

# TUTORIUM

# Datenauswertung

REGRESSIONSANALYSE

# AGENDA

- Regressionsanalyse – Basics
- Regressionsanalyse in R
- Interpretation von Regressionsanalysen
- Prognosen mit Regressionsanalysen
- Drittvariablenkontrolle mit Regressionsanalysen

# REGRESSIONSANALYSE – BASICS

## Die Regressionsanalyse

- Ist ein Verfahren, das benutzt wird, um
  - Den Einfluss mindestens einer unabhängigen Variablen auf eine abhängige Variable zu untersuchen → Kausalannäherung
  - Scheinkorrelationen zu vermeiden → Drittvariablenkontrolle
  - Hypothesen über die Zukunft aufzustellen → Prognosen
- Gibt es in verschiedenen Arten:
  - Linear vs. Nicht-linear
  - Einfach (eine UV) vs. multipel (mehr als eine UV)

# LINEARE REGRESSIONSANALYSE – BASICS

## Die lineare Regressionsanalyse

- Stellt ein lineares Gleichungsmodell auf, sodass
  - Eine abhängige Variable durch eine Menge unabhängiger Variablen geschätzt wird
  - die Summe der quadrierten Abstände der abhängigen Variable von der geschätzten abhängigen Variable minimal ist
- Erfordert metrisch skalierte abhängige und unabhängige Variablen

