

Blockpraktikum zur Statistik mit R

26. März 2012

Sören Gröttrup

Gliederung

- 1 Organisation und erste Schritte in R
 - Literatur- und sonstige Hinweise
 - Programmstart und Befehlsmodus
 - Funktionen und Argumenttypen
 - Variablen und Skripte
- 2 Datenstrukturen
 - Vektoren
 - Matrizen
 - Datentabellen
 - Listen
 - Arrays, Zeitreihen, ...
 - Einlesen aus externen Dateien
- 3 Programmierung
 - Funktionen in R schreiben
 - Schleifen und Abfragen

Gliederung

- 1 Organisation und erste Schritte in R
 - Literatur- und sonstige Hinweise
 - Programmstart und Befehlsmodus
 - Funktionen und Argumenttypen
 - Variablen und Skripte
- 2 Datenstrukturen
 - Vektoren
 - Matrizen
 - Datentabellen
 - Listen
 - Arrays, Zeitreihen, ...
 - Einlesen aus externen Dateien
- 3 Programmierung
 - Funktionen in R schreiben
 - Schleifen und Abfragen

Organisation

- ▶ 10:00 - 18:00 im SRA: Theorie und betreute Aufgabenbearbeitung
- ▶ Freitag Vormittags 10:00 - 12:00 Zeit für Aufgabenbearbeitung
- ▶ Mittagspause: ca. 12:15 - 14:00
- ▶ Es darf/soll in 2er Gruppen gearbeitet werden, um die Aufgaben zu lösen
- ▶ Materialien (Übungszettel, Folien, Lösungen, ...) befinden sich auf der Praktikums-Homepage: <http://wwwmath.uni-muenster.de/statistik/lehre/SS12/PrakStat/>

Literatur



Silke Ahlers

Einführung in die Statistik mit R

<http://wwwmath.uni-muenster.de/statistik/lehre/SS12/PrakStat/Skript.pdf>



Peter Dalgaard

Introductory Statistics with R

Springer



Christine Duller

Einführung in die nichtparametrische Statistik mit SAS und R

Springer



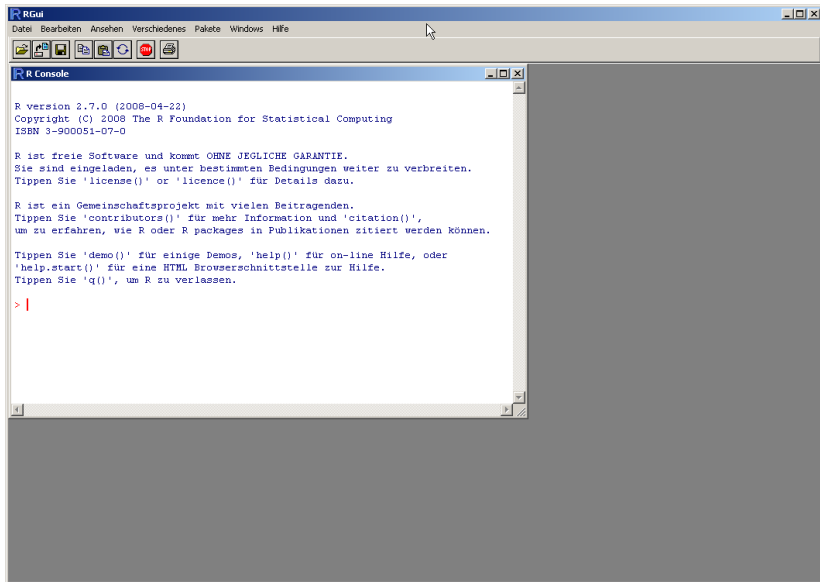
Fahrmeir, Künstler, Pigeot, Tutz

Statistik. Der Weg zur Datenanalyse

Springer

Programmstart

- ▶ Loggen Sie sich unter CentOS ein
- ▶ Öffnen Sie eine Konsole
- ▶ Führen Sie `rdesktop -f zivtserv.uni-muenster.de` aus
- ▶ Loggen Sie sich nun unter Windows ein
- ▶ Starten Sie R (Start → Programme → R)



The screenshot shows the R GUI interface. The main window is titled "RGui" and has a menu bar with "Datei", "Bearbeiten", "Ansehen", "Verschiedenes", "Pakete", "Windows", and "Hilfe". Below the menu bar is a toolbar with icons for file operations and help. A smaller window titled "R Console" is open, displaying the R startup message. The message includes the R version (2.7.0), copyright information (© 2008 The R Foundation for Statistical Computing), and instructions on how to use R, including how to get help and how to quit.

```
R version 2.7.0 (2008-04-22)
Copyright (C) 2008 The R Foundation for Statistical Computing
ISBN 3-900051-07-0

R ist freie Software und kommt OHNE JEGLICHE GARANTIE.
Sie sind eingeladen, es unter bestimmten Bedingungen weiter zu verbreiten.
Tippen Sie 'license()' or 'licence()' für Details dazu.

R ist ein Gemeinschaftsprojekt mit vielen Beitragenden.
Tippen Sie 'contributors()' für mehr Information und 'citation()',
um zu erfahren, wie R oder R packages in Publikationen zitiert werden können.

Tippen Sie 'demo()' für einige Demos, 'help()' für on-line Hilfe, oder
'help.start()' für eine HTML Browserschnittstelle zur Hilfe.
Tippen Sie 'q()', um R zu verlassen.

> |
```

Warum R als Statistiksoftware nutzen?

