

- (i) Zeichnen Sie Histogramme für die Merkmale `mpg`, `cyl`, `hp`, `wt` der R-internen Datentabelle `mtcars`.
- (ii) Finden Sie heraus, für welche der Merkmale `mpg`, `cyl`, `hp`, `wt` ein Säulendiagramm sinnvoll ist.
- (iii) Zeichnen Sie für die in (ii) ermittelten Merkmale Säulendiagramme.
- (iv) Zeichnen Sie jeweils ein Streudiagramm für die Merkmalspaare `mpg ~ hp`, `mpg ~ wt` und interpretieren Sie die Diagramme. Berechnen Sie die zugehörigen Pearson-Korrelationskoeffizienten.

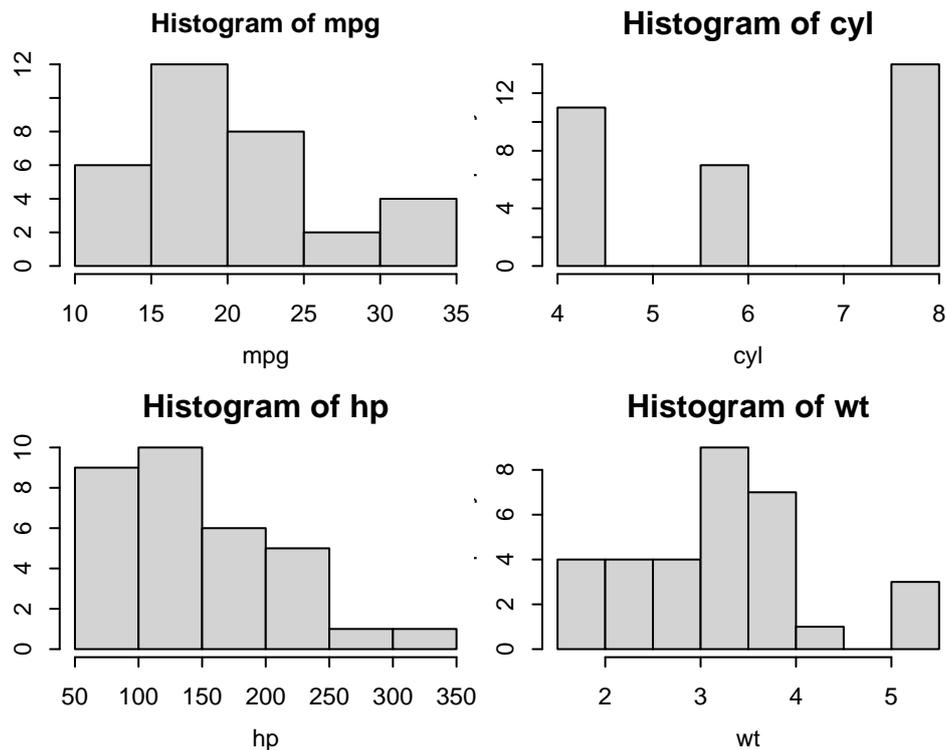
Lösung:

```
# (i)
attach(mtcars)
# Alternative: mtcars$...
# draw four plots in one window
par(mfrow=c(2,2), mar=c(5, 4, 4, 2)-2 + 0.1)
hist(mpg, cex.main = 1)
```

```
hist(cyl)
```

```
hist(hp)
```

```
hist(wt)
```



```
# alternativ mit ggplot
# (1 Punkt)
#
# (ii)
table(mpg)
```

```
mpg
10.4 13.3 14.3 14.7 15 15.2 15.5 15.8 16.4 17.3 17.8 18.1 18.7 19.2 19.7 21
 2    1    1    1    1  2    1    1    1    1    1    1    1    2    1    2
21.4 21.5 22.8 24.4 26 27.3 30.4 32.4 33.9
 2    1    2    1    1    1    2    1    1
```

```
table(cyl)
```

```
cyl
 4  6  8
11  7 14
```

```
table(hp)
```

```
hp
52 62 65 66 91 93 95 97 105 109 110 113 123 150 175 180 205 215 230 245
 1  1  1  2  1  1  1  1  1  1  3  1  2  2  3  3  1  1  1  1  2
264 335
 1  1
```

```
table(wt)
```

```
wt
1.513 1.615 1.835 1.935 2.14 2.2 2.32 2.465 2.62 2.77 2.78 2.875 3.15
 1  1  1  1  1  1  1  1  1  1  1  1  1  1
3.17 3.19 3.215 3.435 3.44 3.46 3.52 3.57 3.73 3.78 3.84 3.845 4.07
 1  1  1  1  3  1  1  2  1  1  1  1  1  1
5.25 5.345 5.424
 1  1  1
```

```
# Säulendiagramm macht für hp und cyl Sinn.
```

```
# (1 Punkt)
```

```
#
```

```
# (iii)
```