# LINEARE REGRESSIONSANALYSE – GLEICHUNGSMODELL

$$\hat{y}_i = a + b_1 * x_1 + \dots + b_n * x_n$$

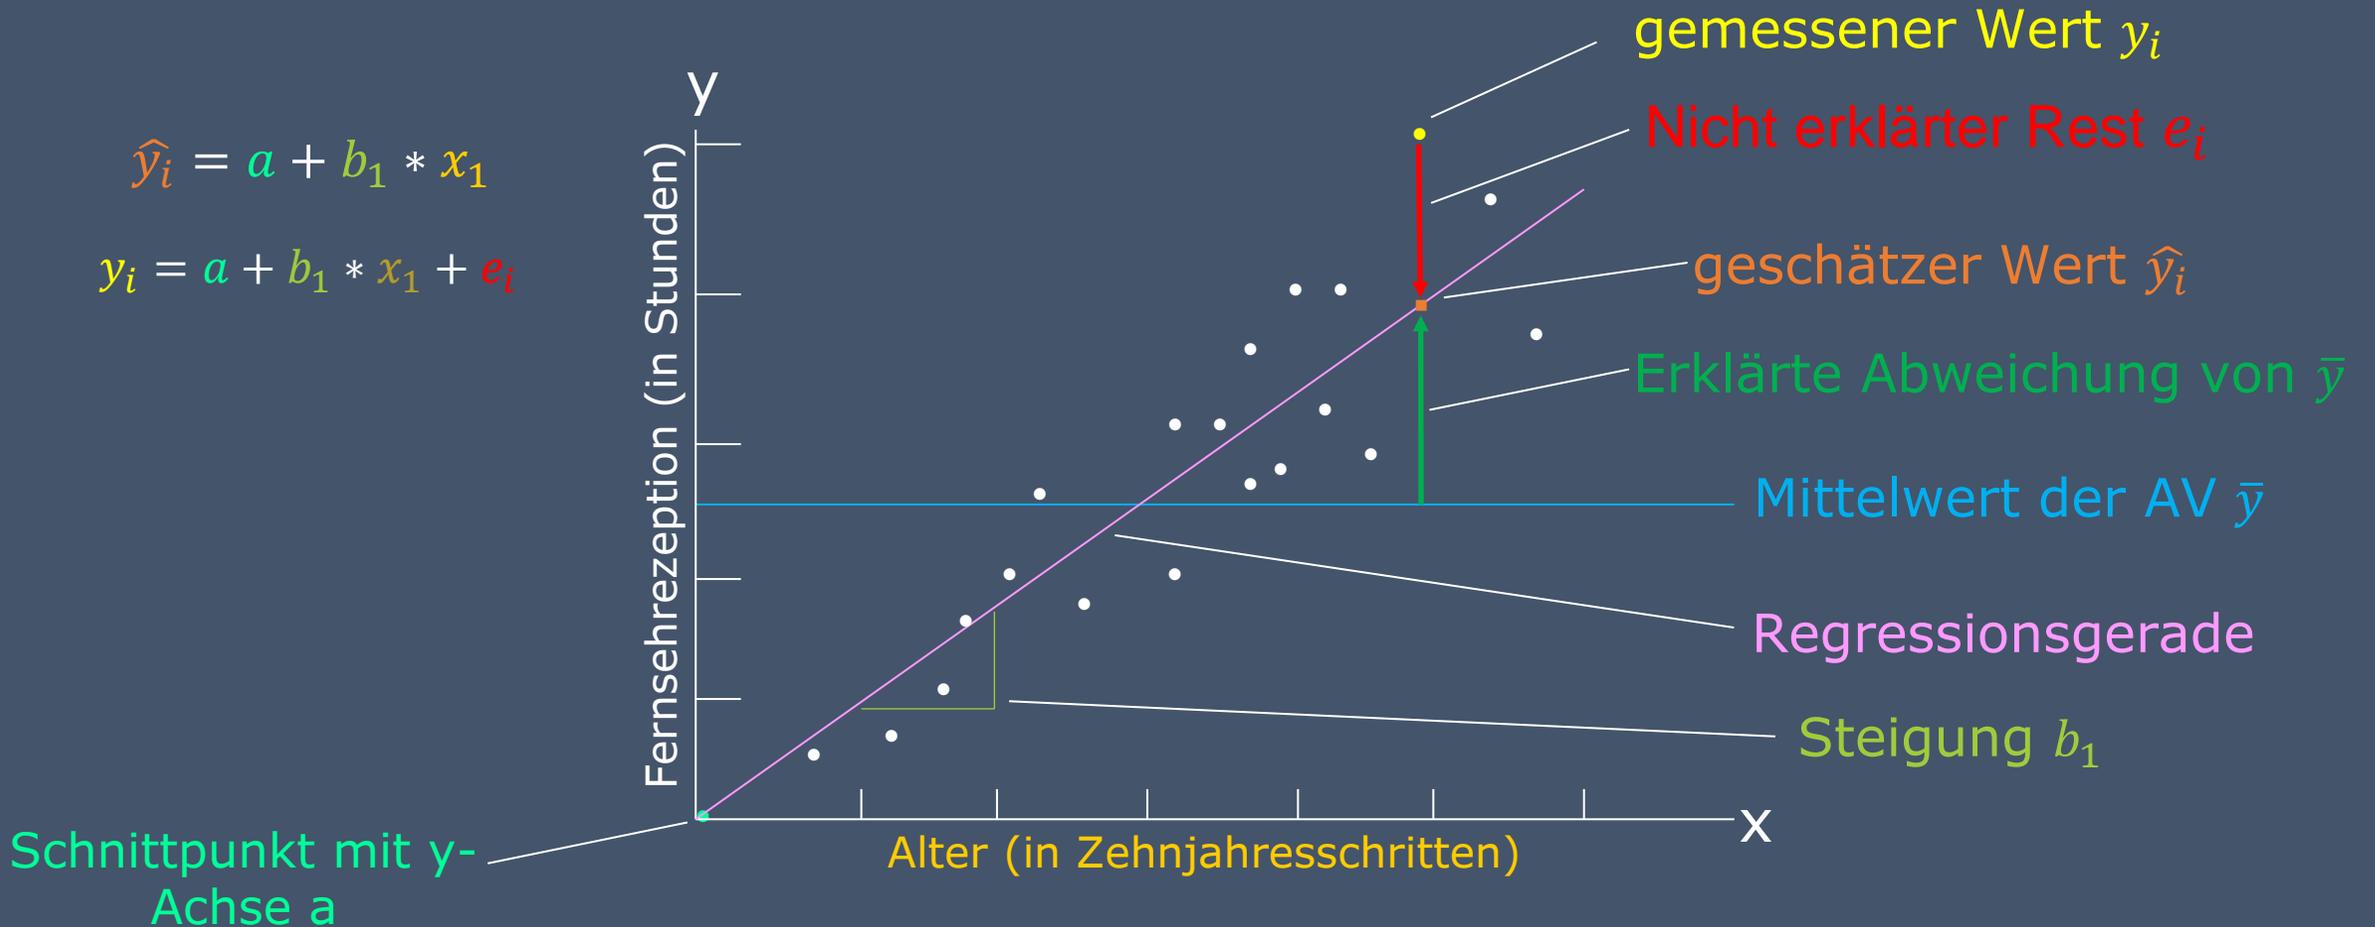
$$y_i = a + b_1 * x_1 + \dots + b_n * x_n + e_i$$