- ▶ Freie Software (kostenfrei, offen)
- ▶ Plattformunabhängig
- ▶ Funktionsbibliotheken für viele Anwendungen
- ▶ Erweiterbarkeit & Flexibilität
- ▶ Datenschnittstelle zu SPSS, SAS u. a. Statistikdatenformaten
- ▶ Gute Dokumentation & Online-Hilfen

Befehlsmodus

- ▶ R bietet eine interaktive Umgebung, den *Befehlsmodus*, in dem man Daten direkt eingeben und analysieren kann
- ▶ Befehlsmodus dient als *Taschenrechner*, z. B. können die Grundrechenarten $+$, $-$, $*$, $/$ direkt eingegeben werden
- ▶ Zum Potenzieren muss $^$ benutzt werden

Beispiel

- ▶ $4+5*5.7$
- ▶ $5/6-2$
- ▶ 2^3

Mathematische Funktionen

- ▶ Die Eingabe $2^{0.5}$ liefert das Ergebnis $2^{0.5} = \sqrt{2} \cong 1.414214$
- ▶ Einfacher: Eingabe von `sqrt(2)` (`sqrt` = square root)
- ▶ Auch andere mathematische Funktionen sind bereits in R implementiert, etwa Logarithmus, Sinus, Cosinus, ...

Beispiel

- ▶ `tan(7/8)`
 - ▶ `exp(3.72)`
 - ▶ `abs(sin(5))`
-
- ▶ Übersicht wichtiger Funktionen: <http://wwwmath.uni-muenster.de/statistik/lehre/SS12/PrakStat/R-Befehle.pdf>

Obligatorische und optionale Argumente einer Funktion

Zwei verschiedene Typen von Funktionsargumenten: *obligatorische* und *optionale*.

Beispiel:

- ▶ Funktion `round(x,digits)` rundet die Zahl `x` auf `digits` Stellen
- ▶ Die zu rundende Zahl `x` ist hierbei ein *obligatorisches Argument*
- ▶ `digits` dagegen ist *optional* mit Standardwert 0, d. h. wird es nicht im Funktionsaufruf übergeben, so rundet R auf eine ganze Zahl

Beispiel

- ▶ `round(x=sqrt(2), digits=3)`
- ▶ `round(x=sqrt(2))`

Argumentnamen

- ▶ Kennt man die Reihenfolge der Argumente im sogenannten *Kopf* der Funktion, so kann man Werte direkt eingeben
- ▶ Andernfalls: Eingabe mit „Name = .“ (Reihenfolge spielt keine Rolle)

Beispiel

- ▶ `round(sqrt(2), 3)`
- ▶ `round(digits=3, x=sqrt(2))`

Hilfeseiten

- ▶ Welche Argumente eine Funktion besitzt, lässt sich mit den Hilfeseiten herausfinden: `help(round)` oder kürzer `?round`
- ▶ Mit `args` lässt sich herausfinden, welche Argumente eine Funktion erhält, welche davon optional sind und welche Standardwerte sie in diesem Fall besitzen

Beispiel

- ▶ `help(cos)`
- ▶ `?choose`
- ▶ `args(round)`

Variablenzuweisung I

- ▶ Will man mit dem Resultat einer Funktionsauswertung weitere Berechnungen durchführen, so ist es sinnvoll das Ergebnis einer Variablen zuzuweisen
- ▶ Dies geschieht mit dem *Zuweisungsoperator* `<-`
- ▶ Links vom Operator steht der Name der Variablen, dem die Daten zugeordnet werden sollen, z. B. `y <- tan(7/8)`
- ▶ Eingabe des Variablennames im Befehlsmodus ruft Inhalt der Variablen auf

Beispiel

- ▶ `y <- tan(7/8)`
- ▶ `y`
- ▶ `y+y`
- ▶ `y <- 3*y`
- ▶ `y`

Variablenzuweisung II

- ▶ R achtet auf Groß- und Kleinschreibung: Die Eingabe von Y liefert einen Fehler
- ▶ Variablennamen dürfen aus Buchstaben, Zahlen und dem Punkt „.“ bestehen
- ▶ Sie beginnen aber immer mit einem Buchstaben
- ▶ Übergabe nach rechts mit `->`

Beispiel

- ▶ `2*y->z`
- ▶ `z`

Variablen im Workspace

- ▶ Auflistung aller im Workspace benutzten Variablen: `ls()`
- ▶ Variable löschen: `rm()`