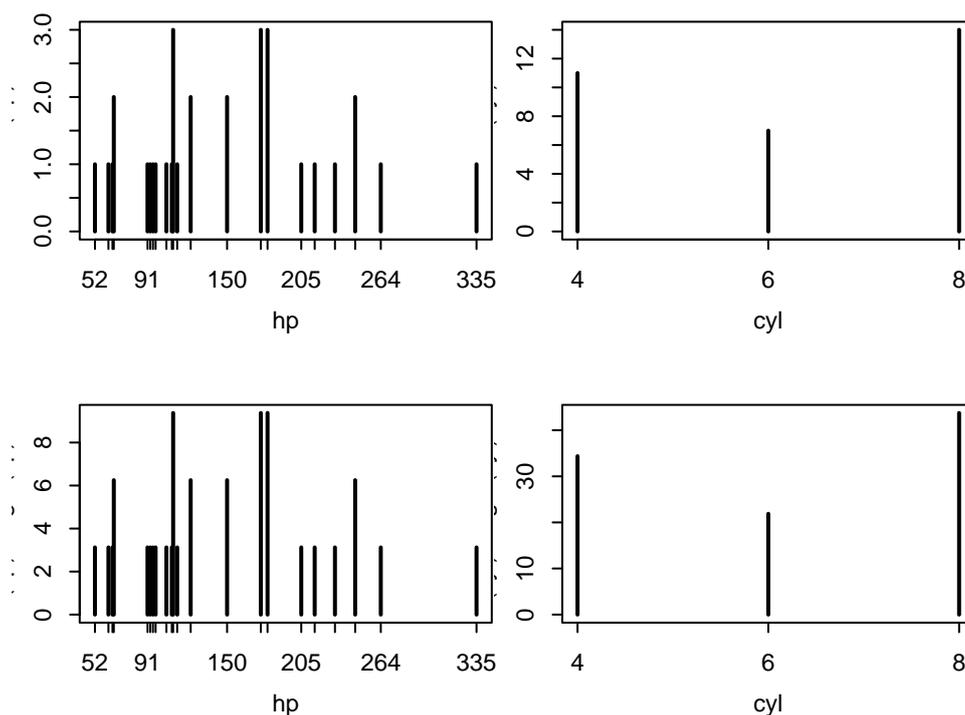
```
plot(table(hp))
```

```
plot(table(cyl))
```

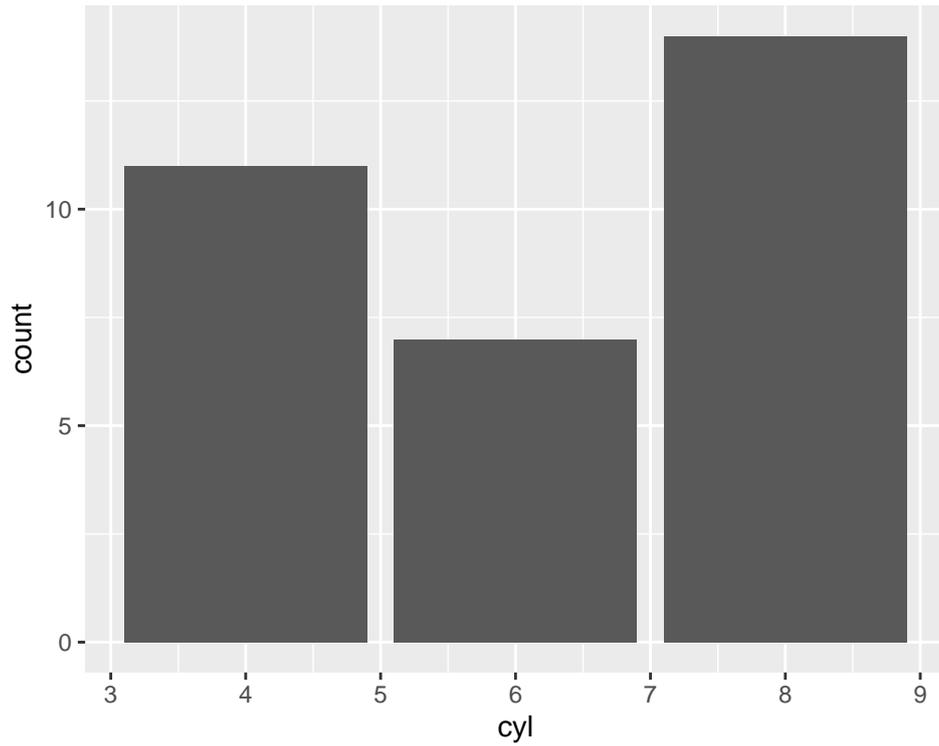
```
# mit relativen Häufigkeiten
```

```
plot(table(hp)/length(hp)*100)
```

