

Aufgabenblatt

Die Aufgaben können in **2er Gruppen** bearbeitet werden. Für jede Aufgabe sollen Sie ein R Skript erstellen, das Sie als „**Aufgabennr.Vorname1.Vorname2.R**“ speichern, also z.B. „**3.2.Bernd.Ute.R**“ für das R Skript zur Aufgabe 3.2.

Abgabe: **16.02.2010 bis 18:00 Uhr** per Email. Besprechung: **17.02.2010 um 13:30** im SRA.

1 Datenstrukturen

Aufgabe 1.1. (5 Punkte)

Die Teilnehmer eines Hochschulsport-Tanzkurses wurden nach Alter und Geschlecht befragt. Dabei ergaben sich folgende Daten:

Person	1	2	3	4	5	6	7	8	9	10
Geschlecht	w	w	m	w	m	m	w	w	m	m
Alter	23	24	26	27	23	28	21	20	25	26

Erstellen Sie aus diesem Datensatz eine Datentabelle **tanz** in R und untersuchen Sie:

- Wie alt sind der älteste und der jüngste Teilnehmer in der gesamten Gruppe? Wie alt sind der (die) älteste und der (die) jüngste bei den Männern (Frauen)?
- Benutzen Sie den Befehl **attach** um direkt auf die Spalte **Alter** zugreifen zu können und ordnen Sie diesen Vektor der Größe nach, einmal aufsteigend und einmal absteigend.
- Wie alt sind die Teilnehmer zusammen? Wie alt sind sie durchschnittlich?
- Welche Teilnehmer sind 23 Jahre alt? Welche sind älter als 21 und jünger als 27? Welche sind mindestens 25 Jahre alt oder genau 23 Jahre alt?
- Erstellen Sie mit Hilfe von **subset** einen Datenvektor **Alter.f**, der nur aus dem Alter der Studentinnen besteht. Wie alt sind die Studentinnen durchschnittlich?

Aufgabe 1.2. (4 Punkte)

Mit dem Befehl **rnorm(16,mean=5,sd=9)** erhalten Sie 16 Zufallszahlen, die gemäß einer Normalverteilung mit Erwartungswert 5 und Standardabweichung 9 gesampelt wurden.

- Runden Sie diese Zahlen auf eine Stelle nach dem Komma und tragen Sie sie zeilenweise in eine 4×4 Matrix **M** ein.
- An welcher Position der Matrix steht das Minimum der Einträge? An welcher das Maximum?

- (c) Gibt es einen Eintrag, der im Intervall $[0, 1]$ liegt? Liegen alle Einträge zwischen -2 und 12 ?
- (d) Bilden Sie, ohne Verwendung der Funktion `colSums`, die Spaltensummen von `M` und schreiben Sie diese in einen Vektor `sp.sums`. In welcher Spalte ist die Summe am höchsten?

Aufgabe 1.3. (5 Punkte)

Herr Weishaupt misst jeden Mittag um 12:00 Uhr die Temperatur in Grad Celsius auf seinem Balkon und notiert sie in seinem Kalender. Für den Januar 2007 hat er sich folgende Daten eingetragen:

1. Woche:	-2	-4	-3.5	-3	-7	-6	-4
2. Woche:	-1	0	0.5	2	1	2	2.5
3. Woche:	0	-1	0	1.5	3	3	2
4. Woche:	4	3	1	-2	-3	-4	0

Erzeugen Sie mittels `ts` eine Zeitreihe `mess`. Achten Sie dabei darauf, einen Startwert und die richtige `frequency` anzugeben.

- (a) Welche Werte sind größer als 0 ?
- (b) An welchen Tagen hat es gefroren (Temperatur negativ)? An welchen Tagen lag die Temperatur bei genau 0 Grad Celsius?

Herr Weishaupts Nachbar misst ebenfalls um 12:00 Uhr die Temperatur und notiert diese. Für den gleichen Zeitraum erhält er die folgenden Werte:

1. Woche:	-1.5	-4	-3	-3.5	-7	-4	-3
2. Woche:	0	-1	1	2	1.5	2	3
3. Woche:	0	-1	0	-0.5	3	2.5	2.5
4. Woche:	4.5	3	1.5	-2	-3	-4	0.5

Erzeugen Sie aus diesen Daten eine Zeitreihe `mess2`.