Beispiel

- ▶ `ls()`
- ▶ `rm(z)`
- ▶ `z`

Skripte

Eine längere Funktion oder eine Abfolge von vielen Befehlen, sollten nicht direkt im Befehlsmodus definiert werden, sondern in einem *Skript*

- ▶ Unter *Datei* → *Neues Skript* kann man ein neues Skript erstellen
- ▶ Befehle ausführen: Markieren und `Strg + R` drücken
- ▶ Kommentare schreiben mit `#`, alle Zeichen dahinter werden ignoriert und nicht im Befehlsmodus ausgeführt
- ▶ Mit `Strg + S` speichert man ein Skript als `.R` Datei

Die Lösungen der Aufgaben müssen ebenfalls als R Skript gespeichert werden.

Gliederung

- 1 Organisation und erste Schritte in R
 - Literatur- und sonstige Hinweise
 - Programmstart und Befehlsmodus
 - Funktionen und Argumenttypen
 - Variablen und Skripte
- 2 Datenstrukturen
 - Vektoren
 - Matrizen
 - Datentabellen
 - Listen
 - Arrays, Zeitreihen, ...
 - Einlesen aus externen Dateien
- 3 Programmierung
 - Funktionen in R schreiben
 - Schleifen und Abfragen

Vektorenerstellung

- ▶ Vektoren erzeugt man in R mit der Funktion `c`
- ▶ Die Erzeugung eines Vektors mit den Daten x_1, \dots, x_n erhält man durch Eingabe von `c(x1, ..., xn)`
- ▶ Variablenzuweisung: Genauso wie mit “normalen” Zahlen

Beispiel

- ▶ `c(3,0,-4,16)`
- ▶ `c(sin(-5),-5.66, -5*6)`
- ▶ `Messung <- c(6,7,5,5,12)`
- ▶ `Messung`

Häufig genutzte Vektoren I

Es gibt eine Reihe von Funktionen, die spezielle Vektoren erstellen:

- ▶ Einen Vektor mit n Nullen erhält man mit `numeric(n)`
- ▶ Der *Doppelpunktoperator* `n:m` erstellt den Vektor $(n, n+1, \dots, m)$ im Fall $n < m$ bzw. den Vektor $(n, n-1, \dots, m)$ im Fall $n > m$
- ▶ Der *Sequenz-Befehl* `seq(from, to, by)` erstellt man den Vektor, dessen 1. Eintrag `from` ist und es folgen Werte im Abstand `by` bis zum Punkt `to` (bzw. dem nächstkleineren Wert, falls `to` kein Vielfaches)

Beispiel

- ▶ `numeric(10)`
- ▶ `1:10`
- ▶ `-3:-7`
- ▶ `seq(from=0,to=100,by=2)`

Häufig genutzte Vektoren II

- ▶ Will man das Intervall $[a, b]$ in n gleichgroße Stücke teilen:
`seq(from=a, to=b, length.out=n)`
- ▶ Mit dem *Repeat-Befehl* `rep(x, times=n)` wird der Vektor x sooft wiederholt, wie das Argument `times` angibt
 - ▶ Ist n eine natürliche Zahl so wird x genau n mal hintereinander geschrieben
 - ▶ Ist n ein Vektor gleicher Länge, so wird der i -te Eintrag von x genau n_i mal dupliziert

Beispiel

- ▶ `seq(0, 1, length.out=1000)`
- ▶ `rep(1:2, 3)`
- ▶ `rep(1:5, 5:1)`

Komponentenzugriff I

Auf die Einträge eines Vektors x greift man mit $x[n]$ zu. Beispiele:

- ▶ Die i -te Komponente von x erhält man durch $x[i]$
- ▶ Die 2., 4. und 7. Komponente erhält man durch $x[c(2,4,7)]$
- ▶ Negative Werte lassen den entsprechenden Eintrag weg, mit $x[c(-1,-3)]$ würde man alle Einträge bis auf den 1. und 3. erhalten
- ▶ Negative und positive Werte dürfen nicht gemischt werden

Beispiel

- ▶ `Messung[4]`
- ▶ `Messung[2:5]`
- ▶ `Messung[-3]`

Logische Operatoren

Will man Komponenten nach Bedingungen auswählen, so geschieht dies unter Benutzung von *logischen Operatoren*

==	gleich	!=	ungleich
<	kleiner	>	größer
<=	kleiner gleich	>=	größer gleich

Diese Operationen liefern als Ergebnis TRUE oder FALSE bzw. einen Vektor mit diesen Einträgen

Beispiel

- ▶ $4 < 2$
- ▶ $2 * 6 == 12$
- ▶ $\text{Messung} \geq 7$

Komponentenzugriff II

Besteht bei `x[n]` der Vektor `n` aus `TRUE` und `FALSE` Einträgen, so enthält `x[n]` den i -ten Eintrag von `x`, falls `ni` `TRUE` ist Beispiel:

- ▶ `Messung[Messung >= 7]` erhält man alle Messungen, die einen Wert größer (oder gleich) 7 besitzen
- ▶ Die Positionen dieser Werte innerhalb des Vektors kann man mit der Funktion `which` herausfinden

Beispiel

- ▶ `Messung[Messung>6]`
- ▶ `which(Messung>=7)`
- ▶ `Messung[Messung==5]`

Logische Vektorfunktionen

- ▶ `any(n)` überprüft, ob in `n` *mindestens* ein TRUE vorkommt
- ▶ `all(n)` überprüft, ob in `n` *alle* Einträge TRUE sind
- ▶ TRUE und FALSE entsprechen den Zahlen 1 bzw. 0

Beispiel

- ▶ `any(c(TRUE, FALSE, TRUE))`
- ▶ `any(Messung < 6)`
- ▶ `all(Messung < 6)`
- ▶ `exp(TRUE) + 5 * TRUE`

Weitere Vektorfunktionen

Es gibt eine Fülle nützlicher Funktionen, die man auf einen Vektor anwenden kann

- ▶ Mit `sum(x)` erhält man etwa die Summe alle Komponenten von `x`
- ▶ Mit `min(x)` das Minimum der Einträge, mit `max(x)` das Maximum
- ▶ Mit `length(x)` die Anzahl der Komponenten von `x`
- ▶ Mit `sort(x)` sortiert man `x` *aufsteigend*, das optionale Argument `decreasing` ändert dies

Beispiel

- ▶ `prod(Messung)`
- ▶ `sort(Messung)`
- ▶ `sort(Messung, decreasing = TRUE)`

Vektorarithmetik I

- ▶ Auch elementare Funktionen (Addition einer Zahl, Sinusfunktion, etc.) lassen sich auf Vektoren anwenden
- ▶ Die Auswertung geschieht *komponentenweise*
- ▶ Vorsicht: Der Doppelpunktoperator bindet stärker als Addition, Multiplikation, usw., d. h. $1:5+1$ ist von $1:(5+1)$ verschieden

Beispiel

- ▶ $\log(\text{Messung})$
- ▶ $\text{Messung} * 4$
- ▶ $\text{round}(\exp(\text{Messung}), 2)$
- ▶ $1:5+1$
- ▶ $1:(5+1)$

Vektorarithmetik II

- ▶ Ebenso nützlich ist die Vektorarithmetik $v+w$, $v*w$, $v^{\wedge}w$, ... für Vektoren $v = (v_1, \dots, v_n)$ und $w = (w_1, \dots, w_m)$
- ▶ Für $m = n$ geschieht die Auswertung komponentenweise
- ▶ Ist n ein Vielfaches von m , so geschieht die Auswertung zyklisch, d. h.

$$v + w = (v_1 + w_1, \dots, v_m + w_m, v_{m+1} + w_1, \dots, v_n + w_m)$$

Der entstehende Vektor hat demnach Länge n

Beispiel

- ▶ Messung - 1:5
- ▶ $c(8,2,4,3) + c(-10,20)$
- ▶ $(1:6)^{\wedge}(2:3)$

Qualitative Merkmale (Faktoren)

- ▶ Für die Eingabe von Daten bei einem qualitativem Merkmal müssen die Komponenten aus *Zeichenketten* bestehen, die in Hochkommata eingeschlossen sind, z. B. `c("blau", "grün", "gelb")`
- ▶ Zur Beseitigung der Hochkommata dient die Funktion `factor`, diese macht aus einem Vektor ein *Faktor*, d. h. ein qualitatives Merkmal
- ▶ Die *Level* (unterschiedliche Ausprägungen) des Faktors `f` erhält man mit `levels(f)`

Beispiel

- ▶ `Geschlecht <- c("m", "w", "w", "m", "w")`
- ▶ `Geschlecht <- factor(Geschlecht)`
- ▶ `Geschlecht`
- ▶ `levels(Geschlecht)`
- ▶ `Messung[Geschlecht=="w"]`

Einträge benennen

Die Einträge eines Vektors v lassen sich für einen einfacheren Zugriff benennen

- ▶ Syntax: `v <- c(Name1=Wert1, Name2=Wert2, ...)`
- ▶ Die Ausgabe im Befehlsmodus ist dann zweizeilig: In der 1. Zeile stehen die Namen, in der 2. die Einträge (Werte) des Vektors
- ▶ Alternativer Zugriff auf die Einträge von v mit `v["Name1"]`

Beispiel

- ▶ `v <- c(Vorname="Max", Nachname="Mustermann")`
- ▶ `v`
- ▶ `v["Nachname"]`

Einträge umbenennen

- ▶ Abfrage der Namenseinträge durch `names(v)`
- ▶ Umbenennen mit `names(v) <- n` wobei `n` ein Vektor gleicher Länge wie `v` ist, der aus Zeichenketten besteht
- ▶ Löschung mit `names(v) <- NULL`

Beispiel

- ▶ `names(Messung) <- c("a", "b", "c", "d", "e")`
- ▶ `Messung`
- ▶ `Messung["e"]`

Die Abschnitte 1 (Grundlagen) und 2 (Vektoren) des Aufgabenblattes können jetzt bearbeitet werden.

