Einführung in R

Marlene Müller

18. November 2008

Fraunhofer Institut
Techno- und
Wirtschaftsmathematik

Inhaltsverzeichnis

1 Was ist eigentlich R?

Programmiersprache S = in den Bell Labs für Statistik, Simulation, Grafik entwickelt (Becker and Chambers; 1984)

→ S-PLUS: kommerzielle Implementation

→ R: Implementation unter GPL (GNU General Public License), offener Quellcode

- \+ interpretierter Programmcode, objektorientiert
- \+ leicht erweiterbar durch eigene Routinen, Pakete, DLLs
- \+ viele Grafikmöglichkeiten (im wesentlichen statisch)
- \+ standardisiertes, einfach handhabbares Datenformat (`data.frame`)
- \+ gut durchdachtes Format zur Anpassung von (Regressions-)Modellen
- \+ aktive Entwicklergruppe, hilfreiche Mailingliste
- – bisher kein "Standard"-GUI
- – verfügbare Routinen/Pakete manchmal unübersichtlich
- – Bücher kommen erst langsam auf den Markt (S-Bücher teilweise nutzbar)

2 Wie fange ich an?

R ist kommandozeilenorientiert, also am einfachsten durch Eingeben von Ausdrücken wie z.B.:

```
> 1+1
[1] 2

> 1+2*3^4
[1] 163

> x <- 1; y <- 2
> x+y
[1] 3

> x <- seq(-pi,pi,by=0.1)
> plot(x,sin(x),type="l",col="red",main="Sinuskurve")
```

2.1 Arbeiten unter Unix/Linux

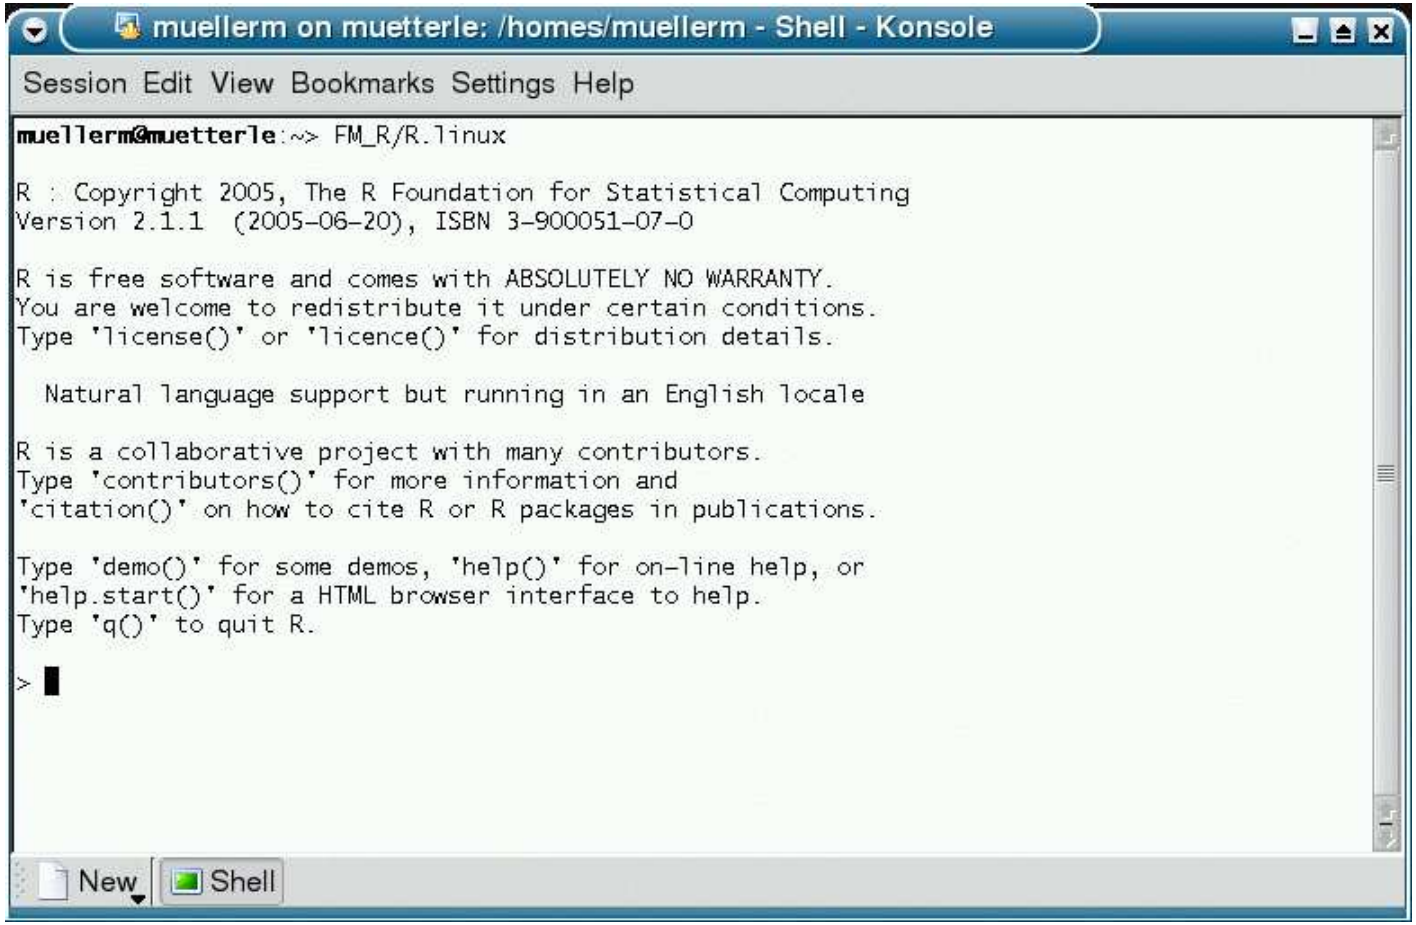

Abb. 1: R in einer Unix/Linux aufrufen

2.2 Arbeiten unter Windows

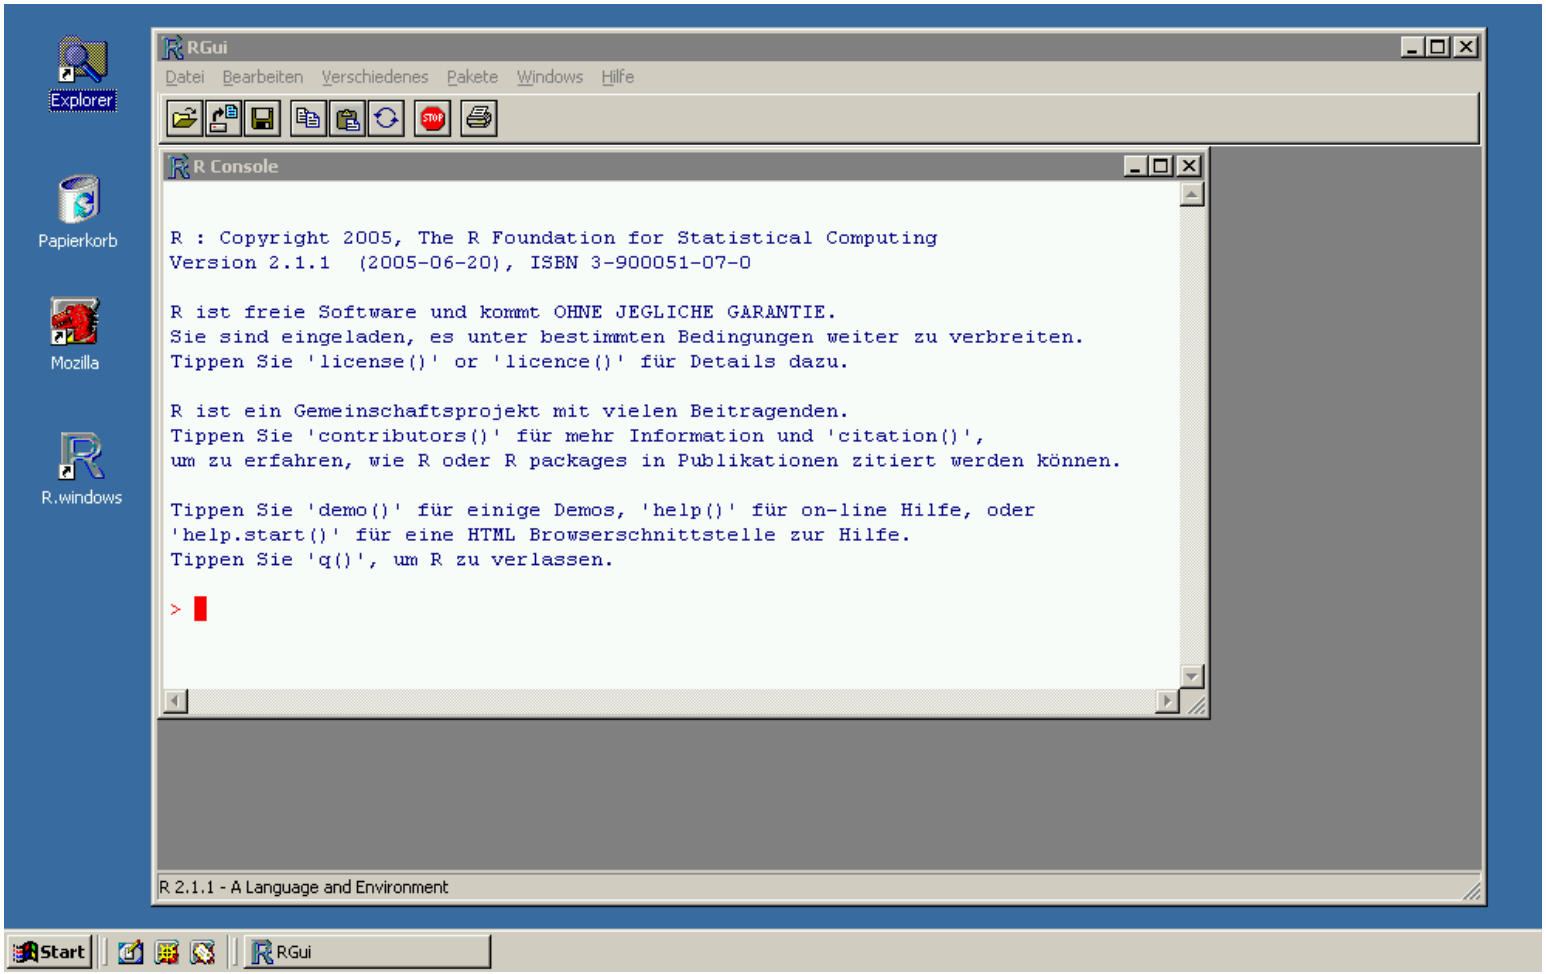

Abb. 2: R im Windows-Desktop starten

3 Wie bekomme ich Hilfe?

3.1 Lokale Hilfeseiten

- Hilfe zu einer Funktion:
  `help(<Funktion>)` oder `?<Funktion>`
- Hilfe zu einem Package:
  `library(help=<Package>)`

Üblicherweise entsprechen die Hilfetexte im lokalen Hilfesystem denen in der Dokumentation zu den Packages.

