

Bernd Klaus (bernd.klaus@imise.uni-leipzig.de)
Verena Zuber (verena.zuber@imise.uni-leipzig.de)

<http://uni-leipzig.de/~zuber/teaching/ws09/r-kurs/>

Den folgenden Aufgaben liegt der Datensatz OECD zu Grunde, er enthält Variablen (Stand 2009), die das Wohlergehen von Kindern in den Mitgliedstaaten messen sollen. Abgefragt wurde:

- Einkommen: das durchschnittliche Einkommen der Eltern [in tausend US Dollar pro Kind]
- Armut: der Anteil [immer in Prozent] an Kindern in einem armen Elternhaus
- Bildung: der Anteil an Kindern, die ohne eine Grundausrüstung (Bücher, Schreibtisch, Computer, Internet) für Bildung auskommen
- WenigRaum: der Anteil an Kindern, die auf zu wenig Raum wohnen
- Umwelt: der Anteil an Kindern, die unter schlechten Umweltbedingungen leben
- Lesen: mittlerer PISA-Score zur Lesefähigkeit
- Geburtsgewicht: der Anteil an Kindern, die bei der Geburt weniger als 2.5kg wiegen
- Säuglingssterblichkeit: Säuglingssterblichkeit (<1 Jahr) [x in Tausend]
- Sterblichkeit: Sterblichkeit (<20 Jahre) [x in 100 000]
- Selbstmord: Selbstmord von Jugendlichen im Alter von 15 bis 19 [x in 100 000]
- Bewegung: der Anteil an 11, 13 und 15 jährigen Jugendlichen, die sich regelmäßig bewegen
- Rauchen: der Anteil an 15 jährigen Jugendlichen, die mindestens einmal die Woche rauchen
- Alkohol: der Anteil an 13-15 jährigen Jugendlichen, die mindestens zweimal betrunken waren
- Bullying: der Anteil an Kindern, die angeben in der Schule bedroht zu werden
- Schule: der Anteil an Kindern, die angeben die Schule zu mögen
- Geo: Faktor, der die geographische Lage eines Landes beschreibt, dabei steht "E" für Europa und "R" für den Rest der Welt.

1 Aufgabe: Datensatz OECD

- Lesen Sie den Datensatz *oecdM* mit der Funktion `data<-read.csv(file="Daten/oecdM", header=TRUE)` ein und überprüfen Sie die Dimension der Daten.
- Berechnen Sie die Mittelwerte und Varianzen der einzelnen Variablen mit dem geeigneten `apply` Befehl.
- Überprüfen Sie, ob die Niederlande im der Länderliste des des Datensatzes auftaucht. Gibt es auch einen Eintrag für China? (Benutzen sie die R-Hilfe, um herauszufinden wie man auf die Ländernamen zugreifen kann.)

- (d) In welchem Land waren die meisten Jugendlichen mindestens zweimal betrunken? Wie hoch ist der maximale Prozentsatz?
- (e) In welchem Land ist die Säuglingssterblichkeit am geringsten? Wie hoch ist sie in diesem Land?
- (f) In welchen Ländern ist der Prozentsatz an Jugendlichen, die sich regelmäßig bewegen, kleiner als der Durchschnitt?

2 Aufgabe: Häufigkeiten und Stripcharts

- (a) Wieviele Länder im Datensatz *oecdM* gehören zu Europa, wieviele zum Rest der Welt? Stellen Sie das Ergebnis in einem Kuchendiagramm dar und verwenden sie dazu die Farben grün ("green") und blau ("blue").
- (b) Visualisieren sie die Variable *Lesen*, getrennt nach dem Faktor Geo, in einem vertikalen Stripchart. Welche Aussage können Sie mit diesem Stripchart treffen?

3 Aufgabe: Quantile und Plots

- (a) Erstellen Sie einen Boxplot für die Variable "Bildung". Was fällt Ihnen auf?
- (b) Untermauern Sie die Beobachtung aus Aufgabe (a) durch Berechnung einiger Quantile mit Hilfe der Funktion `quantile()`.
- (c) Stellen Sie zudem die aufsteigend geordneten Werte der Variable *Bildung* mit Hilfe der Funktion `plot()` als Kurve dar.
- (d) Begründen Sie anhand Ihrer Beobachtungen, dass das 75% Quantil der Daten einen guten Trennpunkt zwischen Ländern mit "guter" und "schlechter" Grundausstattung für Bildung darstellt.
- (e) Bestimmen Sie eine Liste mit Ländern, in denen es an der Grundausstattung für Bildung besonders fehlt.

4 Aufgabe: Kanzlerduell

Der Verteidigungsminister zu Guttenberg ist zurzeit der beliebteste Politiker der Union und wird sogar als neuer Kanzlerkandidat gehandelt. Das Interesse der Bevölkerung für die Person kann als interessanter Indikator betrachtet werden.

In dem Datensatz *kanzlerduell* finden Sie eine skalierte und normalisierte Größe, die die Häufigkeit der wöchentlichen Suchanfrage nach "Angela Merkel" und "zu Guttenberg" auf Google beschreibt. Start der Messungen ist der 25.10.2009, insgesamt enthält der Datensatz 52 Messungen. Die Daten basieren auf dem Google-Dienst "Insights for research".

- (a) Plotten Sie den Zeitverlauf der Suchabfragen nach "Angela Merkel" (x -Achse: Zeit). Setzen Sie y -Achse auf `ylim=c(0,100)`.
- (b) Fügen Sie in dieselbe Graphik mit anderer Farbe den Verlauf der Suchabfragen nach "zu Guttenberg" ein.
- (c) Abschließend ergänzen Sie eine Legende.