Matrizen

- ▶ Mit dem Befehl `matrix(data,nrow,ncol,byrow(=FALSE))` lässt sich eine *Matrix* in R erzeugen.
- ▶ `data` ist der Vektor, mit dem die Matrix gefüllt werden soll
- ▶ `nrow` die Anzahl der Zeilen, `ncol` die Anzahl der Spalten (es genügt, wenn man eines angibt)
- ▶ Optional: `byrow = TRUE` gibt an, dass `data` Zeilenweise in die Matrix eingefüllt wird

Beispiel

- ▶ `matrix(1:9,3)`
- ▶ `matrix(1:12,3,byrow=TRUE)`
- ▶ `A<-matrix(c(3,4,0,1),2)`
- ▶ `B<-matrix(9:6,2)`

Zugriff auf Matrizeneinträge

Auf die Einträge einer Matrix greift man wieder mit dem `[]` Operator zu. Hier muss dieser jedoch die Koordinate des Eintrags enthalten.

- ▶ `A[3,2]` liefert den 3. Zeileneintrag der 2. Spalte der Matrix `A`
- ▶ Mit `A[,2]` erhält man die komplette 2. Spalte von `A`
- ▶ Mit `A[3,]` die komplette 3. Zeile
- ▶ Mit `A[c(2,7,13),]` die 2., 7. und 13. Zeile (als Matrix)

Beispiel

- ▶ `A[1,1] + A[2,2]`
- ▶ `A[2,] * A[,1]`

Matrizenfunktionen

Auch für Matrizen gibt es in R eingebaute Funktionen

- ▶ Dimensionen einer Matrix: `dim(A)`
- ▶ Transponieren: `t(A)`
- ▶ Matrizenmultiplikation: `A %*% B` (Vorsicht: `A * B` multipliziert komponentenweise)
- ▶ Determinantenberechnung: `det(A)`
- ▶ Lineares Gleichungssystem $Ax = b$ lösen mit `solve(A,b)`
- ▶ ...

Beispiel

- ▶ `A %*% B`
- ▶ `det(A)`
- ▶ `solve(A,c(5,2))`

Die apply Funktion

Wendet man Funktionen wie `sum`, `min` oder `max` auf die Matrix an, so werden alle Einträge der Matrix berücksichtigt.

Beispiel

- ▶ `sum(A)`
- ▶ `min(A)`

Mit `apply(X, Margin, FUN)` führt man die Funktion `FUN` nur auf Zeilen (`MARGIN=1`) oder Spalten (`MARGIN=2`) der Matrix `X` aus.

Beispiel

- ▶ `apply(A, 1, sum)`
- ▶ `apply(A, 2, min)`

Datentabellen

- ▶ Nachteil von Matrizen: Alle Einträge sind vom gleichen Typ!
- ▶ In *Datentabellen* können Werte von Merkmalen *unterschiedlichen* Typs (Zahlen, Faktoren) gespeichert werden
- ▶ Jedem Merkmal muss die gleiche Anzahl von Beobachtungen zugrundeliegen
- ▶ Befehl: `data.frame(merkmal1=werte1,merkmal2=werte2,...)`

Beispiel

- ▶ `Tabelle <- data.frame(Geschlecht = c("m", "w", "w"),
Alter = c(24,32,20))`
- ▶ `Tabelle`

Zugriff auf Datentabellen

- ▶ Zugriff auf Einträge wie bei Matrizen mit dem `[]` Operator
- ▶ Auf die Spalten kann man mit dem `$` Operator zugreifen, d. h. die „Alter“-Spalte erhält man durch `Tabelle$Alter`

Beispiel

- ▶ `Tabelle[3,2]`
- ▶ `Tabelle[2,]`
- ▶ `Tabelle$Geschlecht`

Hinzufügen von Spalten oder Zeilen

- ▶ Spalten hinzufügen mit `cbind(x1, x2, ...)`
- ▶ Die Funktion “verbindet” die Datentabellen (oder Vektoren, Matrizen) `x1, x2, ...` zu einer Datentabelle (oder Matrix)
- ▶ `x1, x2, ...` müssen die gleiche Anzahl von Zeilen besitzen, oder die Zeilenanzahlen sind Vielfache voneinander (zyklisches Verbinden)
- ▶ Analog: Zeilen verbinden mit `rbind(x1, x2, ...)`

Beispiel

- ▶ `rbind(Tabelle, c("m",27))`
- ▶ `cbind(B, c(9,4))`
- ▶ `rbind(1:3, 9:7, -2:0)`
- ▶ `rbind(matrix(1:16,4),0,-1:-2,101:104)`