3.2 WWW

- **http://www.r-project.org**
  R-Webseite, dort findet man insbesondere FAQs und eine Google-Site-Search, aber auch:
  - Manuals (http://cran.r-project.org/manuals.html)
    Einführung, Sprachdefinition, “Writing R Extensions” (DLLs, Packages), Einführungen in weiteren Sprachen (außer Englisch)
  - CRAN (http://cran.r-project.org)
    Comprehensive R Archive Network (→ Software zum Download)
  - Mailing-Listen (→ Abschnitt 3.3)
  - Bücher-Liste (→ Abschnitt 3.4)
  - verwandte Projekte

3.3 Mailing-Listen

- R-help
  wichtigste Liste bei User-Fragen, beim Fragen aber auf alle Fälle http://www.r-project.org/posting-guide.html beachten!

  → auch als (Usenet-)NewsGroup gmane.comp.lang.r.general auf http://news.gmane.org verfügbar

- R-announce, R-packages, R-devel
  Ankündigungs-, Pakete-, Entwicklerlisten (→ eher für Spezialisten)

- R-sig-* (special interests groups)
  u.a. R-sig-finance = Special Interest Group for 'R in Finance'

Zum Eintragen und für Archive siehe http://www.r-project.org/mail.html bzw. http://news.gmane.org/index.php?prefix=gmane.comp.lang.r.

Zur Suche hilfreich ist http://www.rseek.org.

3.4 Bücher

- Dalgaard (2002): Introductory Statistics with R
- Murrell (2005): R Graphics
- Ligges (2005): Programmieren mit R
  (siehe auch: http://www.statistik.uni-dortmund.de/∼ligges/PmitR/)
- Venables and Ripley (2002): Modern Applied Statistics with S
  (Ergänzungen u.a. für R: http://www.stats.ox.ac.uk/pub/MASS3)
- Venables and Ripley (2000): S Programming
  (siehe auch: http://www.stats.ox.ac.uk/pub/MASS3/Sprog)

→ weitere: http://www.r-project.org/doc/bib/R-books.html

4 Etwas Rechnerei zum Anfang

Demos:

```
demo()
demo(graphics)   # nette Grafiken ;-)
demo(persp)      # nette 3D-Grafiken ;-)
demo(image)      # besonders nette Grafiken ;-)
```

Zuweisungen:

```
x <- 1
x <- 0 -> y
x <- y <- z <- NA            # Missing
x <- 0/0                     # Not a Number (NaN)
x <- NULL                    # kein Wert

x <- rnorm(100)                              # 100 N(0,1)-Zufallszahlen
hist(x, col="orange")                        # Histogramm
r <- hist(x, col="orange", freq=FALSE)       # dasselbe Histogramm?
g <- seq(-5,5,length=100)
ylim <- range(c(r$density,max(dnorm(g))))
hist(x, col="orange", freq=FALSE, ylim=ylim)    # wieder dasselbe Histogramm?
lines(g, dnorm(g))                           # N(0,1)-Dichte dazu gezeichnet
```

Nützliche Tools:

```
ls()                  ## alle R-Objekte auflisten

x <- 1:3
x                     ## Objekt (hier Vektor: x) anzeigen

print(x)              ## Objekt (hier Vektor: x) anzeigen, auch
                      ## innerhalb von Funktionen

fun <- function(x){ sin(x) }
fun                   ## Objekt (hier Funktion: fun) anzeigen

median                ## genauso: Objekt (hier Funktion: median) anzeigen

memory.limit(1536)    ## NUR Windows: Memory Limit auf 1.5GB erhöhen

rm(x)                 ## Objekt x löschen

save.image()          ## Workspace speichern (.RData, .Rhistory)
load(".RData")        ## Workspace laden     (.RData, .Rhistory)

date()                ## Datum und Uhrzeit

q()                   ## Quit
```

4.1 Datentypen

numeric:

```
x <- 1
y <- pi     # predefined pi = 3.1415926535898
```

character:

```
x <- "a"
y <- "Ein Text"
```

logical:

```
x <- TRUE
y <- 1 > 2

> y
[1] FALSE
```

Kompliziertere Datentypen sind durch Kombination dieser drei einfachen Datentypen in Form von Vektoren, Matrizen, Arrays und Listen konstruierbar.

4.2 Vektoren, Matrizen, Arrays, ...

Vektoren:

```
x <- c(1,2,3)
x <- 1:3

y <- c(1,1,1)
y <- rep(2,10)

z <- as.character(1:3)
z <- c("a","b","c")

length(z)

names(x) <- z

x[2:3]
x["b"]
```

Alle Elemente des Vektors sind vom gleichen Typ (numeric, character, logical)!

Matrizen:

```
x <- 1:20
x <- matrix(x, 5,4)    # matrix(x, nrow=5,ncol=4)

x[2,3]
x[c(1,5),2:4]
x[,2:4]

dim(x)
nrow(x)
ncol(x)

length(x)
as.vector(x)

dimnames(x) <- list(paste("row",1:nrow(x), sep=""),c("a","b","c","d"))

x[,"b"]
x[,c("a","b")]
```

Alle Elemente der Matrix sind vom gleichen Typ (numeric, character, logical)!

Vektoren aus Vektoren konstruieren:

```
x <- c(2,6,3)
y <- 1:3

c(x,y)                # aneinander hängen
c(x,1:5,y,6)          # aneinander hängen
```

Matrizen aus Vektoren konstruieren:

```
x <- c(2,6,3)
y <- 1:3

cbind(x,y)            # vertikal zusammensetzen
rbind(x,y)            # horizontal zusammensetzen

cbind(x,y,rep(0,3))   # vertikal zusammensetzen
```

Arrays:

```
x <- 1:60
x <- array(x, c(5,4,3))

x[2,3,1]
x[1,2:4,3]
x[,,1]

dim(x)
nrow(x)
ncol(x)

length(x)
as.vector(x)

dimnames(x) <- list(paste("row",1:nrow(x), sep=""),c("a","b","c","d"),c("x","y","z"))
```

Alle Elemente des Arrays sind vom gleichen Typ (numeric, character, logical)!

Listen:

```
x <- list(Eins=11:15, Zwei=c("a","b","c"), Drei=(1:4)>0)
y <- list(x=x, Vier=1:3)

x$Eins
y$x$Eins

y$Vier
y[[2]]

length(x)
length(y)

y$Fuenf <- names(x)
```

Listen enthalten Objekte verschiedenen Typs, die Objekte können mit $<Name> über ihren Namen oder mit [[<Nummer>]] über ihre Nummer angesprochen werden.

Datenmatrizen:

```
x <- data.frame(N=11:14, C=c("a","b","c","d"), L=(1:4)>0)

dim(x)
nrow(x)
ncol(x)

length(x)
as.vector(x)

names(x)

x[2,3]
x[,2:3]

x[,2]
x[,"C"]
x$C
```

Datenmatrizen sind Listen, bei denen alle Spalten die gleiche Länge haben.
$\longrightarrow$ Excel-Tabellen, als .csv abgespeichert, werden typischerweise als Datenmatrix (data.frame) in R eingelesen.

4.3 Operationen (elementweise bzw. vektor-/matrixweise)

```
x <- matrix( 1:20, 5, 4)   # 5x4 Matrix

x+1; x-1; x*1; x/1         # elementweise Operationen
sin(x); exp(x)             # elementweise Funktionsaufrufe

y <- 1:5
x * y                      # elementweise Multiplikation

z <- 1:4
x %*% z                    # Matrixmultiplikation

min(x)                     # Minimum aller Elemente von x
apply(x,1,min)             # Zeilenminima
apply(x,2,min)             # Spaltenminima

y <- c(TRUE, TRUE, FALSE, FALSE)
y & TRUE                   # elementweise logische Operation (‘‘UND’’)
y | FALSE                  # elementweise logische Operation (‘‘ODER’’)
!y                         # elementweise logische Operation (‘‘NICHT’’)

y && TRUE                  # ABER: hier gilt nur das erste Ergebnis! (‘‘UND’’)
y || FALSE                 # ABER: hier gilt nur das erste Ergebnis! (‘‘ODER’’)
```

5 Daten & Dateien

Beispiel-Datei in Excel:

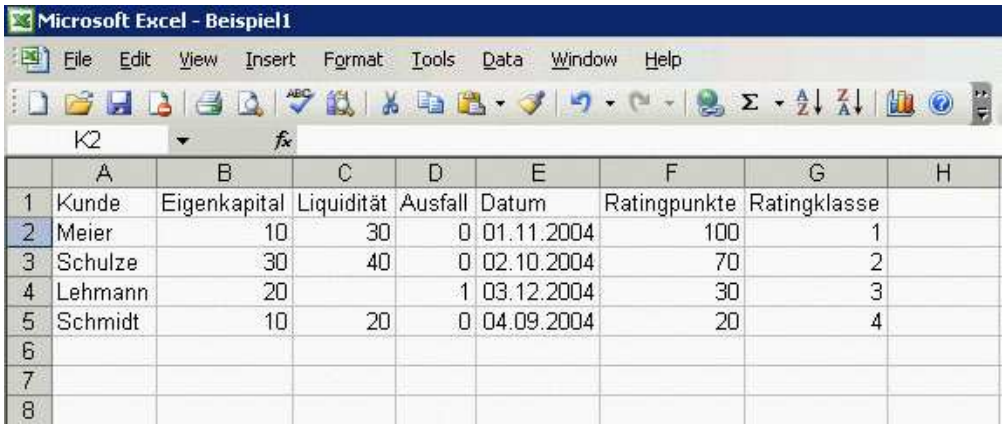

	A	B	C	D	E	F	G	H
1	Kunde	Eigenkapital	Liquidität	Ausfall	Datum	Ratingpunkte	Ratingklasse	
2	Meier	10	30	0	01.11.2004	100	1	
3	Schulze	30	40	0	02.10.2004	70	2	
4	Lehmann	20		1	03.12.2004	30	3	
5	Schmidt	10	20	0	04.09.2004	20	4	
6								
7								
8								

→ unter Excel als CSV speichern: Beispiel1.csv

```
Kunde;Eigenkapital;Liquidität;Ausfall;Datum;Ratingpunkte;Ratingklasse
Meier;10;30;0;01.11.2004;100;1
Schulze;30;40;0;02.10.2004;70;2
Lehmann;20;;1;03.12.2004;30;3
Schmidt;10;20;0;04.09.2004;20;4
```

5.1 CSV-Dateien lesen und Speichern

Lesen der Datei Beispiel1.csv:

```
x <- read.csv("Beispiel1.csv", sep=";")

dim(x)
names(x)
x
```

```
    Kunde Eigenkapital Liquidität Ausfall      Datum Ratingpunkte Ratingklasse
1   Meier           10         30       0 01.11.2004          100            1
2 Schulze           30         40       0 02.10.2004           70            2
3 Lehmann           20         NA       1 03.12.2004           30            3
4 Schmidt           10         20       0 04.09.2004           20            4
```

Schreiben der Daten in Beispiel2.csv:

```
write.table(x,file="Beispiel2.csv",sep=";",row.names=FALSE,quote=FALSE)
```

Andere Funktionen zum Lesen:

- `read.table` (Daten im ASCII-Format)
- `scan` (scannt beliebige Textdatei, eigene Nachbearbeitung erforderlich)

Funktionen zum evtl. Konvertieren von Spalten:

- `as.numeric`, `as.character`, `as.factor`

Andere Möglichkeiten der Kommunikation mit Excel (nicht getestet ;-)):

- `RODBC` (Zugriff auf Excel oder Access als Datenbank)
- R-Excel-Interface über DCOM-Server (http://cran.at.r-project.org/contrib/extra/dcom)

5.2 Zufallszahlen und Verteilungen

Beispiel Normalverteilung:

`rnorm(n, mean=0, sd=1)`	Zufallszahlen
`dnorm(x, mean=0, sd=1)`	Dichte (pdf)
`pnorm(x, mean=0, sd=1)`	Verteilungsfunktion (cdf)
`qnorm(p, mean=0, sd=1)`	Quantile

nach gleichem Muster:

Gleichverteilung	`{r|d|p|q}unif`	t-Verteilung	`{r|d|p|q}t`
Lognormalverteilung	`{r|d|p|q}lnorm`	Gamma-Verteilung	`{r|d|p|q}gamma`
χ^2-verteilung	`{r|d|p|q}chisq`	Beta-Verteilung	`{r|d|p|q}beta`
Binomialverteilung	`{r|d|p|q}binom`	Poisson-Verteilung	`{r|d|p|q}pois`
...			

$\rightarrow$ bei Bedarf den vorher Seed mit `set.seed` setzen

5.3 R-Skriptdateien

Skript mit R-Befehlen einlesen:

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

R-Output in Datei abspeichern:

```
sink("MeinOutput.txt")   # ab jetzt alle Ausgaben in Datei
sink()                   # und nun wieder auf den Bildschirm
```

Normal- vs. t-verteilung:

```
x <- rnorm(100)
mean(x)
sd(x)

plot(rnorm(10000), rnorm(10000))

x <- seq(-5,5,by=0.1)
plot(x, dnorm(x), type="l", col="black", lwd=2)
lines(x, dt(x, df=1), col="blue")
lines(x, dt(x, df=5), col="orange")
lines(x, dt(x, df=20), col="red")

qnorm(0.95)
qnorm(0.975)
```

Multivariate Normalverteilung:

```
library(help=mvtnorm)
library(mvtnorm)

mu <- c(0,0)     # means
sigma <- c(1,1)  # std.dev.
rho <- 0.5       # correlation

S <- matrix(NA, 2,2)
diag(S) <- sigma^2
S[1,2] <- S[2,1] <- rho*prod(sigma)

x <- rmvnorm(n=10000, mean=mu, sigma=S)
plot(x)

x <- seq(-5*sigma[1]+mu[1], 5*sigma[1]+mu[1], length = 50)
y <- seq(-5*sigma[2]+mu[2], 5*sigma[2]+mu[2], length = 50)
f <- function(x,y) { dmvnorm(cbind(x,y), mean=mu, sigma=S) }
z <- outer(x, y, f)
persp(x, y, z, theta = 10, phi = 20, expand = 0.5, col = "lightblue", shade = 0.75)
```

6 Schöne bunte Welt der Grafik

Kreditausfalldaten:

```
file <- read.csv("kredit.csv",sep=";")
y <- 1-file$kredit        # default set to 1
prev    <- (file$moral >2)+0                                  # previous loans were OK
employ  <- (file$beszeit >1)+0                                # employed (>=1 year)
dura    <- (file$laufzeit)                                    # duration
d9.12   <- ((file$laufzeit >9)&(file$laufzeit <=12)) +0 #  9 < duration <= 12
d12.18  <- ((file$laufzeit >12)&(file$laufzeit <=18))+0 # 12 < duration <= 18
d18.24  <- ((file$laufzeit >18)&(file$laufzeit <=24))+0 # 18 < duration <= 24
d24     <- (file$laufzeit >24)+0                              # 24 < duration
amount  <- file$hoehe                                         # amount of loan
age     <- file$alter                                         # age of applicant
savings <- (file$sparkont > 4)+0                              # savings >= 1000 DM
phone   <- (file$telef==1)+0                                  # applicant has telephone
foreign <- (file$gastarb==1)+0                                # non-german citizen
purpose <- ((file$verw==1)|(file$verw==2))+0                  # loan is for a car
house   <- (file$verm==4)+0                                   # house owner
```

6.1 Balkendiagramme

→ grafische Darstellung der Häufigkeitsverteilung diskreter Merkmale

```
table(dura)                              ## Häufigkeitstabelle

barplot(table(dura), col="cyan", main="Duration of Loan")
                                         ## absolute Häufigkeiten

barplot(table(dura)/length(dura), col="cyan", main="Duration of Loan")
                                         ## relative Häufigkeiten

par(mfrow=c(1,3))   # 1 Zeile, 3 Spalten im Display
barplot(table(dura),    col="cyan",    main="Duration of Loan")
barplot(table(savings), col="orange",  main="Savings >1000 DM")
barplot(table(house),   col="magenta", main="House Owner")
par(mfrow=c(1,1))   # Display-Teilung zurücksetzen!
```