- (c) Wieviele Übereinstimmungen mit der ersten Messung gibt es?
- (d) Was ist die größte Abweichung, und wann fand sie statt?
- (e) Benutzen sie den Befehl `ts.union`, um aus den beiden Zeitreihen eine einzelne Zeitreihe `Messung` zu erzeugen.

2 Programmierung, Schleifen und Abfragen

Aufgabe 2.1. (5 Punkte)

(a) Erzeugen Sie den Vektor

$$v = (1, 2, 2, 3, 3, 3, \dots, \underbrace{100, \dots, 100}_{100 \text{ mal}})$$

mit einer `for` Schleife und ohne Verwendung der Funktion `rep`. Wie könnte man v mit `rep` erzeugen?

(b) Erzeugen Sie den Vektor

$$w = (1, 1.2, 1.4, 1.6, \dots, 99.6, 99.8, 100)$$

mit einer `while` Schleife und ohne Verwendung der Funktion `seq`. Wie könnte man w mit `seq` erzeugen?

Aufgabe 2.2. (4 Punkte)

Die Folge $a = (a_n)_{n \in \mathbb{N}}$ sei rekursiv definiert durch $a_1 = a_2 = 1$ und

$$a_n = n + a_{n-1} + a_{n-2}$$

für $n \geq 3$.

- Berechnen Sie die ersten 20 Folgenglieder von a .
- Berechnen Sie die Folgenglieder, die ≤ 100000 sind. Wieviele sind es?
- Wieviele davon sind auch ≥ 5000 ?

Aufgabe 2.3. (5 Punkte)

Auf dem Wochenmarkt hat ein Lakritz- und Weingummihändler folgendes Angebot:

- Bei jedem Kauf zahlt man 50 Cent „Bedienungsgebühr“ und muss ihm mindestens 250g seiner Ware abnehmen.
- Bei einem Kauf von bis zu 500g Süßigkeiten zahlt man pro 100g 0,60 Euro.
- Bei mehr als 500g und höchstens 1000g zahlt man 0,50 Euro pro 100g.
- Bei mehr als einem Kilo 40 Cent pro 100g.

Stellen Sie in R den unter diesen Bedingungen entstehenden Preis als Funktion der gekauften Menge dar und berechnen Sie damit den Preis für 384g, 496g, 502g, 980g und 1107g.

Nützlich ist die Funktion `stop("text")`. Sie bricht eine Funktion ab und liefert die Fehlermeldung "text".

3 Plots

Aufgabe 3.1. (5 Punkte)

Bei der letzten Bundestagswahl in Deutschland (im September 2009) ergab sich folgende Stimmverteilung beim Merkmal *Zweitstimme* (bei 43.371.190 gültigen Stimmen):

CDU/CSU	SPD	FDP	Grüne	Linkspartei	Andere
14.658.515	9.990.488	6.316.080	4.643.272	5.155.933	2.606.902

- (a) Geben Sie die Daten als Vektor `wahl` ein, weisen Sie mit `names(wahl)` die Parteien den Zahlen zu und ordnen Sie den Vektor absteigend.
- (b) Berechnen Sie die zugehörigen prozentualen Anteile an den abgegebenen (und gültigen) Stimmen auf eine Nachkommastelle genau.
- (c) Erzeugen Sie mit den Daten ein, mit den Parteinamen und den zugehörigen Prozentsätzen beschriftetes, Kreissektorendiagramm (in den entsprechenden Parteifarben). Verwenden Sie dazu die Funktion `pie`.
- (d) Erstellen Sie ein geordnetes Säulendiagramm in den entsprechenden Parteifarben. Verwenden Sie dazu die Funktion `barplot`.

Aufgabe 3.2. (4 Punkte)

Zeichnen Sie die Dichten der $\mathcal{N}(0, 1)$ -Verteilung und der $\mathcal{C}(0, 1)$ -Verteilung auf dem Intervall $[-4, 4]$ in eine Grafik, beschriften Sie diese und fügen Sie eine Legende ein.