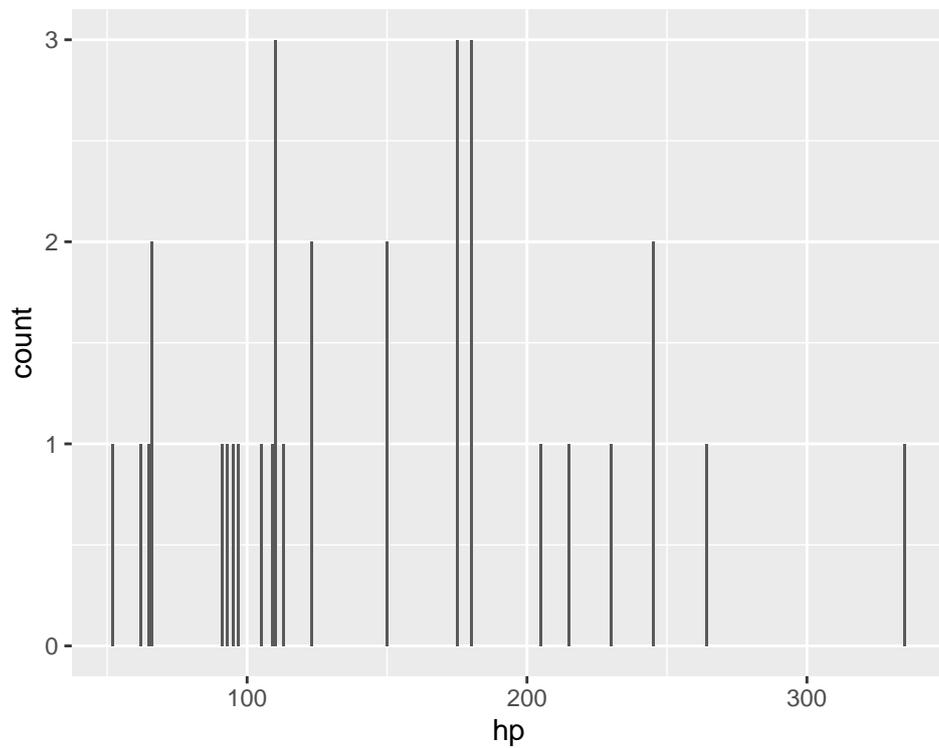
```
plot(table(cyl)/length(cyl)*100)
```



```
# alternativ mit tidyverse
library(tidyverse)
mtcars %>% ggplot() + geom_bar( aes( x = cyl ) )
```

