

Statistik

für Betriebswirtschaft, Internationales Management,
Wirtschaftsinformatik und Informatik

Sommersemester 2016

Veranstaltungen zur Statistik für BW/IM Sommersemester 2016				
Was?	Wer?	Wann?	Wo?	ab wann?
Vorlesung Statistik	Etschberger	Mi, 14.00-17.00	B2.14	16.03.2016
Vorlesung Statistik PLUS	Etschberger/Jansen	- Blocktermin -	?	?
Übung Statistik	Etschberger	Mi, 17.00-18.30	A1.10	30.03.2016
Übung Statistik	Jansen	Di, 11.30-13.00	W1.06	22.03.2016
Übung Statistik	Jansen	Di, 14.00-15.30	W2.14	22.03.2016
Übung Statistik	Jansen	Mi, 11.30-13.00	W2.11	30.03.2016
Übung Statistik	Jansen	Do, 14.00-15.30	W2.14	31.03.2016
Übung Statistik	Schneller	Do, 14.00-15.30	W3.03	31.03.2016
Übung Statistik	Schneller	Do, 15.30-17.00	W3.03	31.03.2016
Übung Statistik	Wins	Di, 14.00-15.30	J3.19	22.03.2016
Übung Statistik	Wins	Di, 15.30-17.00	J3.19	22.03.2016
Offener Statistikraum	Etschberger/Tutoren	Mo, 14.00-17.45	B3.05	04.04.
Veranstaltungen für Teilnehmer der WiMa-Klausur im Juli 2016				
Was?	Wer?	Wann?	Wo?	ab wann?
Tutorium Mathematik	Burkart	Do 13.30-15.00	W1.06	07.04.2016
Tutorium Mathematik	Burkart	Do 15.00-16.15	W1.06	07.04.2016
Offener Matheraum	Jansen/Tutoren	?	?	?

HSA Statistik SS 2016 Sessionlist		
Datum	Statistik für IM/BW	Nr.
Mittwoch, 16. März 2016	Einführung, R Installation, Rstudio Einführung, Skalen	1
Mittwoch, 23. März 2016	univ. desk. Stat., Quantile, Plots	2
Mittwoch, 30. März 2016	Streuung, Konzentrationsmaße	3
Mittwoch, 6. April 2016	Kontingenztabellen, Mosaikplots, Korrelation	4
Mittwoch, 13. April 2016	Preisindizes, lineare Regression	5
Mittwoch, 20. April 2016	Kombinatorik, Wahrscheinlichkeit	6
Mittwoch, 27. April 2016	Wahrscheinlichkeit, diskrete Zufallsvariablen	7
Mittwoch, 4. Mai 2016	Pyramid	
Mittwoch, 11. Mai 2016	Binomial-, Hypergeom.-, Poisson-Verteilung	8
Mittwoch, 18. Mai 2016	Stetige ZV, Gleichverteilung	9
Mittwoch, 25. Mai 2016	Normalverteilung, Verteilungsparameter	10
Mittwoch, 1. Juni 2016	Schätzfunktionen und Punktschätzer	11
Mittwoch, 8. Juni 2016	Konfidenzintervalle	12
Mittwoch, 15. Juni 2016	Tests	13
Mittwoch, 22. Juni 2016	Puffer, WH, Fragen zur Probekl.	14
Mittwoch, 29. Juni 2016	AW Prüfungswoche	

Prof. Dr. Stefan Etschberger
Hochschule Augsburg

i 1 2 3 4 5
 p_i p_1 p_2 p_3 p_4 p_5

$$CR_2 = \sum_{i=5-2+1}^5 p_i = \sum_{i=4}^5 p_i = p_4 + p_5$$

- **Konzentrationskoeffizient:**

$$CR_g = \text{Anteil, der auf die } g \text{ größten entfällt} = \sum_{i=n-g+1}^n p_i = 1 - v_{n-g}$$

- **Herfindahl-Index:**

$$H = \sum_{i=1}^n p_i^2 \quad (\in [\frac{1}{n}; 1])$$

Es gilt: $H = \frac{1}{n} (V^2 + 1)$ bzw. $V = \sqrt{n \cdot H - 1}$

- **Exponentialindex:**

$0^0 \cdot 0.01 \cdot 0.03 \cdot 0.96$


$$E = \prod_{i=1}^n p_i^{p_i} \quad (\in [\frac{1}{n}; 1]) \quad \text{wobei} \quad 0^0 = 1$$

