

Vorbereitungsseminar für Abschlussarbeiten

Einführung in R

Thomas Kneib

SoSe 2012

1 Die statistische Software R

- Open Source Statistik-Software.
- Kompilierte Versionen für alle gängigen Betriebssysteme und Source-Code erhältlich unter

`http://www.r-project.org`

- Kombiniert
 - umfangreiche statistische Methoden,
 - flexible Grafikerstellung,
 - vollständige Programmierumgebung.
- Benutzer können Ihre eigenen Erweiterungs-Pakete (Packages) schreiben und diese im Comprehensive R Archive Network (CRAN) zugänglich machen.
- Lingua Franca der Statistik und (zumindest im akademischen Bereich) dominierend.

- Bedienung (fast) ausschließlich über die Kommandozeile.
- R ist case-sensitive.
- Hilfe:
 - Für spezielle Funktionen: `help("function")`, `?function`.
 - Volltextsuche: `help.search("text")`, `??"text"`.
 - Hilfe-Startseite: `help.start()`.
 - Suche auf <http://www.r-project.org>
 - “See Also”-Abschnitte ähnlicher Hilfeseiten.

- Editoren:
 - Tinn-R für Windows (<http://www.sciviews.org/Tinn-R/>).
 - RStudio für Windows, Mac, Linux (<http://www.rstudio.org/>).
 - Notepad++ für Windows (<http://notepad-plus-plus.org/>)
 - JGR für Windows, Mac, Linux (<http://rforge.net/JGR/>).
 - Emacs Speaks Statistics (EES) für Emacs, Xemacs, etc.
 - Allgemeine Übersicht: http://www.sciviews.org/_rgui/.

2 Grundlagen

- Kommentare beginnen mit #
- R ist auch ein großer Taschenrechner.
 - Operatoren: +, -, *, /, ^
 - `help("+")`
 - R hält die üblichen Regeln zur Punkt- vor Strichrechnung ein.
 - Klammerung von Ausdrücken über (...).
 - Ganzzahlige Division: `%/%`
 - Rest der ganzzahligen Division: `%%`

- Neben den Grundrechenarten gibt es zahlreiche mathematische Funktionen, z.B.
 - `exp`, `log`
 - `sqrt`
 - `sin`, `cos`, `tan`, `atan`, ...
 - `factorial`, `choose`, ...
- Vergleich von Werten:
 - `==`, `!=`, `>`, `>=`, `<`, `<=`
 - `all.equal`

- Die Ergebnisse von Berechnungen lassen sich in Variablen abspeichern:
 - `x <- 7`
 - `x = 7`
 - `7 -> x`
 - `print(x)`

- Einfache Datentypen:
 - Logisch: TRUE, FALSE, T, F
 - Integer: 1, 12^3, 42
 - Numerisch: 1.0, 3.1415297, NaN, Inf, -Inf
 - Zeichenketten: "test", "Hallo Welt"
 - Fehlende Werte: NA
 - Konstanten: pi

- Logische Operatoren: `&`, `|`
- Bestimmung von Datentypen:
 - `mode(x)`
 - `is.numeric(x)`
 - `is.character(x)`

- Arbeiten mit Zeichenketten:
 - paste
 - cat
 - substr
 - strsplit

3 Vektoren

- Vektoren kombinieren Elemente des gleichen Typs.
- Erstellung z.B. über die Funktion `c` (combine):
 - `x <- c(5,2,8,99)`
 - `x <- c(x,3,4)`
 - `y <- c("A","B")`
 - `z <- c(x,y)`
- Eigenschaften eines Vektors:
 - Länge: `length(x)`
 - Typ: `mode(x)`

- Sequenzen: `seq(from=, to=, by=)`
 - `seq(from=0, to=10, by=2)`
 - `seq(from=0, to=10)`
 - `seq(to=10)`
 - `1:10`

- Wiederholungen: `rep(times=, length=, each=)`
 - `rep(0, times=5)`
 - `rep(1:3, times=5)`
 - `rep(1:3, length=5)`
 - `rep(1:3, each=5)`

- Zugriff auf Elemente:
 - Angabe der interessierenden Elemente: `x[c(1,5,8)]`, `x[1:5]`
 - Ausschluss von nicht interessierenden Elementen: `x[-1]`, `x[-c(2,4,5)]`
 - Angabe einer Bedingung: `x[x>4]`, `x[x<5 & x%%2==0]`
 - Komplexe Verschachtelungen möglich
- Auffinden spezieller Elemente:
 - `which(x<3 & x%%2==0)`

- Rechnen mit Vektoren:
 - R rechnet elementweise mit Vektoren: $x+1$, $x*y$,
 - Ordnen und sortieren: `order(x)`, `sort(x)`

4 Matrizen

- Erstellen von Matrizen:
 - `m <- matrix(1:12, ncol=4, nrow=3)`
 - `m <- matrix(1:12, ncol=4, nrow=3, byrow=T)`
- Zugriff auf Elemente:
 - Einzelne Elemente: `m[1,2]`
 - Spalten: `m[,1]`
 - Zeilen: `m[2,]`
 - Kombinationen: `m[2:3,-4]`