Hier wird mit $\mathcal{C}(a, b)$ eine Cauchyverteilung mit Verschiebungsparameter 0 und Skalierungsparameter 1 bezeichnet. An die Dichten der Verteilungen gelangen sie mit `dnorm(x)` bzw. `dcauchy(x)`. Für das Plotten in R empfiehlt sich die Funktion `curve`. Das Einfügen einer Legende in einen Plot geschieht mit dem Befehl `legend`.

Aufgabe 3.3. (5 Punkte)

Laden Sie mit `source("Pfadname")` Ihr Skript der Aufgabe 1.3. Auf die Variable `Messung` können Sie nun zugreifen. Überzeugen Sie sich davon, indem Sie mit `ls()` alle im Workspace definierten Variablen anzeigen lassen.

- (a) Führen Sie den Befehl `plot(Messung)` aus. Wie können Sie erreichen, dass beide Zeitreihen in eine Graphik geplottet werden? Färben Sie dabei beide Zeitreihen unterschiedlich, erstellen Sie mit dem für `plot` optionalen Argument `main` eine Überschrift des Plots und beschriften Sie die x- und y-Achse passend (Argumente `xlab` und `ylab`).
- (b) Fügen Sie eine Legende ein und zeichnen Sie mit `abline` die x-Achse (in Grau).
- (c) Löschen Sie mit `rm` die Variable `Messung` wieder aus dem Workspace.

4 Zeitreihen ohne Saisonkomponente

Aufgabe 4.1. (8 Punkte)

Lesen Sie mit dem Befehl `source` die Datei `temperaturen.R` ein. Sie enthält in der Zeitreihe `Global.annual` die globalen jährlichen Durchschnittstemperaturen von 1856 bis 2005, als Abweichungen vom Durchschnitt der Jahre 1961-1990.

- (a) Auf Zeitreiheneinträge können Sie wie auf Vektoreinträge zugreifen. Schreiben Sie eine Funktion, die den einfachen gleitenden Durchschnitt über 3 (5,7,9) Jahre berechnet, und plotten Sie diese.
- (b) Verwenden Sie nun die R-Funktion `filter` dafür.
- (c) Führen Sie (ohne `HoltWinters`) zu verwenden, eine exponentielle Glättung mit Parametern $\alpha \in \{0.1, 0.3, 0.5, 0.7\}$ durch.
- (d) Wählen Sie einen Zeitraum aus, in welchem ein linearer Trend zu erkennen ist. Weisen Sie (mittels des Befehls `window`) einer neuen Zeitreihe die Temperaturdaten aus dem gewählten Zeitraum zu. Berechnen Sie mittels `lm` Achsenabschnitt und Steigung eines linearen Trends.

5 Zeitreihen mit Saisonkomponente

Aufgabe 5.1. (10 Punkte)

Lesen Sie mit dem Befehl `source` die Datei `steuer.R` ein. Sie enthält die deutschen Steuereinnahmen der Jahre 1991 bis 2008 in Euro (frühere Werte umgerechnet) als Quartalsdaten.

- (a) Offensichtlich liegen hier saisonale Schwankungen vor. Warum?
- (b) Berechnen Sie die gefilterte Zeitreihe der Veränderungen der Steuereinnahmen im Vergleich zum Vorjahresquartal.
- (c) Zerlegen Sie die (ursprüngliche) Zeitreihe in Trend (gl. Durchschnitt) und Saisonkomponente, und plotten Sie diese.
- (d) Bestimmen Sie mit der Methode der kleinsten Quadrate (also in einem linearen Modell) einen linearen Trend, sowie (additive) Saisonkomponenten. Zentrieren Sie Zeitreihe und die Zeit, um vernünftige Werte zu erhalten.
- (e) Betätigen Sie sich als Steuerschätzer, indem Sie ein HoltWinters-Modell für diese Zeitreihe berechnen. Schätzen Sie (unter Annahme unveränderter Wirtschaftslage und Steuergesetzgebung) die Steuereinnahmen für 2009 und 2010, quartalsweise.
- (*) Die Funktion `harmonic` aus dem Paket `TSA` erzeugt, gegeben eine Zeitreihe, eine Matrix mit harmonischen Funktionen (sinus und cosinus), mit denen die Saisonkomponente in einem linearen Modell durch Regression approximiert werden kann. Führen Sie dies durch.