sleep[11:20,"extra"],ylab="extra")
```

Many more functions are available and will be introduced:
`scatter.smooth()`, `matplot()`, `image()`, ...
`lines()`, `points()`, ...
`par()`, `identify()`, `dev.new()`, ...

b There are 6 kinds of **R graphics functions**:

- **High-level plotting functions** such as `plot()`
  ⇒ *generate a new graphical display of data.*
- **Low-level plotting functions** such as `lines()`
  ⇒ *add further graphical elements to an existing graph.*
- **"Interactive" functions** such as `identify()`
  ⇒ *enhance or collect information interactively from a graph.*
- **"Control" functions** such as `par()`
  ⇒ *control the appearance of graphs.*
- **"Device" control functions** such as `dev.new()`
  ⇒ *to manipulate windows and files that display or store graphs.*

4.2 Scatterplot

a The most common graphical display shows the values of two variables, plotted against each other. The (first) syntax is

```
> plot(x=x, y=y, main="...", xlab="...",
  ylab="...", ...)
```

x, y are two numeric vectors.
Example:

```
> plot(x=meuse[,"x"], y=meuse[,"y"], xlab="easting", ylab="northing",
+  main="sampling locations")
```

b Three alternative ways to invoke `plot()`:

- Plot of the values of a single vector against the position indices of the vector elements:
  > `plot(meuse[,"zinc"], ylab = "zinc")`
- Scatterplot of two columns of a matrix or a dataframe
  > `plot(meuse[,c("x","y")])`
- Use of a model "formula" to select y and x variable from a data frame:
  > `plot(zinc~dist, data=meuse)`
  Note: `y~x`: The variable to be used on the vertical axis comes first.

c Many **arguments** of `plot()` are **common** to many graphics functions:

- `main="..."`, `xlab="..."`, `ylab="..."`, where
  `...`: any character string
  ⇒ used to set **title** and **labels** of axes
- `log="x"`, `log="y"`, `log="xy"`
  ⇒ for **logarithmic scaling** of axes
- `xlim=c(`$x_{\min}$`,`$x_{\max}$`)`, `ylim=c(`$y_{\min}$`,`$y_{\max}$`)`
  ⇒ set **ranges** for the values to be displayed.
- `asp=`n
  ⇒ set "aspect ratio" of axes, i.e. ratio of lengths of "measurement" units on y and x axis. This is most often used to ensure that the scales of both axis are equal when displaying a geographical location or two geometrical measurements of an object, by setting `asp = 1`.
- `pch=`i or `pch="`*c*`"`
  ⇒ select the **plotting symbol(s)**
  `c`: a (vector of) single character(s) or
  `i`: a (vector of) integer(s) to select one of the built-in geometrical symbols (square, cricle, triangle, cross, ..., see `?points` for a list).
  If a vector is given, different symbols will be used for the different points (recycled if necessary).
- `cex=`n
  ⇒ choose the **size** of the symbols, relative to the standard size that the `plot` function would choose by default. A vector can be given as with `pch`.
- `col=`i or `col="`*color*`"`
  ⇒ choose the **size** and **color** of symbols
  color: name of color in english (`col = "red"`). A vector can again be given as with `pch`.

4.3 Boxplot

a Boxplots show the most important aspects of (the distribution of) a sample in a simple way. **Syntax**:

> `boxplot(x=`*x*`, notch=`*l*`, horizontal=`*l*`, ...)`

`notch = TRUE`: "notches" are added to roughly test whether two medians are significantly different
`horizontal = TRUE`: boxplots are shown horizontally. (There is no argument `vertical`.)

Example:
```
> boxplot(x=meuse[,"zinc"], notch=TRUE, horizontal=TRUE, log="x",
+ xlab="zinc content")
```

b Variations of boxplots:

- Boxplot of several variables in same graph:
  > `boxplot(meuse[,c("zinc","lead")], horizontal=TRUE, log="x")`
- Boxplots of several groups for one variable:
  > `boxplot(zinc~ffreq, data=meuse)`

4.4 Adding Points and Lines to a Plot

a Use `points()` to add further **points** to a graph created before by a high-level graphics function.
> `points(x=`*x*`, y=`*y*`, pch=`*i*`, col= , cex=`*n*`, ...)`

Example:
```
> plot(lead~dist.m, data=meuse, ylim=c(10,1000), log="y")
> points(meuse[,c("dist.m","copper")],
+  col="red", pch=3)
```

b **Lines** can be added by `lines()` to a graph.