Teiltabellen

- ▶ Die Funktion `subset(x, condition, select)` bietet die Möglichkeit, aus einer Tabelle `x` kleinere Datensätze gemäß der Bedingung `condition` auszuwählen
- ▶ Mit dem optionalen Argument `select` ist es möglich, nur gewisse Spalten auszuwählen

Beispiel

- ▶ `subset(Tabelle, Geschlecht == "w")`
- ▶ `subset(Tabelle, Geschlecht == "w", select = Alter)`

split Funktion

- ▶ Die Funktion `split(x,f)` teilt Tabelle `x` in Gruppen ein, die durch den Faktor (Zeichenkettenvektor) `f` definiert werden
- ▶ Das Ergebnis ist eine Liste mit sovielen Einträgen, wie `f` Level besitzt
- ▶ Jeder Eintrag der Ergebnisliste ist eine Tabelle und es gilt:
Die Zeile i von `x` befindet sich in der Tabelle zur Gruppe g , falls der i -te Eintrag in `f` genau g ist

Beispiel

- ▶ `s <- split(Tabelle, Tabelle$Geschlecht)`
- ▶ `s`
- ▶ `s$m`
- ▶ `s$w`

Listen

Eine Liste besteht aus Elementen beliebigen Typs und Einträgen beliebiger Länge

- ▶ Erstellung mit `l<-list(name1=wert1, name2=wert2, ...)`
- ▶ Zugriff auf das 1. Element mit `l$name1` oder `l[[1]]`

Beispiel

- ▶ `l<-list(Text=c("bla","blu"), Mat=A)`
- ▶ `l`
- ▶ `l[[1]]`
- ▶ `l$Mat`
- ▶ `s`

Einträge einer Liste herausfinden

Viele Funktionen in R liefern eine Liste als Ergebnis zurück. Die Namen der Einträge einer Liste `l` findet man mit Hilfe von `str(l)` heraus. Beispiel:

- ▶ Die Funktion `eigen(A)` berechnet numerisch Eigenwerte und -vektoren der Matrix `A`
- ▶ Wendet man `str` darauf an, erhält man das Resultat

```
List of 2
 $ values : num [1:2] 3 1
 $ vectors: num [1:2, 1:2] 0.447 0.894 0 1
```

Beispiel

- ▶ `eig<-eigen(A)`
- ▶ `str(eig)`
- ▶ `eig$values`
- ▶ `eig$vectors`

Weitere Datenstrukturen

Es gibt noch einige weitere Datenstrukturen, etwa

- ▶ *Array* = d -dimensionalen Datensatz (R Befehl: `array`)
- ▶ *Zeitreihe* = Vektor mit Zeitangabe (R Befehl: `ts`)
- ▶ ...
- ▶ Die Struktur der Variablen v lässt sich mit `str(v)` herausfinden

Beispiel

- ▶ `str(Tabelle)`
- ▶ `str(A)`
- ▶ `str(l)`

Einlesen von Tabellen aus externen Dateien

- ▶ Tabellen aus externen Dateien einlesen: Ein Backslash \ im Pfad muss mit \\ angegeben werden (unter Windows)

<code>read.table("Pfad")</code>	liest externen Datensatz ein
<code>read.csv("Pfad")</code>	liest durch Kommata getrennte Spalten
<code>read.delim("Pfad")</code>	liest Tab-getrennte Spalten

- ▶ Argumente der Funktionen:

<code>header = TRUE</code>	In 1. Zeile stehen die Spaltennamen
<code>sep</code>	Wie sind Spalteneinträge getrennt? ("," oder ".")
<code>dec</code>	Wie ist Dezimalpunkt angegeben? ("," oder ".")

- ▶ Tabelle wird in R als `data.frame` hinterlegt.

Gliederung

- 1 Organisation und erste Schritte in R
 - Literatur- und sonstige Hinweise
 - Programmstart und Befehlsmodus
 - Funktionen und Argumenttypen
 - Variablen und Skripte
- 2 Datenstrukturen
 - Vektoren
 - Matrizen
 - Datentabellen
 - Listen
 - Arrays, Zeitreihen, ...
 - Einlesen aus externen Dateien
- 3 Programmierung
 - Funktionen in R schreiben
 - Schleifen und Abfragen

Eigene Funktionen schreiben

Eine eigene Funktion f erstellt man in R mit

```
f <- function(Argumente) {  
  Körper der Funktion  
  return(Ergebnis)  
}
```

- ▶ *Argumente* müssen in der Form $\text{arg1}, \text{arg2}, \dots$ angegeben werden, optionale Argumente gibt man durch arg=Wert an
- ▶ Im *Körper der Funktion* können beliebig viele Anweisungen stehen
- ▶ Alle im Körper definierten Variablen sind *lokal*, d. h. man kann sie außerhalb der Funktion nicht nutzen
- ▶ Das *Ergebnis* ist das, was die Funktion am Ende "auspuckt", also etwa eine Zahl, ein Vektor oder eine Liste