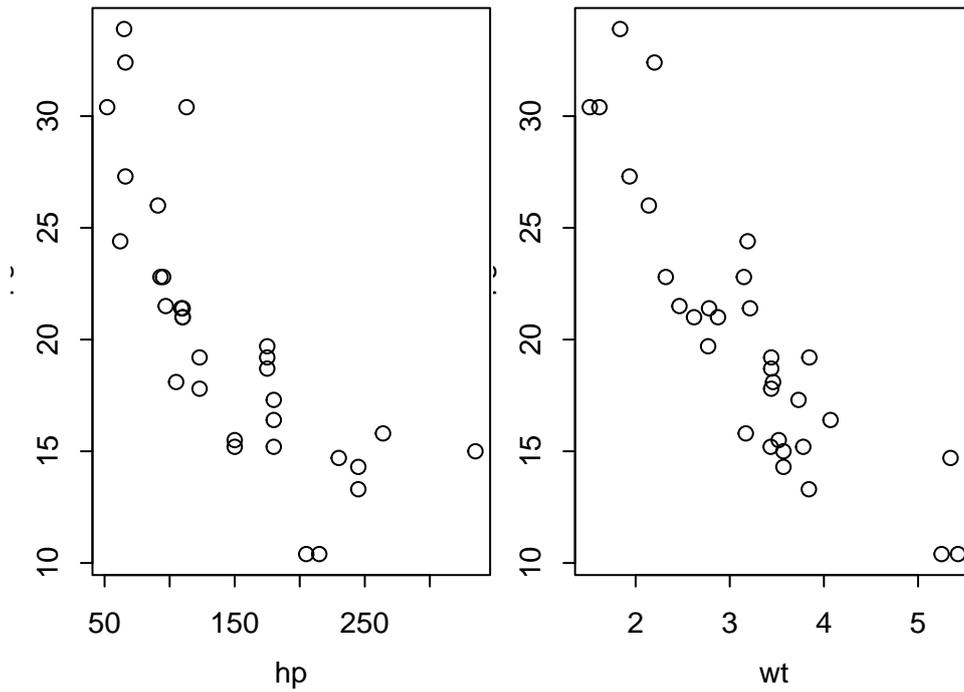


```
mtcars %>% ggplot() + geom_bar( aes( x = hp ) )
```



```
#
# (1 Punkt)
# (iv)
par(mfrow=c(1,2))
plot(hp,mpg) # erst x, dann y Koordinate
```

```
plot(wt,mpg)
```



```
cor(hp,mpg)
```

```
[1] -0.776168
```

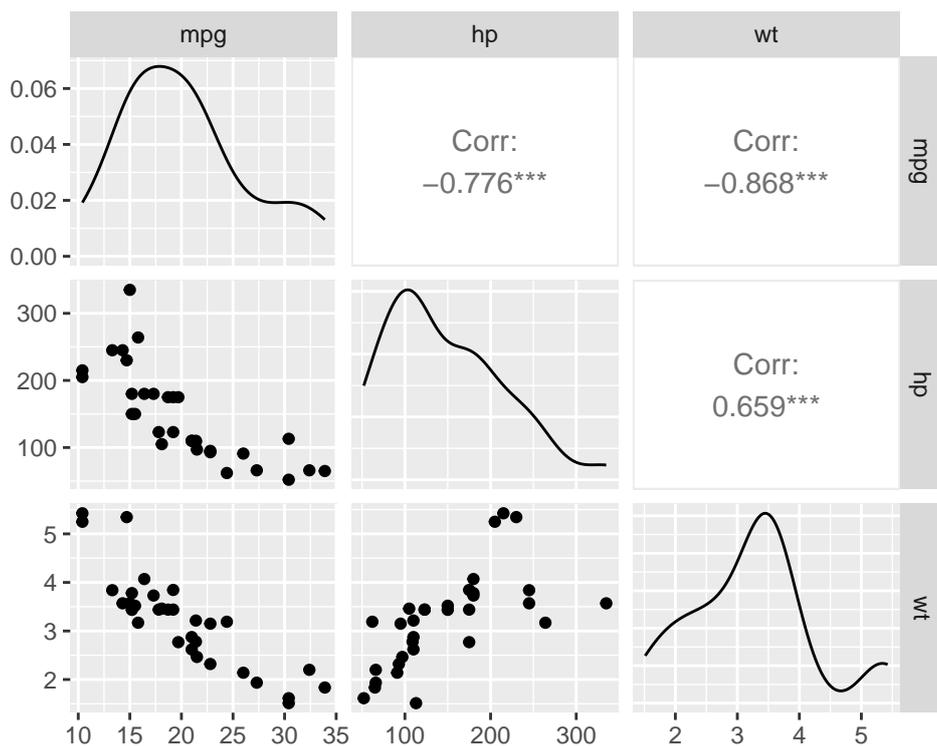
```
cor(wt,mpg)
```

```
[1] -0.867659
```

```
# alternative mit GGally
```

```
library(GGally)
```

```
ggpairs(mtcars %>% select(mpg, hp, wt))
```