Variable	Bedeutung	Name in R
$y_i$	Tatsächlich gemessener Wert der AV für Fall i	[Name der AV in R]
$\hat{y}_i$	Geschätzter Wert der AV für Fall i	-
$a$	Schnittpunkt der Regressionsgeraden mit der y-Achse	Intercept
$b_1$	Steigung der AV, wenn $x_1$ um 1 steigt (Regressionskoeffizient)	Estimate
$x_1$	Erste unabhängige Variable der Gleichung	[Name der ersten UV in R]
$e_i$	Abweichung des geschätzten Wertes $\hat{y}_i$ vom tatsächlich gemessenen Wert $y_i$	Residuals

# LINEARE REGRESSIONSANALYSE – BEISPIEL

$$\hat{y}_i = a + b_1 * x_1$$

$$y_i = a + b_1 * x_1 + e_i$$



# DER DETERMINATIONSKOEFFIZIENT $R^2$

## Der Determinationskoeffizient $R^2$

– ist ein Maß dafür, welchen Anteil der Varianz der AV das Modell erklärt:

Interpretation	Mathematisch	graphisch
Das Modell erklärt so viel Varianz wie der Mittelwert	$R^2 = 0$	die Regressionsgerade ist identisch mit der Mittelwertgeraden
Das Modell erklärt die gesamte Varianz der AV	$R^2 = 1$	Alle Punkte liegen auf der Regressionsgeraden

- Sollte größer als 0,1 sein
- Ist für einfache Regression identisch mit  $r^2$
- Wird bei multipler Regression an die Anzahl der UVs angepasst → adjusted  $R^2$

# DER BETAKOEFFIZIENT $\beta$

## Der Betakoeffizient $\beta$

- Ist der standardisierte Regressionskoeffizient  $b$
- Wird berechnet, weil  $b$  von der Maßeinheit und der Streubreite abhängt
- Macht die Effekte der unabhängigen Variablen auf die abhängige Variable vergleichbar
- lässt sich für die  $n$ te UV so berechnen:  $\beta_n = \frac{b_n}{s_{x_n} * s_y}$

# REGRESSIONSANALYSE IN R: BESCHREIBUNG DER DATEN

```
#Laden der Pakete
library(knitr)
library(mosaic)
# Laden und Auswählen der Daten
load("daten_x.RData")
datensatz <- subset(daten_x, Bedingung)
#Berechnung der Lage- und Streuungsmaße
kable(round(rbind("AV-Label" = favstats(datensatz$AV),
  "UV1-Label" = favstats(datensatz$UV1),
  "UV2-Label" = favstats(datensatz$UV2),
  "UV3-Label" = favstats(datensatz$UV3)), 2))
```