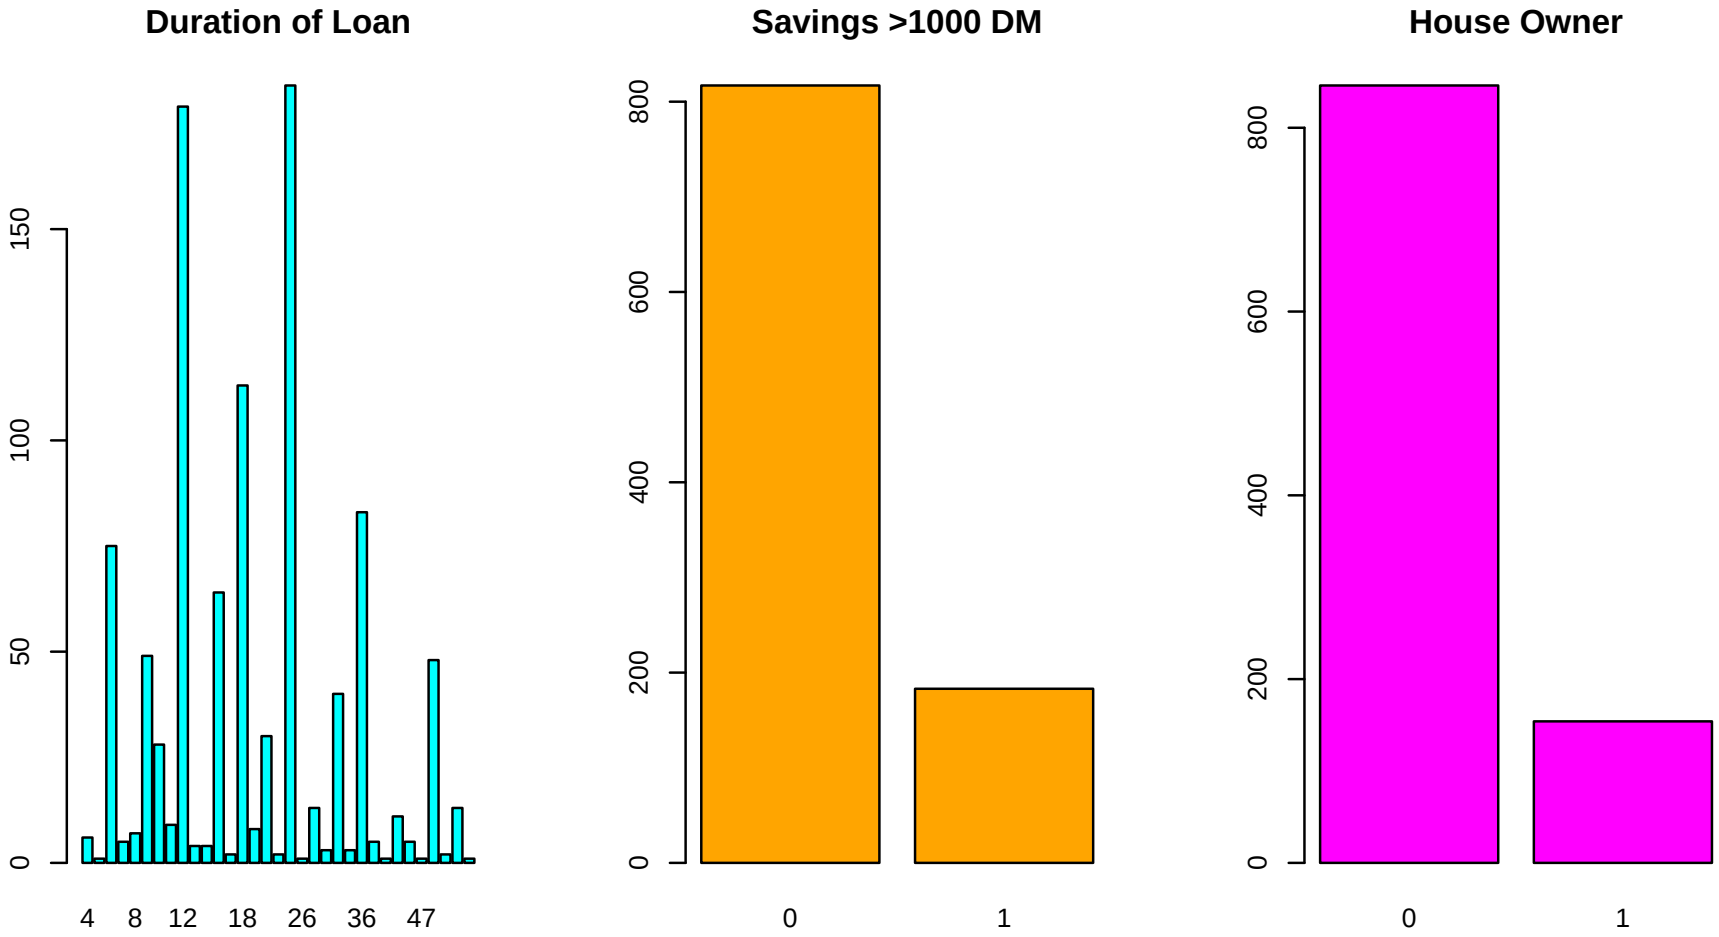

Abb. 3: Beispiele für Balkendiagramme: Laufzeit des Kredits (links), Spareinlagen (mitte) und Immobilienbesitz (rechts)

6.2 Boxplots

→ grafische Darstellung von Ausreißern, Minimal-/Maximalwerten (die keine Ausreißer sind), 25%-,50%,75%-Quantilen

```
boxplot(age)
boxplot(age, horizontal=TRUE)

boxplot(age, col="gray",horizontal=TRUE)

boxplot(age ~ y, col=c("gray","red"),horizontal=TRUE, main="Age vs. Y")
boxplot(amount ~ y, col=c("gray","red"),horizontal=TRUE, main="Amount vs. Y")
```

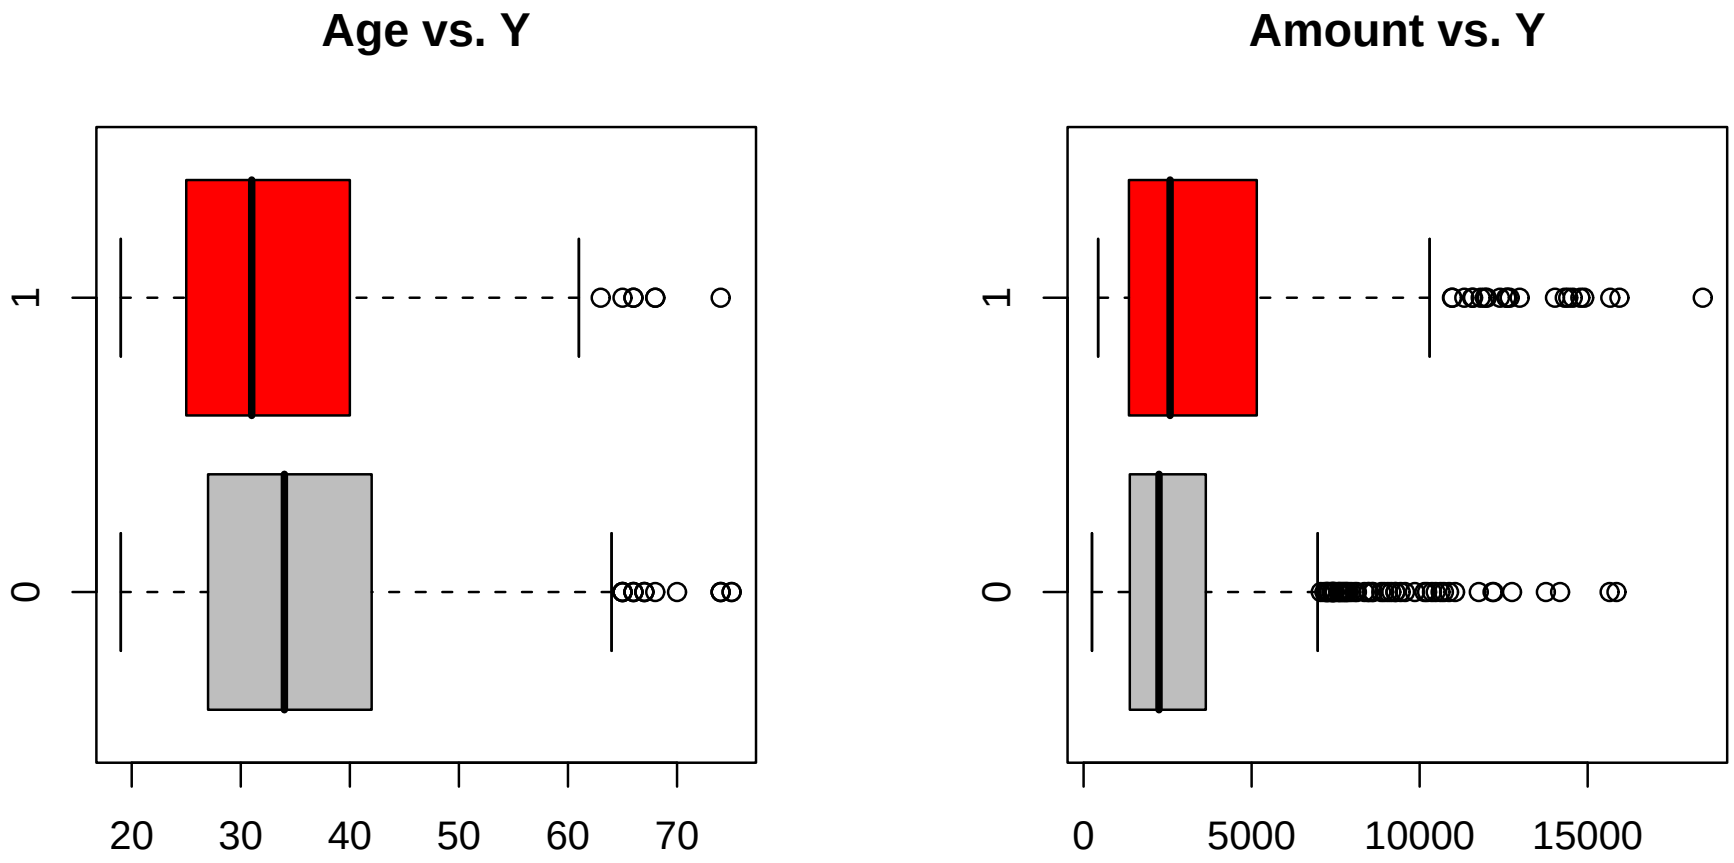

Abb. 4: Alter des Kreditnehmers (links) und Kreditbetrag (rechts) gegen Ausfallbeobachtung (1 =Ausfall, 0 = Nichtausfall)

6.3 Histogramme

→ grafische Darstellung der Häufigkeitsverteilung stetiger Merkmale

```
hist(age)
hist(age, freq=FALSE)
hist(age, freq=FALSE, col="gray")

hist(amount, freq=FALSE, col="gray",    main="Amount")
xx <- seq(min(amount),max(amount), length=100)
lines(xx, dnorm(xx, mean(amount), sd(amount)), col="red")
lines(xx, dlnorm(xx, mean(log(amount)), sd(log(amount))), col="green", lwd=2)

## mit kleineren Intervallen und besserer vertikaler Skalierung
b  <- seq(0,20000,by=1500)                          ## neue Intervalle
h  <- hist(amount, freq=FALSE, breaks=b, plot=FALSE)   ## Histogramm ohne Grafik
xx <- seq(min(amount),max(amount), length=100)
d1  <- dnorm(xx, mean(amount), sd(amount))             ## Normal-Dichte
d2  <- dlnorm(xx, mean(log(amount)), sd(log(amount)))  ## LogNormal-Dichte
ylim <- range( c(h$density, d1, d2) )

hist(amount, freq=FALSE, breaks=b, col="gray", main="Amount", ylim=ylim)
lines(xx, d1, col="red")
lines(xx, d2, col="green", lwd=2)
```