(2 Punkte)

Gegeben seien $m \in \mathbb{N}$ (Teil-)Stichproben (man sagt auch Schichten) x_1, \dots, x_m reeller Zahlen mit den Umfängen n_1, \dots, n_m , $n := \sum_{i=1}^m n_i$, arithmetischen Mitteln $\bar{x}_1, \dots, \bar{x}_m$ und Stichproben-Varianzen s_1^2, \dots, s_m^2 . Zeigen Sie, dass für das arithmetische Mittel \bar{z} und die Stichproben-Varianz s_z^2 der gemeinsamen Stichprobe $z = (z_1, \dots, z_n)$, die aus allen Stichprobenwerten der m Teilstichproben besteht, folgende Formeln gelten.

- (i) $\bar{z} = \frac{1}{n} \sum_{i=1}^m n_i \bar{x}_i$ (gewichtetes Mittel)
- (ii) $s_z^2 = \frac{1}{n-1} \sum_{i=1}^m (n_i - 1) s_i^2 + \frac{1}{n-1} \sum_{i=1}^m n_i (\bar{x}_i - \bar{z})^2$ (Streuungszerlegung)
- (iii) Die Streuungszerlegung, vgl. (ii), wird oft in der Form:

Gesamtstreuung = Streuung in den Schichten + Streuung zwischen den Schichten

ausgedrückt. Interpretieren Sie diese Aussage, z.B. grafisch, anhand der Formel in (ii).

Hinweis: Ohne Einschränkung der Allgemeinheit kann man davon ausgehen, dass die ersten n_1 Stichprobenwerte z_1, \dots, z_{n_1} der gemeinsamen Stichprobe z die Werte der Stichprobe x_1 sind, die folgenden n_2 Werte $z_{n_1+1}, \dots, z_{n_1+n_2}$ die Werte der Stichprobe x_2 sind usw. bis zu den n_m Werten $z_{n_1+\dots+n_{m-1}+1}, \dots, z_n$, die die Stichprobenwerte von x_m sind.

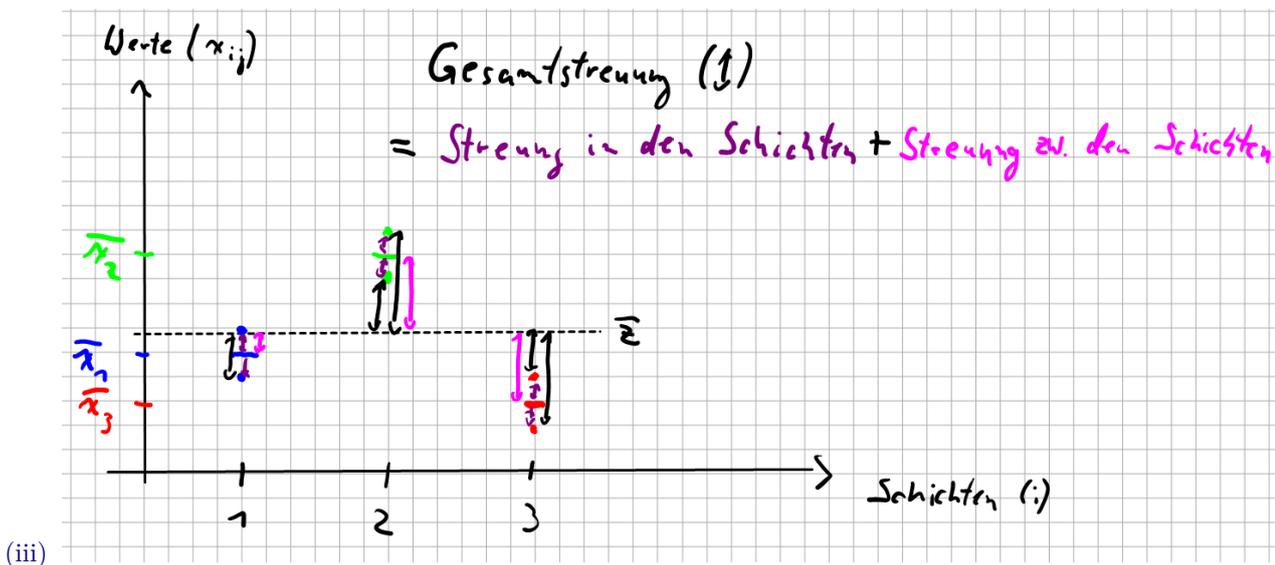
Lösung:

(i) $\bar{z} = \frac{1}{n} \sum_{i=1}^n z_i = \frac{1}{n} \sum_{i=1}^m \sum_{j=1}^{n_i} x_{ij} = \frac{1}{n} \sum_{i=1}^m n_i \bar{x}_i$ #

(ii)

$$\begin{aligned}
 s_z^2 &= \frac{1}{n-1} \sum_{i=1}^n (z_i - \bar{z})^2 = \frac{1}{n-1} \left(\sum_{i=1}^m \sum_{j=1}^{n_i} (x_{ij} - \bar{z})^2 \right) \\
 &= \frac{1}{n-1} \left(\sum_{i=1}^m \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i + \bar{x}_i - \bar{z})^2 \right) \\
 &= \frac{1}{n-1} \left(\sum_{i=1}^m \left(\sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2 + 2 \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)(\bar{x}_i - \bar{z}) + \sum_{j=1}^{n_i} (\bar{x}_i - \bar{z})^2 \right) \right) \\
 &= \frac{1}{n-1} \sum_{i=1}^m (n_i - 1) s_i^2 + \frac{1}{n-1} \sum_{i=1}^m n_i (\bar{x}_i - \bar{z})^2
 \end{aligned}$$

#



- (i) Lesen Sie die Datei „AbsolventenDat.csv“ wie in Aufgabe 2.4 in den tibble `dat.Absolventen` ein.
- (ii) Wandeln Sie die beiden Merkmale *Kontakt der Studierenden untereinander* und *Umgang der Lehrenden mit den Studierenden* in den Datentyp `factor` um und kodieren Sie die Stufen der beiden Merkmale mit dem Befehl `levels` in Schulnoten (1 bis 5) um.
- (iii) Berechnen Sie mit dem Befehl `table` eine Kontingenztabelle der beiden oben genannten Merkmale.
- (iv) Zeichnen Sie einen Häufigkeitsplot der beiden Merkmale.
Hinweis: Verwenden Sie den `geom_count()`-Befehl.
- (v) Schreiben Sie zusätzlich die absolute Häufigkeit in die Kreise des Häufigkeitsplots.
Beispielsweise könnte die Grafik so aussehen:



Hinweis: Sehen Sie sich die Internetseite:

www.r-graph-gallery.com/5-correlation-of-discrete-variables

an. Auf der Seite www.r-graph-gallery.com finden Sie eine Menge schöner Grafiken und den zugehörigen R-code. Außerdem ist stackoverflow.com immer eine Suche wert.