# REGRESSIONSANALYSE IN R: BESCHREIBUNG DER DATEN – BEISPIEL

```
#Laden der Pakete
library(knitr)
library(mosaic)
# Laden und Auswählen der Daten
load("daten_2019.RData")
datensatz <- subset(daten_2019, jahr > 2000)
#Berechnung der Lage- und Streuungsmaße
kable(round(rbind("Radiokonsum" = favstats(datensatz$radio_minuten),
  "Zeitungskonsum" = favstats(datensatz$tz_minuten),
  "Jahrgang" = favstats(datensatz$soz_jahrgang),
  "Haushaltsgröße" = favstats(datensatz$soz_haushalt)), 2))
```

	<b>min</b>	<b>Q1</b>	<b>median</b>	<b>Q3</b>	<b>max</b>	<b>mean</b>	<b>sd</b>	<b>n</b>	<b>missing</b>
Radiokonsum	0	10	45	120	720	93.09	127.05	482	6
Zeitungskonsum	0	0	15	30	180	22.10	24.80	476	12
Jahrgang	1943	1963	1971	1991	2004	1974.09	16.00	488	0
Haushaltsgröße	0	1	2	3	19	1.83	1.51	486	2

# REGRESSIONSANALYSE IN R: REGRESSIONSMODELL

```
#Laden der Pakete
library(knitr)
library(QuantPsyc)
# Laden und Auswählen der Daten
load("daten_x.RData")
datensatz <- subset(daten_x, Bedingung)
#Regressionsmodell
regression = lm(AV ~ UV1 + UV2 + UV3, data= datensatz)
summary(regression)
lm.ergebnis <- summary(regression)
coeff <- round(lm.ergebnis$coefficients[-1,], 2)
Std.coeff <- round(lm.beta(regression), 2)
coeff.gesamt <- data.frame(coeff, Std.coeff)
kable(coeff.gesamt)
```

# REGRESSIONSANALYSE IN R: REGRESSIONSMODELL – BEISPIEL

```
#Laden der Pakete
library(knitr)
library(QuantPsyc)
# Laden und Auswählen der Daten
load("daten_2019.RData")
datensatz <- subset(daten_2019, jahr > 2000)
#Regressionsmodell
regression = lm(radio_minuten ~ tz_minuten + soz_jahrgang + soz_haushalt, data= datensatz)
summary(regression)
lm.ergebnis = summary(regression)
coeff = round(lm.ergebnis$coefficients[-1,], 2)
std.coeff = round(lm.beta(regression), 2)
coeff.gesamt = data.frame(coeff, std.coeff)
kable(coeff.gesamt)
```

```
Call:      AV →          UV1 →          UV2 →          UV3 →  
lm(formula = radio_minuten ~ tz_minuten + soz_jahrgang + soz_haushalt,  
    data = datensatz)
```

Residuals: ← Verteilung der nicht erklärten Abweichungen vom gemessenen Wert

```
      Min       1Q   Median       3Q      Max  
-160.22  -68.69  -39.30   13.47   620.25
```

Signifikanzwerte der Regressionskoeffizienten

Coefficients:

		Estimate	Std. Error	t value	Pr(> t )	
(Intercept)		4177.6372	<i>a</i> 792.7439	5.270	2.09e-07	*** ←
tz_minuten	<i>x</i> <sub>1</sub>	0.1519	<i>b</i> <sub>1</sub> 0.2573	0.590	0.555	
soz_jahrgang	<i>x</i> <sub>2</sub>	-2.0702	<i>b</i> <sub>2</sub> 0.4007	-5.166	3.55e-07	***
soz_haushalt	<i>x</i> <sub>3</sub>	-0.6954	<i>b</i> <sub>3</sub> 3.7695	-0.184	0.854	↑

---  
Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

signifikant

$R^2 < 0,1 \rightarrow$  schlechtes Modell!

Residual standard error: 123.3 on 467 degrees of freedom  
(17 observations deleted due to missingness)

Multiple R-squared: 0.07579, Adjusted R-squared: 0.06985

F-statistic: 12.77 on 3 and 467 DF, p-value: 4.959e-08

$p < 0.05$ :  
signifikant!

