

Eine Einführung in R: Deskriptive Statistiken und Graphiken

Bernd Klaus, Verena Zuber

Institut für Medizinische Informatik, Statistik und Epidemiologie (IMISE),

Universität Leipzig

25. Oktober 2012

- ① I. Diskrete Daten
Häufigkeitstabellen
Darstellung

- ② II. Stetige Daten
Maße für die Lage
Maße für die Streuung
Boxplot
Stripcharts
Histogramm

- ③ III. Graphiken in R

I. Diskrete Daten: Deskriptive Statistiken und Graphiken

Was sind diskrete Variablen?

Diskrete Variablen nehmen nur eine endliche Anzahl an Werten an:

- **Kategorial**: Es besteht keine Rangordnung der Kategorien
- **Ordinal**: Kategorien können geordnet werden

Kategoriale oder ordinale Variablen sollten in R als Faktoren definiert sein.

Mit einer Häufigkeitstabelle kann man ein kategoriales Objekt zusammenfassen:

- `table(object)`: Absolute Häufigkeiten
- `prop.table(table(object))`: Relative Häufigkeiten

Betrachten wir einen Faktor mit 4 Ausprägungen:

```
DNA <- rep(c("A", "C", "G", "T"), 10)
```

1		"A"
2		"C"
3		"G"
3		"T"
⋮		⋮



- `table(DNA)` ergibt:

```
  A C G T
10 10 10 10
```

- `prop.table(table(DNA))` ergibt:

```
  A C G T
0.25 0.25 0.25 0.25
```

Kuchendiagramm und Balkendiagramm



Zu erzeugen mit:

```
pie(table(DNA))
```

```
barplot(table(DNA))
```

II. Stetige Daten: Deskriptive Statistiken und Graphiken

Was sind stetige Variablen?

Stetige Variablen können (in der Theorie) eine unendliche Anzahl an Werten annehmen. Beispiele:

- Gewicht
- Größe
- Gehalt

R speichert stetige Variablen als metrische Objekte (**numeric**) ab.

Häufigkeitstabelle sind für stetige Variablen meist nicht geeignet. Wichtiger sind:

- Maße für die Lage
- Maße für die Streuung

Maße für die Lage

Die **Lage** (*location*) gibt an, in welcher Größenordnung sich Daten bewegen.

- (Empirische) Mittelwert

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (x_1 + \dots + x_n).$$

- In R: `mean()`

Maße für die Lage II

- $x\%$ -Quantile, trennen die Daten in zwei Teile.
So liegen $x\%$ der Daten unter dem $x\%$ -Quantile und $100 - x\%$ darüber.
 - Median $x_{0.5}$ entspricht dem 50%-Quantil
 - In R: `median()`
 - 25%-Quantil $x_{0.25}$ (das erste Quartil)
 - 75%-Quantil $x_{0.75}$ (das dritte Quartil)
- Der Median ist robuster gegen Ausreißer als der Erwartungswert
- Oder gleich in R: `summary()`

Maße für die Streuung

Die Streuung (*scale*) gibt an, wie stark die verschiedenen Werte voneinander abweichen.

- Die (empirische) Varianz

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} ((x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2).$$

- **Spannbreite:**
Differenz vom größten zum kleinsten Wert
- **Interquartilsabstand:**

$$\text{IQR} = x_{0.75} - x_{0.25}$$

Beispiel: *oecd*-Daten

Betrachten wir das durchschnittliche, frei verfügbare Einkommen einer Familie [pro Kind, in tausend US-Dollar].

- Einen Überblick erhält man durch:

```
summary(Einkommen)
Min. 1st Qu. Median Mean 3rd Qu. Max.
 5.10 16.60 21.10 19.18 22.65 34.20
```

- Die Varianz bzw. Standardabweichung

```
var(Einkommen)
[1] 50.75937
sd(Einkommen) (alternativ sqrt(var(Einkommen)) )
[1] 7.124561
```

Beispiel: *oecd*-Daten II

- Den Interquartilsabstand erhält man durch:

```
IQR(Einkommen)  
[1] 6.05
```

- Die Spannweite mit

```
max(Einkommen) - min(Einkommen)  
[1] 29.1
```

Bei der Variable *Alkohol* (Prozentsatz der 13-15 jährigen Kinder, die mindestens zweimal betrunken waren) bestehen fehlende Werte.