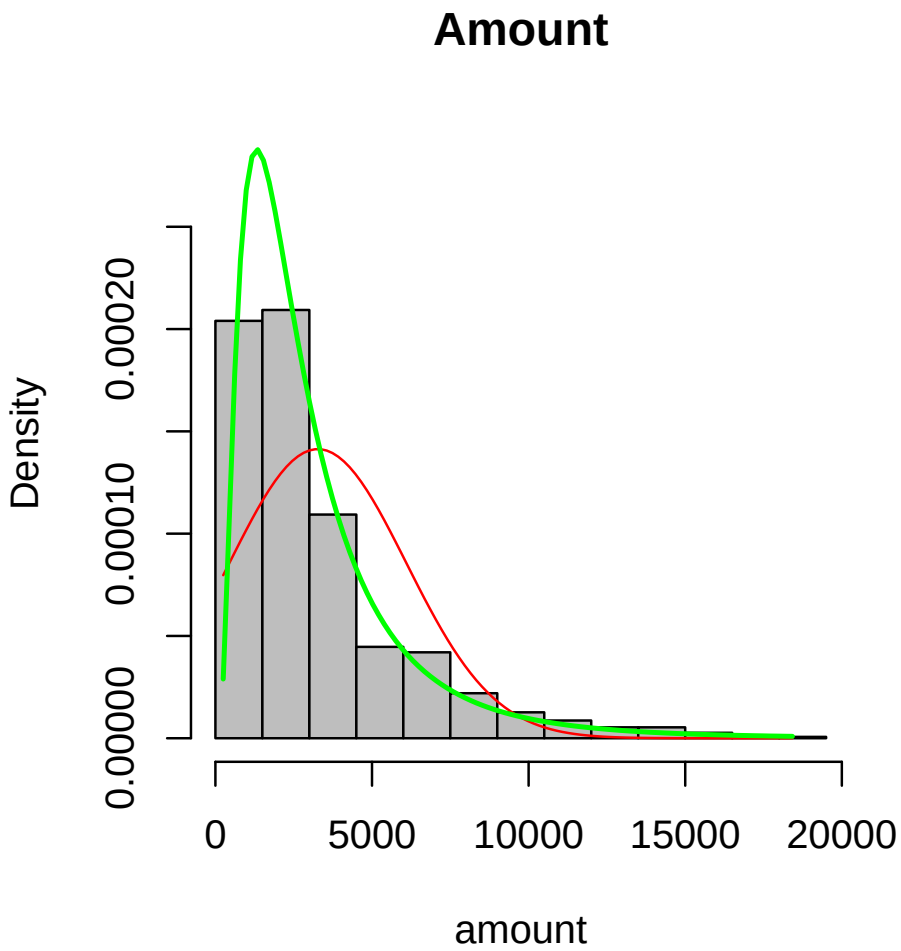

Abb. 5: Verteilung des Kreditbetrags, Histogramm im Vergleich mit Normal- und LogNormaldichte

6.4 Scatterplots und Kurven

→ Punktwolken ...

```
plot(age, amount)

color <- 1*(y==1) + 2*(y==0)
plot(age, amount, col=color)

color <- rep("", length(age))
color[y==1] <- "red"
color[y==0] <- "blue"
plot(age, amount, col=color)

plot(1:20,1:20,col=1:20, pch=1:20)
text(1:20,1:20,labels=as.character(1:20), pos=4)

symbol <- 8*(y==1) + 1*(y==0)
plot(age, amount, col=color, pch=symbol)
```

→ ... oder Linien oder beides

```
x <- seq(-pi,pi,length=100)
plot(x, sin(x), type="l")
lines(x, cos(x), col="red")

logit <- glm(y ~ age, family=binomial(link = "logit"))

plot(age, logit$fitted.values)

plot(age, logit$fitted.values, type="l")         ## nicht so, sondern ...

o <- order(age)
plot(age[o], logit$fitted.values[o], type="l")   ## ... so! (sortiert)

plot(age[o], logit$fitted.values[o], type="l", lwd=2, ylim=c(0,1))
title("PDs")
points(age, y, col="red", pch=3, cex=0.5)
```

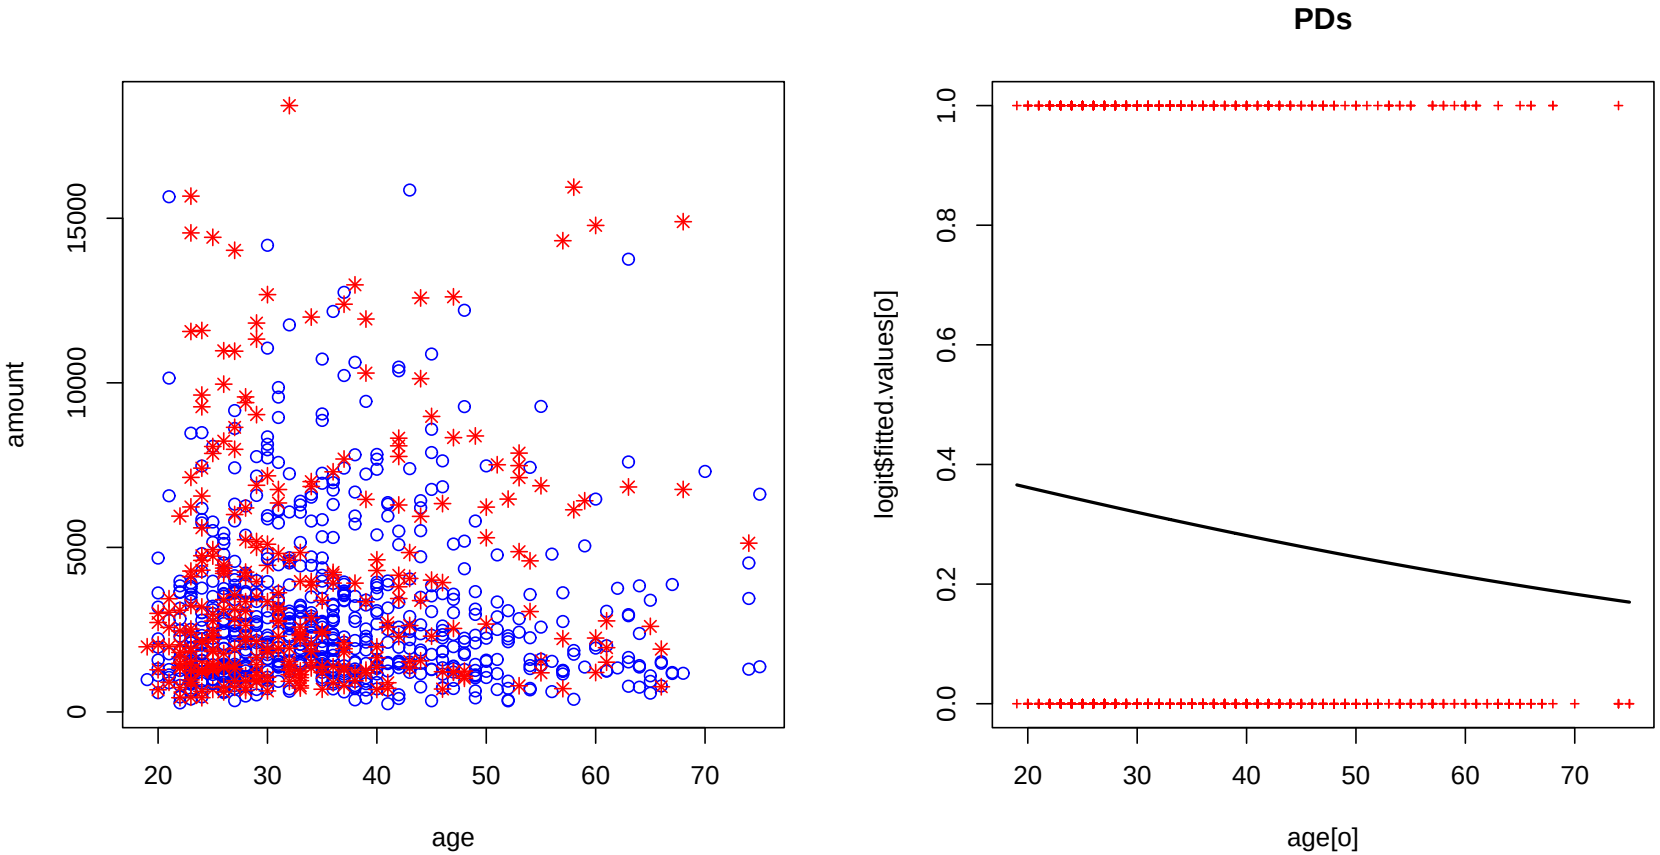

Abb. 6: Scatterplot von Alter vs. Kreditbetrag (links), Logit-Ausfallwahrscheinlichkeiten (rechts)

6.5 Dreidimensionale Darstellung

→ Oberflächen, Punktwolken und Konturkurven

```
## Bivariate Normalverteilungsdichte
library(mvtnorm)
x <- y <- seq(-5, 5, length = 50)
f <- function(x,y) { dmvnorm(cbind(x,y)) }
z <- outer(x, y, f)
persp(x, y, z, theta = 10, phi = 20, expand = 0.5, col = "lightblue")
persp(x, y, z, theta = 10, phi = 20, expand = 0.5, col = "lightblue", shade = 0.75)

## Konturkurven der bivariaten Normalverteilungsdichte
x <- y <- seq(-5, 5, length = 150)
z <- outer(x, y, f)
contour(x, y, z, nlevels=20)
contour(x, y, z, nlevels=20, col=rainbow(20))
contour(x, y, z, nlevels=20, col=rainbow(20), labels="")

## Dreidimensionale normalverteilte Daten
library(scatterplot3d)
x <- matrix(rnorm(15000),ncol=3)
scatterplot3d(x)
scatterplot3d(x, angle=20)
```