> `lines(x=`*x*`, y=`*y*`, col= , lty= , lwd=`*n*`,...)`
`lty=`*i* or `lty="`*linetype*`"` (keyword): type of line
`n`: line width relative to default value

Example:
```
> plot(y~x, meuse, asp=1)
> lines(meuse.riv, lty="dotted", lwd=2.5, col= "cyan")
```

c **Straight lines** through the whole plotting area can be added by `abline()` to a graph.
> `abline(a=`*n*`, b=`*n*`, h=`*v*`, v=`*v*`, ...)`
Provide either values to `a` (intercept) and `b` (slope) **or** `h=`*v* as the (y) position(s) of *horizontal* **or** `v=`*v* as the (x) position(s) of *vertical* straight line(s).

Example:
```
> plot(lead~dist.m, meuse, asp=1)
> abline(h=c(200,500), lty="dotted", col=c("orange","red"))
> abline(a=300, b=-1, lty="3313", lwd=3)
```

d **Line segments** are added by `segments()`.
> `segments(x0=v, y0=v, x1=v, x2=v, ...)`

Line segments are drawn ***from*** **the points** (`x0`, `y0`) ***to*** **the points** (`x1`, `y1`) (*v* numeric vectors of same length).

Example:
```
> plot(y~x, meuse)
> t.xr <- range(meuse[,"x"])
> t.yr <- range(meuse[,"y"])
> segments(x0=rep(t.xr[1],2), y0=t.yr, x1=rep(t.xr[2],2), y1=t.yr[2:1] )
```

e **Polygons** are added by `polygon()`.
> `polygon(x=x, y=y, density=n, angle=n, border= , col= ,...)`
Provide values to `density` and `angle` for **hachuring** and to `border` and `col` for **border** and **fill color** of polygons. ???

Example:
```
> plot(y~x, meuse, asp=1)
> polygon(meuse.riv, border="blue", col="cyan", angle=135, density=10)
```

4.5 Adding Text to a Plot

a **Points** in a scatterplot are **labelled** by `text()`.
> `text(x=x, y=y, labels= , pos=i, ...)`
Provide a vector of character strings to `labels`. The argument `pos` controls whether the text is plotted below (1), to the left (2), above (3) or to the right (4) of the points.

Example:
```
> plot(y~x, meuse, asp=1, type="n")
> text(meuse[,c("x","y")], cex=0.7, labels=meuse[,"landuse"])
```

b **Legend.** Place a legend explaining any different symbols or line types used by `legend()`.
```
> legend(x= , y=n, xjust=n, yjust=n,
  legend= , col= , lty= , pch= ,...)
```

The position of the legend is either specified by `x` and `y` in combination with the arguments `xjust`, `yjust` or by a keyword such as `"bottomleft"` as the first argument (cf.`?legend` for details). `legend` contains the explanatory text as a vector of character strings. One or more of the remaining arguments will be specified by a vector of the same length as `legend` and will give the symbols and line types (`pch` and `lty`), the symbol sizes (`cex`), or the colors (`col`).

Example:
```
> plot(meuse[,c("x","y")], asp=1, col=as.numeric(meuse[,"ffreq"]),
+  cex=sqrt(meuse[,"zinc"])/10)
> legend(x="topleft", pch=c(NA,rep(1,3)),
+ col=c("black","black","red","green"),
+ legend=c("flooding", "often", "intermediate", "rarely"))
```

4.6 Interacting with a Plot

a **Points** in plots are identified and querried interactively by `identify()`.
> `identify(x=`*x*`, y=`*y*`, labels= )`
Provide a character or numeric vector of the same length as `x` and `y` to `labels` for labelling identified points accordingly. Click the right hand mouse button to stop identifying.

Example:
```
> plot(meuse[,c("x","y")], asp=1, cex=sqrt(meuse[,"zinc"])/10))
> t.i <- identify(meuse[,c("x","y")], labels=meuse[,"zinc"])
```
Now, the sequence numbers of the identified points are available as `t.i` for further use.

b Read the coordinates of interactively selected points from plots by using `locator()`.
> `locator(n=`*i*`, type="p")`
You can either specify the number *i* of points to locate in advance or right-click to stop locating points.
Example:
```
> plot(meuse[,c("x","y")], asp=1)
> polygon(locator())
```