- Mittelwertsberechnung über



```
mean(Alkohol, na.rm=TRUE)  
[1] 15.225
```

Was ist ein Boxplot?

Der Boxplot ist eine Graphik zur Darstellung stetiger Variablen.
Er enthält:

- Minimum und Maximum
- 25%-Quantil und 75%-Quantil
- Median
- In R: `boxplot(variable)`
- Um Variablen getrennt nach Faktorstufen zu untersuchen, bietet sich an: `boxplot(variable ~ factor)`
- Einschub: Ein Label für den Faktor `Geo`
`factor(Geo, levels=c("R", "E"), labels=c("Nicht-Europa", "Europa"))`

Boxplot: *Alkohol*




Zu erzeugen mit:

```
boxplot(Alkohol)
```

```
boxplot(Alkohol ~ Geo)
```

Stripchart: *Alkohol*

Eine Alternative zum Boxplot bei wenigen Beobachtungen ist der Stripchart:



Zu erzeugen mit:

```
stripchart(Alkohol~Geo)
```

Was ist ein Histogramm?



- Zur Erstellung eines Histogramms teilt man die Daten in homogene Teilintervalle ein und plottet dann die absolute Häufigkeit pro Teilintervall
- Dieses Verfahren gibt einen ersten Überblick über die Verteilung der Daten
(=> Ermitteln der “empirischen Dichte” möglich)

```
hist(x, breaks = “AnzahlBins”, freq = NULL )
```

- **x**: Daten
- **breaks = “AnzahlBins”**: Steuerung der Teilintervalle
- **freq=TRUE**: absolute Häufigkeiten
- **freq=FALSE**: relative Häufigkeiten (“empirische Dichte”)

Histogramm: *Einkommen*

Histogramme des Einkommens mit verschiedenen Binstärken



Zu erzeugen mit:

```
hist(Einkommen)
```

```
hist(Einkommen, breaks=15)
```

III. Graphiken in R: Grundaufbau und Parameter

Graphiken in R

R kennt einen Standardbefehl für einfache Graphiken (`plot()`), aber auch viele spezielle Befehle, wie `hist()` oder `pie()`.

```
plot(x, y, type, main, par (...))
```

- `x`: Daten der x -Achse
- `y`: Daten der y -Achse
- `type="l"`: Darstellung durch eine Linie
- `type="p"`: Darstellung durch Punkte
- `main`: Überschrift der Graphik
- `par (...)`: Zusätzlich können sehr viele Parametereinstellungen geändert werden

Parameter für Graphiken in R

```
par(cex, col, lty, mfrow, pch, x/yaxs)
```

- `cex`: Skalierung von Graphikelementen
- `col`: Farbe (`colors()` zeigt die vordefinierten Farben an)
- `lty`: Linienart
- `mfrow`: Anordnen von mehreren Graphiken nebeneinander
- `pch`: Andere Punkte oder Symbole
- `x/yaxs`: Stil der x - bzw. y -Achse

Einen Überblick über die Parameter erhält man mit `?par`.

`par()` kann entweder im `plot()` -Befehl gesetzt werden oder als eigene Funktion vor einem oder mehreren `plot()`-Befehlen.

Aufbau von Graphiken in R

- ① `plot()`: Bildet den Grundstein einer Graphik
- ② Zusätzlich können weitere Elemente eingefügt werden wie:
 - `lines()`: Linien
 - `points()`: Punkte
 - `legend()`: Legende
 - `text()`: Text
- ③ `dev.off()`: schließt die Graphik

Einen Überblick erhält man mit der betreffenden Hilfsfunktion, z.B. `?legend`.


Abspeichern von Graphiken

Folgende Graphikformate können in R erzeugt werden:

- `pdf()`
- `ps()`
- `jpg()`

Beispiel:

```
pdf(file="boxplot.pdf", width=13, height=6)
par(mfrow=c(1,2))
boxplot(Alkohol, main="Boxplot")
boxplot(Alkohol~Geo, main="Boxplot für ...")
par(mfrow=c(1,1))
dev.off()
```



```
pdf(file="RGraphiken/beispiel.pdf", width=12, height=6)
plot(x,y, type="l", col="darkviolet", main="Cos und Sin")
lines(x,z, col="magenta")
points(x,null, pch=3)
legend("topleft", c("cosinus","sinus"),
col=c("darkviolet", "magenta"), lty=1)
dev.off()
```