- Im Beispiel mit $x = (1, 2, 2, 15)$:

$$CR_2 = \frac{17}{20} = 0,85$$

$$H = \left(\frac{1}{20}\right)^2 + \dots + \left(\frac{15}{20}\right)^2 = 0,59$$


$$E = \left(\frac{1}{20}\right)^{\frac{1}{20}} \dots \left(\frac{15}{20}\right)^{\frac{15}{20}} = 0,44$$



$$H = \sum p_i^4 = 0^4 + 1^4 = 1$$

$$E = \prod p_i^{p_i} = 0^0 \cdot 1^1 = 1$$

Urliste: $x = 2 \text{ Mio}, 2 \text{ Mio}, 2 \text{ Mio}$
 Quellen
 Tabellen



$$H = \sum p_i^2 = \left(\frac{1}{3}\right)^2 + \left(\frac{1}{3}\right)^2 + \left(\frac{1}{3}\right)^2 = 3 \cdot \frac{1}{9} = \frac{1}{3}$$

Beispiel: $x = \underbrace{1 \text{ Mio}, 1 \text{ Mio}, \dots, 1 \text{ Mio}}_{n \text{-mal}}$

$$p_i = \frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n}$$

$$\Rightarrow H = \left(\frac{1}{n}\right)^2 + \dots + \left(\frac{1}{n}\right)^2 = n \cdot \left(\frac{1}{n}\right)^2 = \frac{1}{n}$$



1. Einführung
2. Deskriptive Statistik
 - Häufigkeiten
 - Lage und Streuung
 - Konzentration
 - Zwei Merkmale
 - Korrelation
 - Preisindizes
 - Lineare Regression
3. W-Theorie
4. Induktive Statistik

R Markdown

This is an R Markdown document. Markdown is a simple formatting syntax for authoring HTML, PDF, and MS Word documents. For more details on using R Markdown see <http://rmarkdown.rstudio.com>.

When you click the **Knit** button a document will be generated that includes both content as well as the output of any embedded R code chunks within the document. You can embed an R code chunk like this:

```
# -----
# Statistik SS 2016: R Mitschrift aus Vorlesung
# -----

# Daten aus dem Netz
Umfrage = read.csv("http://goo.gl/KCGF16", sep=";", dec=",")

# Aufgabe zu Lorenzkurve und Gini-Koeffizient
require(ineq) # Paket ist nötig


## Loading required package: ineq

## Warning: package 'ineq' was built under R version 3.1.3

set.seed(4)
x = c(max(na.exclude(Umfrage$AusgKomm)), sample(Umfrage$AusgKomm, 4))
x

## [1] 4668 250 420 250 300

# Aufgabe:
# a) Zeichne Lorenzkurve (5 Minuten)
```



```
cumsum(sort(x))/sum(x)

## [1] 0.04245924 0.08491848 0.13586957 0.20720109 1.00000000

# Gini von Hand
pi = sort(x)/sum(x) # Sortieren nicht vergessen
n = length(x)
x.Gini = ((2*sum(pi*(1:n))) - 6)/n
pi

## [1] 0.04245924 0.04245924 0.05095109 0.07133152 0.79279891

x.Gini

## [1] 0.6118207


# Oder über Paket ineq
Gini(x)
```

```
> # Aufgabe zu Lorenzkurve und Gini-Koeffizient
> require(ineq) # Paket ist nötig
> set.seed(4)
> x = c(max(na.exclude(Umfrage$AusgKomm)), sample(Umfrage$AusgKomm, 4))
> x
[1] 4668 250 420 250 300
> # Aufgabe:
> # a) Zeichne Lorenzkurve (5 Minuten)
> # b) Berechne Gini-Koeffizient (3 Minuten)
>
> # Lösung
> plot(Lc(x))
> grid()
> sort(cumsum(x)/sum(x))
[1] 0.04245924 0.11379076 0.15625000 0.20720109 1.00000000
>
> # Gini von Hand
> pi = sort(x)/sum(x) # Sortieren nicht vergessen
> n = length(x)
> x.Gini = ((2*sum(pi*(1:n))) - 6)/n
> x.Gini
[1] 0.6118207
>
> # Oder über Paket ineq
> Gini(x)
[1] 0.6118207
```

Umfrage: In der letzten Aufgabe hatte ich

- A) Alles richtig
- B) Alles bis auf die Zeichnung richtig
- C) Einen Fehler in den Zahlen
- D) Mehr als einen Fehler in den Zahlen
- E) Ich wusste nicht, was zu tun ist

Ergebnis (n=149)



Zweidimensionale Urliste

Urliste vom Umfang n zu **zwei** Merkmalen X und Y :

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$$

Kontingenztabelle:

Sinnvoll bei wenigen Ausprägungen bzw. bei klassierten Daten.