Unabhängige Variablen    Regressionkoeffizienten  $b$     Signifikanzwerte der Regressionkoeffizienten    Standardisierte Regressionkoeffizienten  $\beta$

	<b>Estimate</b>	<b>Std..Error</b>	<b>t.value</b>	<b>Pr...t..</b>	<b>std.coeff</b>
tz_minuten	0.15	0.26	0.59	0.56	0.03
soz_jahrgang	-2.07	0.40	-5.17	0.00	-0.26
soz_haushalt	-0.70	3.77	-0.18	0.85	-0.01

# REGRESSION – KAUSALANNÄHERUNG

Der kausale Einfluss einer UV auf eine AV ist zu vermuten dann und nur dann, wenn...

- Die Vermutung über den Effekt auf einer Theorie basiert
- Alle möglichen Einflussfaktoren miterhoben und ins Regressionsmodell miteinbezogen wurden
- Der Regressionskoeffizient der UV dennoch signifikant ist

# REGRESSION – PROGNOSEN

## Prognosen

- Sind Schätzungen über die (möglicherweise zukünftige) Ausprägung einer AV aufgrund mindestens einer UV
- Können anhand von Regressionsgleichungen aufgestellt werden, indem man die Werte der UVs für den betrachteten Fall in die Regressionsgleichung einsetzt
- Beispiel: Wetterprognosen