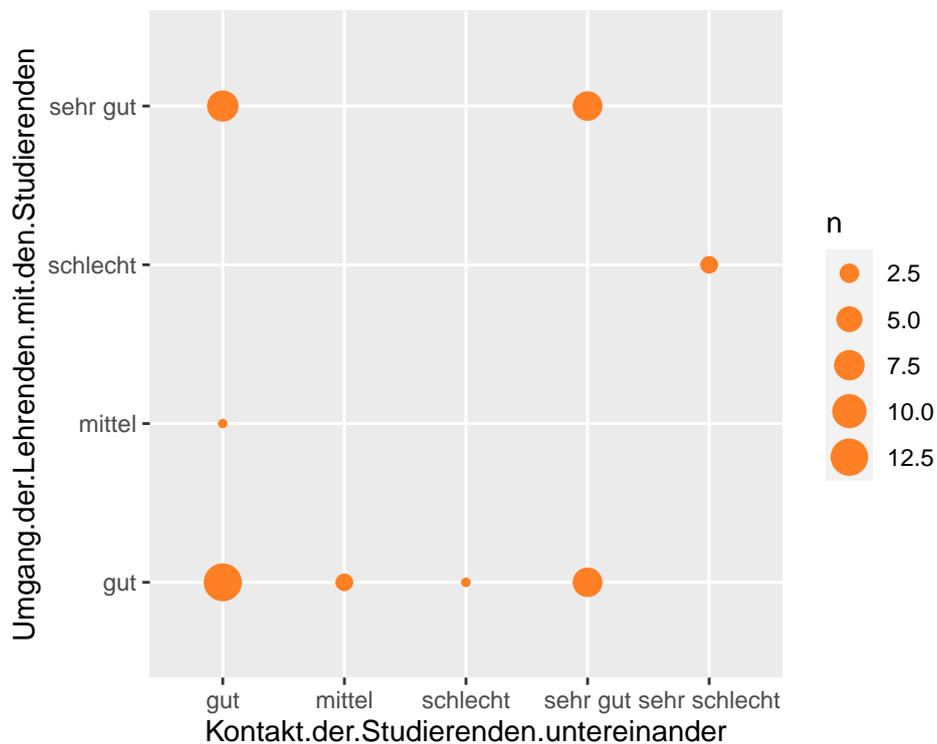
Lösung:

```
#
# (i)
dat.Absolventen <- read.csv2("AbsolventenDat.csv",na.strings = c("-", "k.A."))
# (ii)
dat.Absolventen |> mutate(
  Kontakt.der.Studierenden.untereinander =
    factor( Kontakt.der.Studierenden.untereinander,
            levels = list( "1"="sehr gut", "2"="gut", "3"="mittel",
                          "4"="schlecht", "5"="sehr schlecht" ) ),
  Umgang.der.Lehrenden.mit.den.Studierenden =
    factor( Umgang.der.Lehrenden.mit.den.Studierenden,
            levels = list( "1"="sehr gut", "2"="gut", "3"="mittel",
                          "4"="schlecht", "5"="sehr schlecht" ) ) )
```

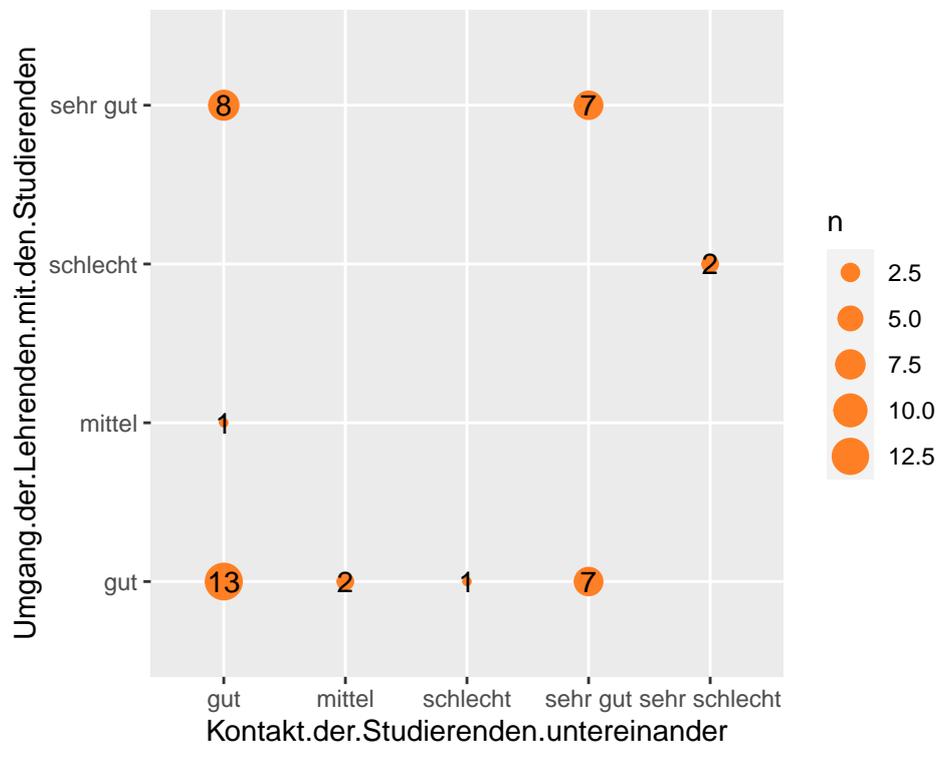
```
#
# (iii)
table( dat.Absolventen$Kontakt.der.Studierenden.untereinander,
        dat.Absolventen$Umgang.der.Lehrenden.mit.den.Studierenden )
```