- Eigenschaften einer Matrix:
 - Dimensionen: `dim(m)`
 - Typ: `mode(m)`
- Erstellung über die Kombination von Vektoren:
 - Verbinden als Spalten: `m <- cbind(x,y)`
 - Verbinden als Zeilen: `m <- rbind(x,y)`

- Rechnen mit Matrizen:
 - Transponieren: `t(m)`
 - Matrixmultiplikation (bei passenden Dimensionen): `m1%*%m2`
 - Inversion: `solve(m)`
 - Lösen von Gleichungssystemen: `solve(m, rhs)`
 - Determinante: `det(m)`
 - Rang: `qr(m)$rank`
 - Definition von Diagonalmatrizen mit den Werten aus dem Vektor `x` auf der Diagonalen: `diag(x)`
 - Extraktion der Diagonalen: `diag(m)`
- Erweiterung von Matrizen auf höhere Dimensionen: `array`

5 Listen

- Erzeugen von Listen:
 - `l <- list(vector=1:5, char="ABC", mat=matrix(1:4,ncol=2,nrow=2))`
 - `names(l)`
- Zugriff auf die Elemente der Liste:
 - Per Name: `l$char`
 - Per Index: `l[[2]]`

6 Data Frames

- Data frames sind die typische Möglichkeit um Datensätze abzuspeichern.
- Zwei Sichtweisen auf Data Frames:
 - Matrix mit zusätzlichen Attributen und Eigenschaften.
 - Liste in der alle Elemente die gleiche Länge haben müssen.
- Erzeugen von Data Frames:
 - `d <- data.frame(v1=c(1,2,3), v2=rep(1,3))`

- Einlesen von Datensätzen:
 - `d <- read.table(file, header = FALSE, sep = "", dec = ".")`
 - `d <- read.csv(file, header = TRUE, sep = ",", dec=".")`
 - foreign-Paket: `read.dta`, `read.spss`,
- Speichern von Datensätzen:
 - `write.table(x, file, quote = TRUE, sep = " ", eol = "\n",
 row.names = TRUE, col.names = TRUE)`

- Anschauen von Datensätzen:
 - `fix(d)`
 - `head(d, n=10)`
 - `names(d)`
- Zugriff auf Variablen:
 - Per Namen: `d$spaltenname`
 - Per Index (Liste): `d[[2]]`
 - Per Index (Matrix): `d[,2]`

- Faktorvariablen sollten auch als Faktoren gespeichert werden:
 - Umwandeln in einen Faktor: `factor`, `as.factor`
 - Umkodieren eines Faktors: `recode` (aus dem Paket `car`)

7 Grafiken

- Darstellung von diskreten Häufigkeitsverteilungen:
 - Balkendiagramm: `barplot`
 - Kuchendiagramm: `pie`
- Darstellung stetiger Häufigkeitsverteilungen:
 - Histogramm: `hist`
 - Kerndichteschätzung: `density`
 - Boxplot: `boxplot`

- Generische Plot-Funktion: `plot`
 - `type`: Typ der Grafik (Punkte, Liniensegmente, Stufenfunktion, . . .)
 - `pch`: Plot-Charakter
 - `main`: Überschrift
 - `xlab`, `ylab`: Beschriftung der x- und y-Achse
 - `xlim`, `ylim`: Wertebereich der x- und y-Achse
 - `cex`, `cex.axis`, `cex.lab`, `cex.main`, . . . : Faktor zur Vergrößerung / Verkleinerung der Schriftgröße relativ zum Default.
 - `col`, `col.axis`, `col.lab`, `col.main`, . . . : Farbe der Beschriftung.
 - `lty`, `lwd`: Typ und Breite der Linien

- Ergänzungen zu einer bestehenden Grafik:
 - `lines`
 - `segments`
 - `points`
 - `text`
 - `arrows`
 - `abline`
 - `rect`
 - `polygon`
 - `axis`
 - `box`
- Option `xpd=TRUE` erlaubt das ergänzen außerhalb des plot-Bereichs.

- `par`: Mit Hilfe von `par` werden global Einstellungen für Grafiken definiert.
 - `mfrow`: Aufteilung des Grafik-Fensters in verschiedene Teilgrafiken.
 - `las`: Ausrichtung der Label-Beschriftungen an den Achsen.
 - Alternative zu `mfrow` mit mehr Optionen: `layout`.
- Eine `plot`-Funktion existiert für viele verschiedene R-Objekte (z.B. Ergebnisse eines linearen Modells).

- Darstellung von Oberflächen:
 - `image`
 - `contour`
 - `persp`

- Abspeichern von Grafiken:
 - Über das Menü (File -> Save As)
 - Per Befehl: pdf, postscript, jpeg, bmp, . . .

8 Praktische Hinweise zum Schluss

- Die Installation in ein Verzeichnis ohne Leerzeichen kann bestimmte Probleme vermeiden.
- Code am Besten in einem Editor entwickeln und abspeichern, um spätere Reproduzierbarkeit zu sichern.
- Code dokumentieren!
- Mit Hilfe von Sweave ist eine direkte Verbindung von R und $\text{\LaTeX}$ möglich (aber nicht Inhalt dieses Kurses).