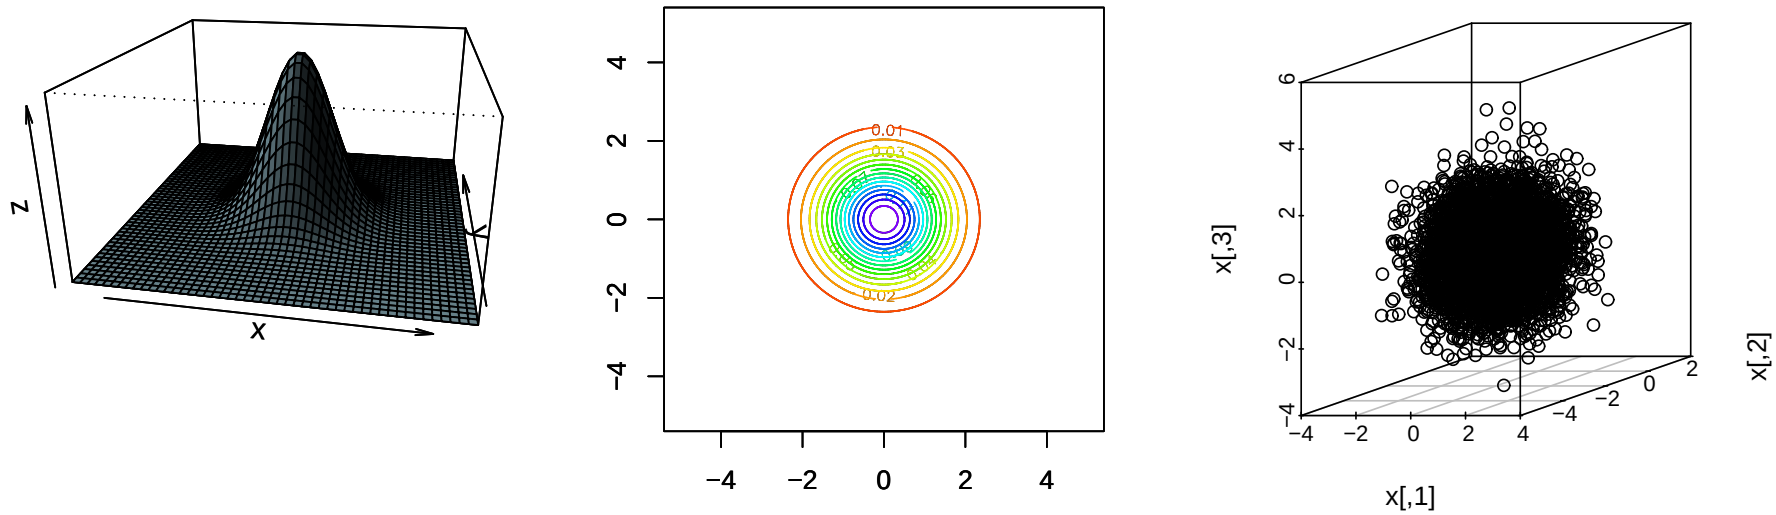

Abb. 7: Bivariate Normalverteilungsdichte: 3D-Darstellung (links) und Konturkurven (mitte); 3D-Scatterplot (rechts)

6.6 Gestaltungsmöglichkeiten

Direkt in den Grafikroutinen: → Hilfe dazu mit `?par`

- Farben setzen mit `col=...`
  (Generierung von → `?rainbow`, `?rgb`, `?col2rgb`)
- Symbole setzen mit `pch=...`, Größen mit `cex=...`
- Titel setzen mit `main=...`, Achsenlabels mit `xlab=...`, `ylab=...`
- Zeichenbereich setzen mit `xlim=...`, `ylim=...`

Nach Zeichnen einer Grafik:

- Linien und Punkte mit `lines(...)` bzw. `points(...)` ergänzen
- Labels (Texte) mit `text(...)` ergänzen
- Titel mit `title(...)` ergänzen
- Legende mit `legend(...)` ergänzen

6.7 Grafiken speichern

- PostScript:

```
x <- matrix(rnorm(5000),ncol=2)
plot(x)
postscript(file = "MeinPlot.ps", width = 5, height = 5.5, horizontal = FALSE)
plot(x)
dev.off()
```

- andere Formate sind u.a. `pdf`, `pictex`, `xfig`, png, `jpeg`
  $\rightarrow$ siehe `?Devices`

7 Etwas Statistik

Kreditausfalldaten:

```
file <- read.csv("kredit.csv",sep=";")
y <- 1-file$kredit        # default set to 1
prev    <- (file$moral >2)+0                                  # previous loans were OK
employ  <- (file$beszeit >1)+0                                # employed (>=1 year)
dura    <- (file$laufzeit)                                    # duration
d9.12   <- ((file$laufzeit >9)&(file$laufzeit <=12)) +0 #  9 < duration <= 12
d12.18  <- ((file$laufzeit >12)&(file$laufzeit <=18))+0 # 12 < duration <= 18
d18.24  <- ((file$laufzeit >18)&(file$laufzeit <=24))+0 # 18 < duration <= 24
d24     <- (file$laufzeit >24)+0                              # 24 < duration
amount  <- file$hoehe                                         # amount of loan
age     <- file$alter                                         # age of applicant
savings <- (file$sparkont > 4)+0                              # savings >= 1000 DM
phone   <- (file$telef==1)+0                                  # applicant has telephone
foreign <- (file$gastarb==1)+0                                # non-german citizen
purpose <- ((file$verw==1)|(file$verw==2))+0                  # loan is for a car
house   <- (file$verm==4)+0                                   # house owner
```

7.1 Kennzahlen

```
kredit <- data.frame(y,age,amount,dura,prev,savings,house)

summary(kredit)

mean(kredit$age)
sd(kredit$age)
var(kredit$age)

cov(kredit[,1:3])
cor(kredit[,1:3])

median(kredit$age)
quantile(kredit$age,c(0.1,0.5,0.9))

library(help=e1071)
library(e1071)
skewness(kredit$age)
kurtosis(kredit$age)

skewness(rnorm(1000))
kurtosis(rnorm(1000))
```

7.2 Tabellen

```
length(kredit$age)
length(unique(kredit$age))

table(kredit$age)
table(kredit$dura)
table(kredit$savings)

table(kredit$y, kredit$savings)
table(kredit$y, kredit$savings)/nrow(kredit)

table(kredit$y, kredit$savings, kredit$house)

unique(kredit[,c("y","savings","house")])
```

7.3 Regressions- und Zeitreihenanalyse

7.3.1 Lineare Regression

```
plot(kredit$age, kredit$dura)

lm <- lm( dura ~ age, data=kredit)
summary(lm)                                  ## Abhängigkeit von Alter
o <- order(kredit$age)
lines(kredit$age[o], lm$fitted.values[o], col="red", lwd=2)

lm2 <- lm( dura ~ age + amount, data=kredit)
summary(lm2)                                 ## Abhängigkeit von Alter+Betrag

lm3 <- lm( dura ~ amount, data=kredit)
summary(lm3)                                 ## Abhängigkeit von Betrag
plot(kredit$amount, kredit$dura)
o <- order(kredit$amount)
lines(kredit$amount[o], lm3$fitted.values[o], col="red", lwd=2)

lm4 <- lm( dura ~ amount + I(amount^2), data=kredit)
summary(lm4)                                 ## Abhängigkeit von Betrag (quadr.)
lines(kredit$amount[o], lm4$fitted.values[o], col="blue", lwd=2)
```

→ Laufzeit des Kredits hängt klar vom Kreditbetrag ab:

```
> summary(lm4)

Call:
lm(formula = dura ~ amount + I(amount^2), data = kredit)

Residuals:
     Min       1Q   Median       3Q      Max
-34.6115  -5.5761  -0.9547   5.0850  42.1110

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  8.410e+00  6.516e-01  12.906  < 2e-16 ***
amount       4.855e-03  2.961e-04  16.393  < 2e-16 ***
I(amount^2) -1.815e-07  2.309e-08  -7.863  9.7e-15 ***
---
Signif. codes:  0 ’***’ 0.001 ’**’ 0.01 ’*’ 0.05 ’.’ 0.1 ’ ’ 1

Residual standard error: 9.144 on 997 degrees of freedom
Multiple R-Squared: 0.4262,     Adjusted R-squared: 0.425
F-statistic: 370.3 on 2 and 997 DF,  p-value: < 2.2e-16
```