# PROGNOSEN – BEISPIEL I

Call:

```
lm(formula = daten_2019$tv_minuten ~ daten_2019$soz_jahrgang +  
    daten_2019$tz_minuten)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	3869.8680	503.2073	7.690	8.64e-14	***
daten_2019\$soz_jahrgang	-1.9134	0.2541	-7.531	2.60e-13	***
daten_2019\$tz_minuten	0.5965	0.1651	3.614	0.000334	***

Form:  $\hat{y}_i = a + b_1 * x_1 + \dots + b_n * x_n$

Eingesetzt:  $\widehat{tv\_minuten}_i = 3870 - 1,9 * soz\_jahrgang + 0,6 * tz\_minuten$

# PROGNOSEN – BEISPIEL II

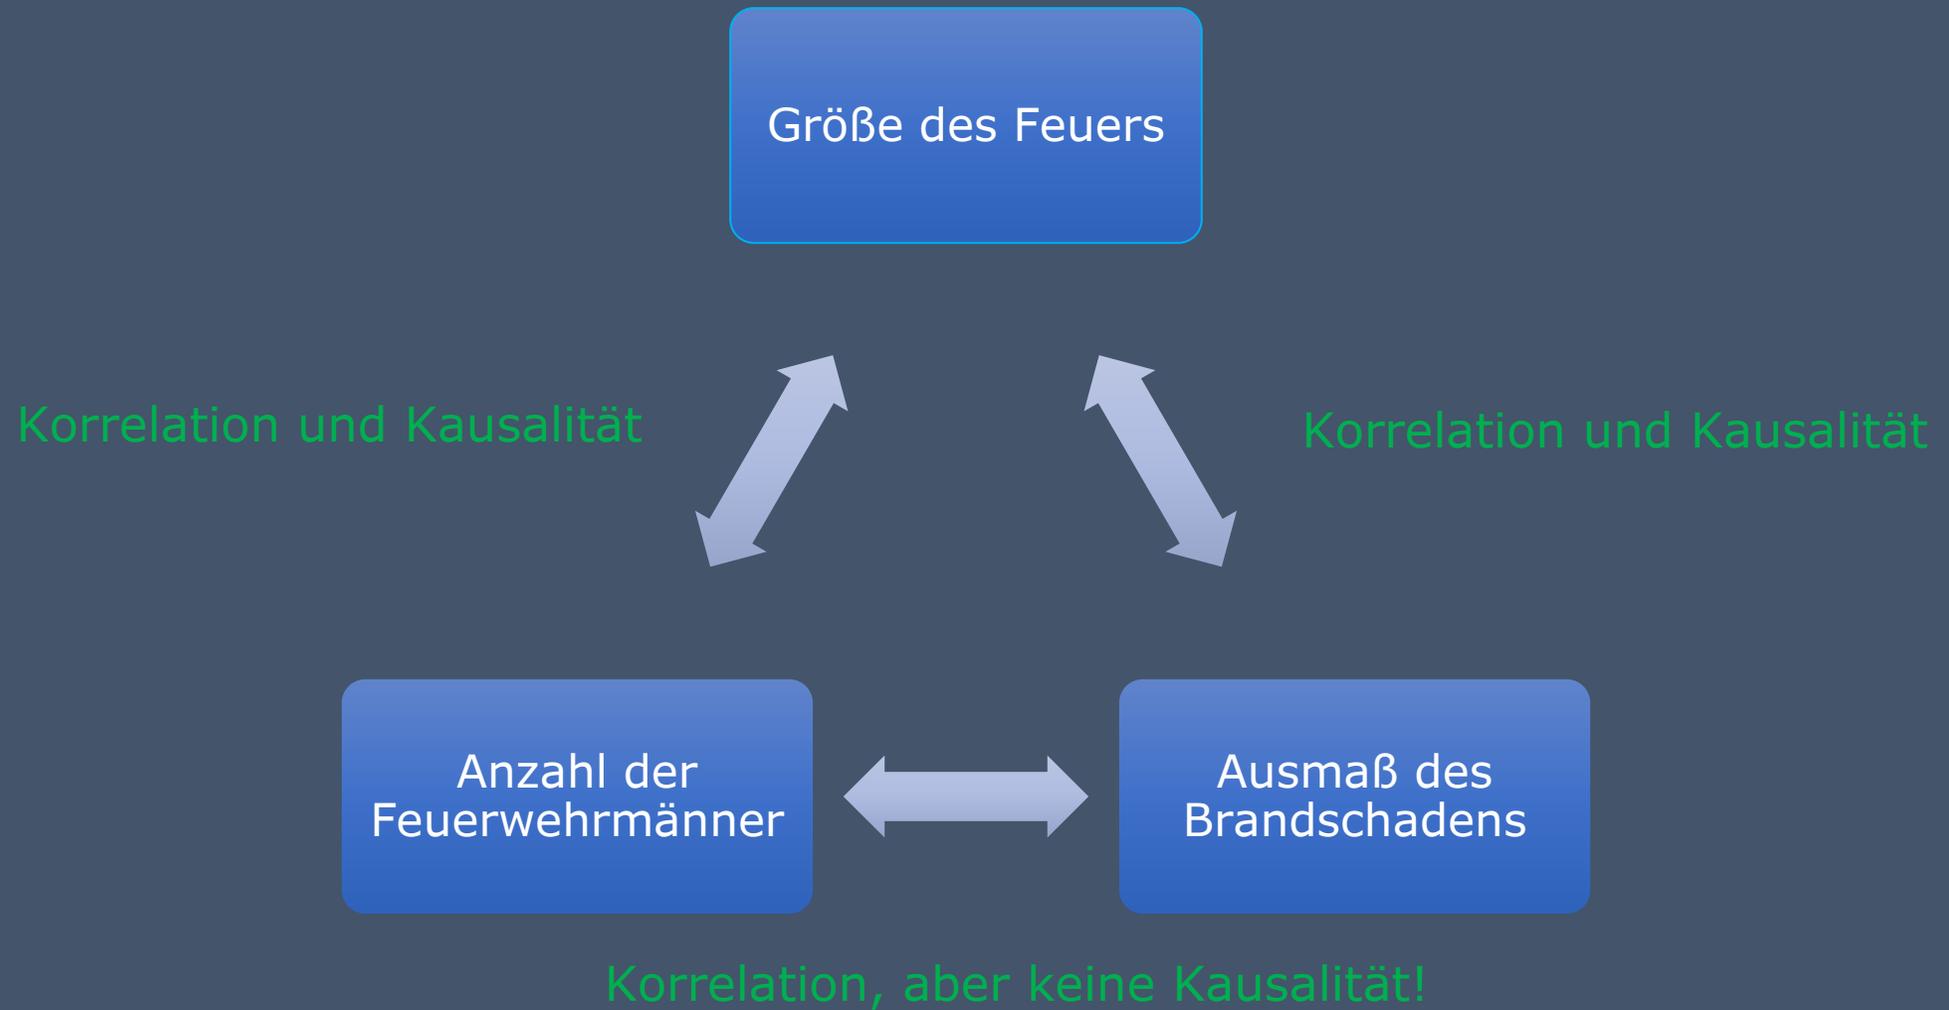
Formel:  $\widehat{tv\_minuten}_i = 3870 - 1,9 * soz\_jahrgang + 0,6 * tz\_minuten$

Aufgabe	Peter ist 1990 geboren und liest 45 Minuten Zeitung pro Tag. Schätzt, wie lange er pro Tag fern schaut.
Rechnung	$\widehat{tv\_minuten}_{Peter} = 3870 - 1,9 * 1990 + 0,6 * 45 = 116$
Lösung	Peter schaut voraussichtlich ca. 2 Stunden fern pro Tag.

# REGRESSION – DRITTVARIABLENKONTROLLE

## Die Drittvariablenkontrolle

- Prüft den Einfluss einer möglichen Störvariable auf eine unabhängige Variable
- Deckt damit Scheinkorrelationen auf
- Kann durchgeführt werden, indem die Störvariable als weitere UV in die Regressionsgleichung miteinbezogen wird:
  - Der Regressionskoeffizient der UV ist signifikant → keine Scheinkorrelation
  - Der Regressionskoeffizient der UV ist nicht signifikant → Scheinkorrelation



	<b>Anzahl der Feuerwehrmänner</b>	<b>Höhe des Brandschadens</b>	<b>Größe des Feuers</b>
Anzahl der Feuerwehrmänner	1.00	0.79	0.92