	gut	mittel	schlecht	sehr gut
gut	13	1	0	8
mittel	2	0	0	0
schlecht	1	0	0	0
sehr gut	7	0	0	7
sehr schlecht	0	0	2	0

```
#
# (iv)
dat.Absolventen |> ggplot() +
  geom_count(mapping = aes(x = Kontakt.der.Studierenden.untereinander,
                           y = Umgang.der.Lehrenden.mit.den.Studierenden),
             color="chocolate1")
```



```
# (v) [Lösung aus Stackoverflow]
p <- dat.Absolventen |> ggplot(mapping = aes(x = Kontakt.der.Studierenden.untereinander,
                                             y = Umgang.der.Lehrenden.mit.den.Studierenden)) +
  geom_count(color="chocolate1")
p + geom_text(data = ggplot_build(p)$data[[1]], aes(x, y, label = n), color = "black")
```



Sei $(x_i, y_i), i = 1, \dots, n$, eine bivariate Stichprobe zweier metrischer Merkmale mit $s_x > 0, s_y > 0$ und Pearson-Korrelationskoeffizient $r_{x,y}$, wobei $x = (x_1, \dots, x_n)^T$ und $y = (y_1, \dots, y_n)^T$. Zeigen Sie, dass die folgenden Aussagen gelten.

(i) $-1 \leq r_{x,y} \leq 1$

(ii) $\forall i = 1, \dots, n : y_i = a + bx_i, a, b \in \mathbb{R}, b \neq 0 \Rightarrow r_{x,y} = \text{sgn}(b)$, wobei $\text{sgn} : \mathbb{R} \rightarrow \{-1, 0, 1\}$ die Signum- oder Vorzeichenfunktion mit der Abbildungsvorschrift

$$\text{sgn}(x) = \begin{cases} -1 & \text{für } x < 0 \\ 0 & \text{für } x = 0 \\ 1 & \text{für } x > 0 \end{cases}$$

bezeichnet.

(iii) $r_{x,y} = \pm 1 \Rightarrow \exists a, b \in \mathbb{R}, \text{sgn}(b) = \text{sgn}(r_{x,y}) : y_i = a + bx_i, \forall i = 1, \dots, n$.

Hinweis: Verwenden Sie die Ungleichung von Cauchy-Schwarz (Schwarzsche Ungleichung): Für alle $u, v \in \mathbb{R}^n, n \in \mathbb{N}$, gilt, dass

$$|u \cdot v| \leq \|u\| \|v\|.$$

Das Gleichheitszeichen gilt genau dann, falls u und v linear abhängig sind. Der Malpunkt steht dabei für das Skalarprodukt.

Lösung:

(i) Da

$$r_{x,y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{x \cdot y}{\|x\| \cdot \|y\|}$$

folgt nach der Cauchy-Schwarz-Ungleichung (CSU) sofort die Behauptung. #

(ii) Es gelte $\forall i = 1, \dots, n : y_i = a + bx_i, a, b \in \mathbb{R}, b \neq 0$. Damit gilt auch für die Vektoren: $y = a + bx$. Also sind x und y linear abhängige Vektoren (siehe LA-Vorlesung, S. 110). Damit folgt mit der CSU: $|x \cdot y| = \|x\| \cdot \|y\|$ und damit $|r_{x,y}| = 1$. Da

$$\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n (x_i - \bar{x})b(x_i - \bar{x}) = b\|x - \bar{x}\|^2 (*)$$

folgt die Behauptung.

(iii) Sei $r_{x,y} = \pm 1$. Dann gilt:

$$|(x - \bar{x}) \cdot (y - \bar{y})| = \|x - \bar{x}\| \cdot \|y - \bar{y}\|$$

(\bar{x} und \bar{y} decken wir uns hierbei als Vektoren mit n gleichen Elementen). Nach der CSU sind daher $x - \bar{x}$ und $y - \bar{y}$ linear abhängig. Folglich existiert nach der LA-Vorlesung ein $b \in \mathbb{R}$ mit: $y - \bar{y} = b(x - \bar{x})$ und damit $y = bx + a$ mit $a := \bar{y} - b\bar{x}$.

Die Tatsache, dass b und $r_{x,y}$ das gleiche Vorzeichen haben müssen, folgt aus (*).