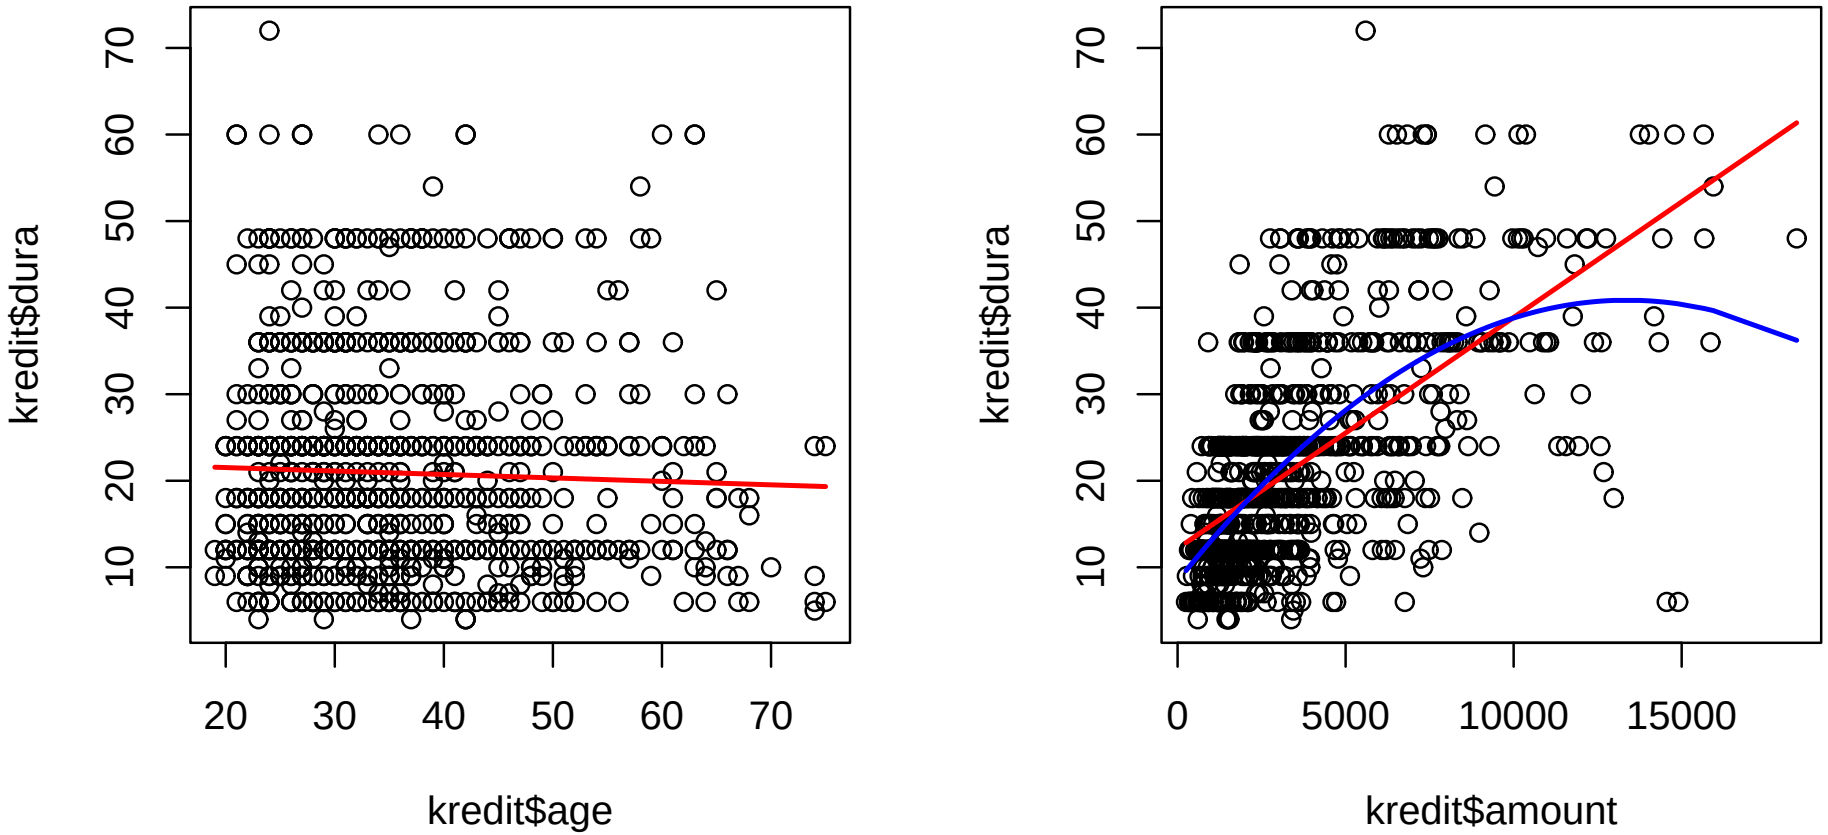

Abb. 8: Abhängigkeit der Kreditlaufzeit vom Alter (links) und vom Kreditbetrag (rechts)

7.3.2 Generalisiertes Lineares Modell (GLM)

→ Schätzung der Ausfallwahrscheinlichkeiten

```
logit <- glm(y ~ age + amount + dura + prev + savings + house,
             family=binomial(link = "logit"))
summary(logit)

logit2 <- glm(y ~ age + amount + I(amount^2) + dura + prev + savings + house,
              family=binomial(link = "logit"))
summary(logit2)
```

→ Ausfallwahrscheinlichkeiten hängen u.a. nichtlinear vom Betrag ab:

```
> summary(logit2)

Call:
glm(formula = y ~ age + amount + I(amount^2) + dura + prev +
    savings + house, family = binomial(link = "logit"))

Deviance Residuals:
    Min       1Q   Median       3Q      Max
-2.1244  -0.8495  -0.6196   1.0935   2.2584
```

```
Coefficients:
              Estimate Std. Error z value Pr(>|z|)
(Intercept) -4.637e-01  3.035e-01  -1.528  0.12652
age         -1.748e-02  7.159e-03  -2.442  0.01460 *
amount      -2.070e-04  9.348e-05  -2.214  0.02679 *
I(amount^2)  1.870e-08  6.941e-09   2.694  0.00707 **
dura         3.992e-02  8.106e-03   4.925 8.46e-07 ***
prev        -7.589e-01  1.619e-01  -4.688 2.76e-06 ***
savings     -9.897e-01  2.232e-01  -4.435 9.22e-06 ***
house        6.277e-01  2.073e-01   3.027  0.00247 **
---
Signif. codes:  0 ’***’ 0.001 ’**’ 0.01 ’*’ 0.05 ’.’ 0.1 ’ ’ 1

(Dispersion parameter for binomial family taken to be 1)

    Null deviance: 1221.7  on 999  degrees of freedom
Residual deviance: 1102.1  on 992  degrees of freedom
AIC: 1118.1

Number of Fisher Scoring iterations: 4
```

7.3.3 Auswahl weiterer Regressions- und Zeitreihenmodelle

Modell	Routinen
Linear	`lm`, `anova`
GLM	`glm`, `mgcv` / `gam` (additiv nichtparametrisch)
Nichtlinear	`nls`
Nichtparametrisch	`locpoly`, `locfit`
Mixed Models	`lmm`, `nlme`, `glmmML`, `glmmPQL`
Zeitreihen	`ar`, `arma`, `arima`, `arima0`, `garch`
Classification and regression trees	`tree`

Packages: `MASS`, `stats`, `KernSmooth`, `tseries`, `gam`, `gcv`

7.4 Hypothesentests

7.4.1 Normaltests

```
library(KernSmooth)
f <- bkde(kredit$age)
plot(f, type="l", xlim=range(f$x), ylim=range(f$y))
title("Distribution of Age")          ## Verteilung normal?

t <- shapiro.test(kredit$age)
t
t$p.value

library(tseries)
t <- jarque.bera.test(kredit$age)
t
t$p.value
```

7.4.2 Vergleich von Verteilungen

```
library(KernSmooth)
f0 <- bkde(kredit$age[y==0])
f1 <- bkde(kredit$age[y==1])
plot(f0, type="l", col="blue", xlim=range(c(f0$x,f1$x)), ylim=range(c(f0$y,f1$y)))
lines(f1, col="red")
title("Age vs. Default")          ## Verteilungen gleich?

t <- ks.test(kredit$age[y==1],kredit$age[y==0])
t
t$p.value

t <- wilcox.test(kredit$age[y==1],kredit$age[y==0])
t
t$p.value
```

7.4.3 Auswahl weiterer Tests

Test	Routinen
Mittelwert-Tests/-Vergleiche (t-Tests)	`t.test`
Varianz-Tests/-Vergleiche (F-Tests)	`var.test`
Binomial-Tests	`prop.test`, `binom.test`
Korrelation	`cor.test`
Rangtests	`wilcox.test`
Regression	`anova`
Unit Roots (mean reversion)	`adf.test`, `kpss.test`

Packages: `stats`, `tseries`, `exactRankTests`

8 “Höhere” Mathematik

8.1 Optimierung von Funktionen

Lineares Modell

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \varepsilon_i$$

```
n <- 100; b <- c(-1,3)
x <- matrix(rnorm(n*length(b)),ncol=length(b))   ## Regressoren
e <- rnorm(n)/4

y <- 1 + x %*% b + e                             ## Lineares Modell

l <- lm( y~x ); summary(l)                       ## built-in Lineare Regression
```

$\longrightarrow$ zu optimieren

$$QS = \sum_i (y_i - x_i^\top \beta)^2$$

(zugegebenermaßen kein wirklich gutes Beispiel für iterative Optimierung ;-))

Optimierung (ohne Konstante)

```
QS <- function(b, x, y){ sum( (y - x %*% b)^2 ) }  ## Optimierungskriterium

b0 <- c(0,0)
opt <- optim(b0, QS, method="BFGS", x=x, y=y)      ## Optimierung (ohne Konstante!)
opt
sum( (x %*% opt$par - mean(y))^2 )/sum( (y-mean(y))^2 )    ## R^2
```

$\rightarrow$ Bestimmtheitsmaß R^2 kann hier außerhalb von $[0, 1]$ liegen

Optimierung (mit Konstante)

```
b1 <- c(0,0,0)
x1 <- cbind(rep(1,n),x)
opt1 <- optim(b1, QS, method="BFGS", x=x1, y=y)    ## Optimierung (mit Konstante!)
opt1
sum( (x1 %*% opt1$par - mean(y))^2 )/sum( (y-mean(y))^2 )  ## R^2
```

Optimierung mit Gradient

$$QS = \sum_i (y_i - x_i^\top \beta)^2 = (y - \mathcal{X}\beta)^\top (y - \mathcal{X}\beta), \quad \frac{\partial QS}{\partial \beta} = -2\mathcal{X}^\top y + 2\mathcal{X}^\top \mathcal{X}\beta$$

```
D.QS <- function(b, x, y){ -2* t(x) %*% y + 2* t(x) %*% x %*% b }  ## Gradient

opt2 <- optim(b1, QS, D.QS, method="BFGS", x=x1, y=y)
opt2
sum( (x1 %*% opt2$par - mean(y))^2 )/sum( (y-mean(y))^2 )  ## R^2
```

Optimierung mit Intervalrestriktion (z.B. $\beta_j \geq 0$)

```
b2 <- c(0,0,0)
x1 <- cbind(rep(1,n),x)
opt3 <- optim(b1, QS, D.QS, method="BFGS", lower=0, x=x1, y=y)
opt3
sum( (x1 %*% opt3$par - mean(y))^2 )/sum( (y-mean(y))^2 )  ## R^2
```