Beispiel: eigene Funktion schreiben

Wir wollen eine Funktion `f` schreiben, die $f(x, y) = x^y - x$ berechnet. `y` soll dabei ein optionales Argument mit Standardwert 2 sein. Dies geht mit

```
f <- function(x, y=2) {  
  erg<-x^y-x  
  return(erg)  
}
```

Danach steht `f` zur Verfügung und wird auch unter `ls()` aufgelistet

Beispiel

- ▶ `f(3)`
- ▶ `f(3,4)`
- ▶ `f(1:9,4)`

Abkürzungen

In einigen Spezialfällen lässt sich der Code übersichtlicher gestalten

- ▶ Auf die Eingabe von "return" kann verzichtet werden: Die letzte Berechnung im Körper wird dann zurückgegeben (dies darf keine Variablenzuweisung sein!)
- ▶ Ist der Körper der Funktion leer, so kann auf die geschweiften Klammern verzichtet werden (in der Funktion darf dann nur eine Berechnung stehen!)
- ▶ Will man mehrere Anweisungen in *eine* Zeile schreiben, muss man sie mit einem Semikolon voneinander trennen

Beispiel

- ▶ `f2 <- function(x,y=2) { erg<-x^y-x; return(erg) }`
- ▶ `f3 <- function(x,y=2) { erg<-x^y-x; erg }`
- ▶ `f4 <- function(x,y=2) x^y-x`

Allgemeine Programmierhinweise I

- ▶ Verwenden Sie ▶ Skripte
- ▶ Verwenden Sie Variablen, um ein Skript flexibel ändern zu können:
Wenn man etwa mit 100 Simulationen arbeiten muss, setzt man `n<-100` und arbeitet mit `n`, um später leicht `n = 1000` Simulationen durchführen zu können
- ▶ Verwenden Sie aussagekräftige Variablennamen um den Code lesbarer zu machen: Lieber `sim.anz` statt `n` als Namen für die Simulationsanzahl wählen
- ▶ Kommentieren Sie Ihren Code so, dass Sie auch später noch verstehen, was er bewirkt. (Kommentieren Sie bitte Ihre Abgaben)
- ▶ Kommentare schreibt man mit `#`, alle Zeichen dahinter werden ignoriert

Allgemeine Programmierhinweise II

- ▶ Verwenden Sie die Vektorarithmetik: Mit ihr lassen sich viele `for` Schleifen umgehen und ein Skript braucht in der Regel weniger Laufzeit
- ▶ Speichern Sie ein Skript regelmäßig (mit `Strg + S`) um bei einem Programmabsturz nicht alles neu schreiben zu müssen
- ▶ Rücken Sie den Code so ein, dass man auf einen Blick sieht, wo sich zusammengehörige `{ }` Klammern befinden

for Schleife

Schleifenprozesse sind Vorgänge, die vom Programm immer wiederholt werden, bis eine gewisse Bedingung erfüllt ist. Die wichtigsten Schleifen sind die `for`- und die `while`-Schleife.

- ▶ Die `for`-Schleife unterliegt folgender Syntax:
`for(Name in Vektor) { Körper der Schleife }`
- ▶ Dadurch wird eine Variable, die „Name“ heißt, schrittweise gleich den Elementen des Vektors „Vektor“ gesetzt
- ▶ In jedem Schritt wird für den entsprechenden Wert des Vektors der zugehörige Befehl aus den geschweiften Klammern ausgeführt
- ▶ Die Befehle im Körper der Schleife werden also sooft ausgeführt, wie es Elemente im Vektor „Vektor“ gibt
- ▶ Bei nur *einem* Befehl können die { } Klammern weggelassen werden

Beispiele: for Schleife

Beispiel

Wir wollen die Zahlen von 1 bis 100 aufaddieren.

- ▶ `sum <- 0`
- ▶ `for (j in 1:100) sum <- sum + j`
- ▶ `sum`

Beispiel

Wir wollen die ersten 12 Fibonacci-Zahlen erzeugen:

- ▶ `Fibo <- numeric(12)`
- ▶ `Fibo[1] <- Fibo[2] <- 1`
- ▶ `for (i in 3:12) Fibo[i] <- Fibo[i-2]+Fibo[i-1]`
- ▶ `Fibo`

Beispiele: for Schleife

Beispiel

Wir wollen die Zahlen von 1 bis 100 aufaddieren.

```
▶ sum <- 0
▶ for (j in 1:100) sum <- sum + j
▶ sum
```

Beispiel

Wir wollen die ersten 12 Fibonacci-Zahlen erzeugen:

```
▶ Fibo <- numeric(12)
▶ Fibo[1] <- Fibo[2] <- 1
▶ for (i in 3:12) Fibo[i] <- Fibo[i-2]+Fibo[i-1]
▶ Fibo
```

while Schleife

- ▶ Bei einer `for` Schleife ist klar, wie oft die Befehle im Körper ausgeführt werden
- ▶ Will man einen Vorgang wiederholen bei dem man dies nicht weiß, so hilft die `while` Schleife
- ▶ Syntax: `while(Bedingung) { Körper der Schleife }`
- ▶ Vor jedem Schritt wird die Bedingung überprüft
 - ▶ Ist Bedingung `TRUE` \rightsquigarrow Befehle werden ausgeführt
 - ▶ Ist Bedingung `FALSE` \rightsquigarrow Schleife wird beendet