Höhe des Brandschadens	0.79	1.00	0.84
Größe des Feuers	0.92	0.84	1.00

→ Alle Variablen korrelieren sehr stark miteinander, auch die Höhe des Brandschadens mit der Anzahl der Feuerwehrmänner!

Call: `lm(formula = brandschaden ~ anzahl_feuerwehr + grösse_feuer)`

AV → UV → Störvariable →

Residuals:

Min	1Q	Median	3Q	Max
-5.0408	-0.2424	0.4968	0.5087	1.3089

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	0.4677	0.8497	0.550	0.5892
anzahl_feuerwehr	0.1245	0.3276	0.380	0.7087
grösse_feuer	0.7629	0.3593	2.124	0.0487 *

---  
Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Nicht signifikant → Scheinkorrelation!

Signifikant → keine Scheinkorrelation!

Residual standard error: 1.484 on 17 degrees of freedom

Multiple R-squared: 0.7092, Adjusted R-squared: 0.6749

F-statistic: 20.73 on 2 and 17 DF, p-value: 2.761e-05

Extrem gutes Modell!

Signifikantes Modell!

# FRAGEN?

# SELBSTSTUDIUM

- Forschungsbericht (nur EFB):
  - Regressionsmodell:  $\text{www\_minuten} \sim \text{tz\_minuten} + \text{soz\_haushalt} + \text{soz\_jahrgang}$
  - Inhaltliche Sätze zu den Ergebnissen
  - Vergleich  $\text{tz\_minuten}$  im Regressionsmodell und Korrelation  $\text{tz\_minuten}, \text{www\_minuten} \rightarrow$  Scheinkorrelation?
- Fragen zur Wiederholungssitzung sammeln und bis Freitag, 29.06.2019, 23:59 Uhr per Mail zuschicken
- Forschungsbericht bis Sonntag, 30.06.2019, 23:59 Uhr ins Learnweb hochladen

**BIS NÄCHSTE WOCHEN!**