Optimierung mit linearer Restriktion (z.B. $\beta_0 \geq 0$, $\beta_1 + \beta_2 \leq 2$)

$$\mathcal{U}\beta - c = \begin{pmatrix} 0 & -1 & -1 \\ 1 & 0 & 0 \end{pmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{pmatrix} - \begin{pmatrix} -2 \\ 0 \end{pmatrix} \geq 0$$

```
u <- cbind( c(0,1), c(-1,0), c(-1,0) )
c <- c(-2,0)

applyDefaults <- function(fn, ...) {   ## um weitere Parameter an QS, D.QS
  function(x) fn(x, ...)               ## zu übergeben
}

b4 <- rep(0.5,3)
opt4 <- constrOptim(b4, applyDefaults(QS, x=x1, y=y),
                    applyDefaults(D.QS, x=x1, y=y), ui=u, ci=c)
opt4
sum( (x1 %*% opt4$par - mean(y))^2 )/sum( (y-mean(y))^2 )  ## R^2
```

8.2 Interpolation

→ `approx` für lineare, `spline` bzw. `interpSpline` für Spline-Approximation

```
x <- seq(-5,5,by=1)
y <- sin(x)

xx <- seq(-5,5,by=0.1)
y.approx <- approx(x,y, xout=xx)$y
yy <- sin(xx)

plot(xx,yy, type="l", col="green")
lines(xx,y.approx, lwd=2)

library(splines)
sp <- interpSpline(x,y)
lines(predict(sp,xx), col="red")
```

8.3 Numerische Integration

→ `integrate` für 1-dimensionale, `adapt` für mehrdimensionale Integration

```
pnorm(0)

it <- integrate(dnorm, -Inf,0)
it

attributes(it)     ## Ergebnis ist Objekt der Klasse "integrate"

it$value

pmvnorm(c(0,0))
pmvnorm(c(0,0))[[1]]

library(adapt)
it <- adapt(2, c(-Inf,-Inf), c(0,0), functn=dmvnorm)

attributes(it)     ## Ergebnis ist Objekt der Klasse "integration"

it$value
```

9 Einstieg ins Programmieren

9.1 Funktionen

```
myfun <- function(x, a){
  r <- a*sin(x)
  return(r)
}
myfun(pi/2,2)

myfun1 <- function(x, a){ a*sin(x) }      ## dasselbe kürzer
myfun1(pi/2,2)

myfun2 <- function(x, a=1){               ## opt. Parameter mit Defaultwert=1
  a*sin(x)
}
myfun2(pi/2,2)
myfun2(pi/2)

myfun3 <- function(x, a=NULL){            ## opt. Parameter ohne Defaultwert
  if (!is.null(a)){ a*sin(x) }else{ cos(x) }
}
myfun3(pi/2,2)
myfun3(pi/2)
```

```
myfun4 <- function(x, a=1){
  r1 <- a*sin(x); r2 <- a*cos(x)
  return(r1=r1,r2=r2)                ## zwei Ergebnisse (depreciated!)
}
myfun4(pi/2)

myfun5 <- function(x, a=1){
  r1 <- a*sin(x); r2 <- a*cos(x)
  return(list(r1=r1,r2=r2))          ## ein Ergebnis (Liste!)
}
myfun5(pi/2)

myfun6 <- function(x, a=1, b=2){
  r1 <- a*sin(x); r2 <- b*cos(x)
  return(list(r1=r1,r2=r2))
}
myfun6(pi/2)                         ## a=1, b=2 (Defaults)
myfun6(pi/2,1,2)                     ## a=1, b=2 (explizit gegeben)

myfun6(pi/2,2)                       ## a=2, b=2 (nur a explizit gegeben)
myfun6(pi/2,a=2)                     ## a=2, b=2 (nur a explizit gegeben)

myfun6(pi/2,b=3)                     ## a=1, b=3 (nur b explizit gegeben)
```

→ Inputparameter können (wenn sinnvoll) weggelassen werden; mehrere Outputparameter sind eigentlich Listenelemente

9.2 Bedingte Anweisungen, Schleifen

- `if` & Co.

```
x<- 1; if (x==2){ print("x=2") }
x<- 1; if (x==2){ print("x=2") }else{ print("x!=2") }
```

- `for` & `repeat`

```
for (i in 1:4){ print(i) }
for (i in letters[1:4]){ print(i) }
i <- 0; while(i<4){ i <- i+1; print(i)}
i <- 0; repeat{ i <- i+1; print(i); if (i==4) break }
```

- weitere: `ifelse`, `switch`

9.3 “Mengenlehre”

```
a <- 1:3; b <- 2:6; a %in% b; b %in% a
a <- c("A","B"); b <- LETTERS[2:6]; a %in% b; b %in% a
```

9.4 Packages

- Packages umfassen (eine oder) mehrere Funktionen, werden mit `library(<Package-Name>)` geladen, in einem Package verfügbare Funktionen können mit `library(help=<Package-Name>)` abgefragt werden
- zum Erstellen eigener Packages gibt es zwei hilfreiche Funktionen

  `package.skeleton(<Package-Name>)`
  erstellt die Verzeichnisstruktur des Packages mit Templates für die notwendigen Files

  `prompt(<Funktion>)`
  erstellt ein Template für den Hilfetext zur Funktion
- Kollektionen von Packages heißen Bundles
- Packages oder Bundles installiert man unter Windows mit dem entsprechenden Menüpunkt, unter Unix/Linux mit `install.packages` oder mit `R CMD INSTALL <Package-...>.tar.gz`

9.5 DLLs

C-Funktion:

```
#include <stdlib.h>
#include <math.h>

/* Compile into shared library: gcc -shared -O2 -o mydll.so mydll.c */

int mysum(double *dim, double *x, double *y, double *z)
{
    long i, n;
    n=dim[0];

    for (i=0; i<n; i++)   /* loop over obs  */
    {
        z[i] = x[i] + y[i];
    }
    printf ("mysum in C\n");
    return 0;
}
```

Aufruf in R:

```
dyn.load("mydll.so")                                    ## DLL laden
is.loaded("mysum")                                      ## "mysum" ist da?

d <- 3
x <- 1:3
y <- 4:6
z <- rep(0,3)

r <- .C("mysum", dim=d, x=x, y=y, z=z )                 ## das geht schief!
r$z

d <- as.double(3)
x <- as.double(1:3)
y <- as.double(4:6)
z <- rep(0.0,3)

r <- .C("mysum", dim=d, x=x, y=y, z=z )                 ## so geht's
r$z
z                                                       ##    -> z ist immer noch 0

r <- .C("mysum", dim=d, x=x, y=y, z=z, DUP=FALSE)       ## oder so (ohne Kopie der Param.)
r$z
z                                                       ##    -> z enthält das Ergebnis

dyn.unload("mydll.so")                                  ## DLL unload
```

9.6 Tipps & Tricks

- Syntaxhighlightening (und R in (X)Emacs integrieren):
  ESS = “emacs speaks statistics” von http://ess.r-project.org/ downloaden und in `.emacs` einbinden:
  `(load "<Pfad zu ESS>/ess-5.1.24/lisp/ess-site")`
- Syntaxhighlightening für Windows gibt es auch in WinEdt (http://cran.at.r-project.org/contrib/extra/winedt)
- Runden und Formatieren von Zahlen geht mit `round`, `floor`, `ceiling`, `signif`, `formatC`
- Strings (character vectors) können bearbeitet werden mit `paste`, `substr`, `nchar`, `strsplit`, `toupper`, `tolower`, `sub`
- Datumsgenerierung mit `as.POSIXlt` und `strptime`, z.B.
  ```
  as.POSIXlt( strptime("20050101","%Y%m%d"))+(0:364)*86400
  ```
  erzeugt alle Tage des Jahres 2005;

```
d <- as.POSIXlt( strptime("20050926","%Y%m%d")); d$wday
```
gibt den Wochentag des 26.9.2005 an

- mit `system` kann man Betriebssystemkommandos ausführen, z.B. unter Linux: `system("cal 09 2005")`
- die Funktionen `xtable` (Package: `xtable`) und `latex` (Package: `Hmisc`) können R-Objekte als Latex-Kode speichern
- mit `eval` und `parse` können Zeichenketten als Ausdrücke ausgewertet werden:

```
eval( parse( text=paste("x.",as.character(1:2)," <- 0",sep="") ) )
print(x.1)
```

- es gibt in R zwei Verfahren für OOP: S3- und S4-Klassen; zur Information über die Komponenten von S3-Klassen (älterer Ansatz) sind die Funktionen `class`, `attributes` nützlich während für S4-Klassen (neuerer Ansatz) `getClass`, `slot`, `slotNames` verwendet werden
- Methoden können klassenabhängig sein, z.B. erhält man mit `methods(print)` alle zur Funktion gehörenden Methoden

Literatur

Becker, R. A. and Chambers, J. M. (1984). *S. An Interactive Envrionment for Data Analysis and Graphics*, Wadsworth and Brooks/Cole, Monterey.

Becker, R. A., Chambers, J. M. and Wilks, A. R. (1988). *The New S Language*, Chapman & Hall, London.

Chambers, J. M. and Hastie, T. J. (1992). *Statistical Models in S*, Chapman & Hall, London.

Dalgaard, P. (2002). *Introductory Statistics with R*, Springer. ISBN 0-387-95475-9.
URL: *http://www.biostat.ku.dk/ pd/ISwR.html*

Ligges, U. (2005). *Programmieren mit R*, Springer-Verlag, Heidelberg. ISBN 3-540-20727-9, in German.
URL: *http://www.statistik.uni-dortmund.de/ ligges/PmitR/*

Murrell, P. (2005). *R Graphics*, Chapman & Hall/CRC, Boca Raton, FL. ISBN 1-584-88486-X.
URL: *http://www.stat.auckland.ac.nz/ paul/RGraphics/rgraphics.html*

Venables, W. N. and Ripley, B. D. (2000). *S Programming*, Springer. ISBN 0-387-98966-8.
URL: *http://www.stats.ox.ac.uk/pub/MASS3/Sprog/*

Venables, W. N. and Ripley, B. D. (2002). *Modern Applied Statistics with S. Fourth Edition*, Springer. ISBN 0-387-95457-0.
URL: *http://www.stats.ox.ac.uk/pub/MASS4/*