Beispiele: while Schleife

Beispiel

Wir wollen die Zahlen von 1 bis n aufaddieren, solange bis die Summe größer als 10000 ist

- ▶ `sum <- 0; n<-1`
- ▶ `while (sum <= 10000) { sum <- sum + n; n <- n + 1 }`

Beispiel

Wir wollen alle Fibonacci-Zahlen auflisten, die kleiner als 300 sind.

- ▶ `Fib1 <- Fib2 <- Fibonacci <- 1; upperBound <- 300`
- ▶ `while(Fib2<upperBound) {
 Fibonacci <- c(Fibonacci,Fib2)
 oldFib2 <- Fib2
 Fib2 <- Fib1+Fib2
 Fib1 <- oldFib2 }`

Beispiele: while Schleife

Beispiel

Wir wollen die Zahlen von 1 bis n aufaddieren, solange bis die Summe größer als 10000 ist

- ▶ `sum <- 0; n<-1`
- ▶ `while (sum <= 10000) { sum <- sum + n; n <- n + 1 }`

Beispiel

Wir wollen alle Fibonacci-Zahlen auflisten, die kleiner als 300 sind.

- ▶ `Fib1 <- Fib2 <- Fibonacci <- 1; upperBound <- 300`
- ▶ `while(Fib2<upperBound) {`
`Fibonacci <- c(Fibonacci,Fib2)`
`oldFib2 <- Fib2`
`Fib2 <- Fib1+Fib2`
`Fib1 <- oldFib2 }`

if-else Abfragen

Häufig müssen in die Definition einer Funktion Fallunterscheidungen bzgl. des Outputs in Abhängigkeit von den eingesetzten Werten vorgenommen werden.

- ▶ Dazu verwendet man Anweisungen der Art

```
if(Bedingung) { Befehlsfolge }  
else { Befehlsfolge }
```
- ▶ Ist Bedingung TRUE \rightsquigarrow Befehlsfolge hinter if wird ausgeführt
- ▶ Ist Bedingung FALSE \rightsquigarrow die hinter else
- ▶ Will man im else-Fall nichts tun, so kann man diese Zeile auch weglassen
- ▶ Bei nur *einem* Befehl kann auf die { } Klammern verzichtet werden

Beispiel: if-else Abfragen

Beispiel

$g(x)$ soll $\sin(\sqrt{x})$ berechnen, falls $x \geq 0$ ist, andernfalls NaN ausgeben:

```
▶ g<-function(x) {  
  if(x >= 0) return(sin(sqrt(x)))  
  else return(NaN)}
```

Beispiel (Indikatorfunktion auf dem abgeschlossenen Einheitsintervall)

```
▶ indikator<-function(x) {  
  if(x < 0) return(0)  
  else {  
    if(x>1) return(0)  
    else return(1)  
  }  
}
```

Beispiel: if-else Abfragen

Beispiel

$g(x)$ soll $\sin(\sqrt{x})$ berechnen, falls $x \geq 0$ ist, andernfalls NaN ausgeben:

```
▶ g<-function(x) {  
  if(x >= 0) return(sin(sqrt(x)))  
  else return(NaN)}
```

Beispiel (Indikatorfunktion auf dem abgeschlossenen Einheitsintervall)

```
▶ indikator<-function(x) {  
  if(x < 0) return(0)  
  else {  
    if(x>1) return(0)  
    else return(1)  
  }  
}
```

Logische Operatoren II

Da in den Fällen $x < 0$ und $x > 1$ der gleiche Wert zurückgegeben wird, kann man auch beide Bedingungen mit einem logischen ODER miteinander verknüpfen

<pre>& logisches UND logisches ODER ! logisches NICHT</pre>

Beispiel

```
▶ indikator2<-function(x) {
  if(x < 0 | x > 1) return(0)
  else return(1)
}
```

ifelse Funktion

Noch einfacher wird es, wenn man die `ifelse` Funktion benutzt

- ▶ Syntax: `ifelse(Bedingung, Wert1, Wert2)`
- ▶ Bedingung `TRUE` \leadsto `Wert1` wird zurückgegeben, andernfalls `Wert2`
- ▶ Sowohl Bedingung als auch die Werte können vektorwertig sein (die Ausgabe ist ein Vektor der so lang ist wie der Bedingungsvektor)

Beispiel

- ▶ `indikator3<-function(x) ifelse(x<0 | x>1, 0, 1)`
- ▶ `ifelse(c(TRUE,FALSE,TRUE,TRUE), 1:2, 0)`