Ausprägungen von X	Ausprägungen von Y			
	b_1	b_2	\dots	b_l
a_1	h_{11}	h_{12}	\dots	h_{1l}
a_2	h_{21}	h_{22}	\dots	h_{2l}
\vdots	\vdots	\vdots		\vdots
a_k	h_{k1}	h_{k2}	\dots	h_{kl}



1. Einführung

2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen



Unterscheide:

► **Gemeinsame Häufigkeiten:**

$$h_{ij} = h(a_i, b_j)$$

► **Randhäufigkeiten:**

$$h_{i.} = \sum_{j=1}^l h_{ij} \quad \text{und} \quad h_{.j} = \sum_{i=1}^k h_{ij}$$

► **Bedingte (relative) Häufigkeiten:**

$$f_1(a_i | b_j) = \frac{h_{ij}}{h_{.j}} \quad \text{und} \quad f_2(b_j | a_i) = \frac{h_{ij}}{h_{i.}}$$

1. Einführung

2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen



Beispiel: 400 unfallbeteiligte Autoinsassen:

	leicht verletzt (= b_1)	schwer verletzt (= b_2)	tot (= b_3)	
angegurtet (= a_1)	264 (= h_{11})	90 (= h_{12})	6 (= h_{13})	360 (= $h_{1.}$)
nicht angegurtet (= a_2)	2 (= h_{21})	34 (= h_{22})	4 (= h_{23})	40 (= $h_{2.}$)
	266 (= $h_{.1}$)	124 (= $h_{.2}$)	10 (= $h_{.3}$)	400 (= n)

Rand-
häufig-
häufig-
keit

$$f_2(b_3 | a_2) = \frac{4}{40} = 0,1$$

(10% der nicht angegurteten starben.)

$$f_1(a_2 | b_3) = \frac{4}{10} = 0,4$$

(40% der Todesopfer waren nicht angegurtet.)

1. Einführung

2. Deskriptive Statistik

Häufigkeiten
Lage und Streuung
Konzentration

Zwei Merkmale

Korrelation
Preisindizes
Lineare Regression

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen



Streuungsdiagramm sinnvoll bei vielen verschiedenen Ausprägungen (z.B. stetige Merkmale)


➡ Alle (x_i, y_i) sowie (\bar{x}, \bar{y}) in Koordinatensystem eintragen.

Beispiel:

i	1	2	3	4	5	Σ
x_i	2	4	3	9	7	25
y_i	4	3	6	7	8	28

$$\Rightarrow \bar{x} = \frac{25}{5} = 5$$

$$\bar{y} = \frac{28}{5} = 5,6$$



1. Einführung

2. Deskriptive Statistik

- Häufigkeiten
- Lage und Streuung
- Konzentration
- Zwei Merkmale
- Korrelation
- Preisindizes
- Lineare Regression

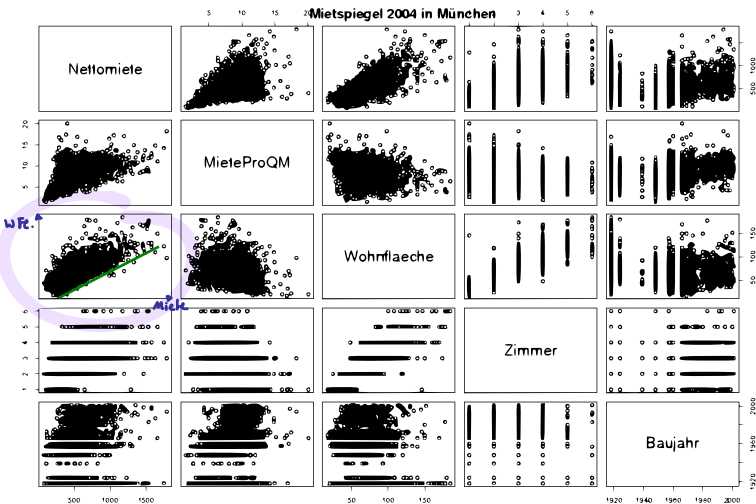
3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen

Beispiel Streudiagramm



(Datenquelle: Fahrmeir u. a. (2009))

1. Einführung

2. Deskriptive Statistik

Häufigkeiten
Lage und Streuung
Konzentration

Zwei Merkmale

Korrelation
Preisindizes
Lineare Regression


3. W-Theorie

4. Induktive Statistik

Quellen


Tabellen


```
if (!require("RColorBrewer")) {  
  install.packages("RColorBrewer")  
  library(RColorBrewer)  
}  
mieten <- read.table('http://goo.gl/jhpJW4', header=TRUE, sep='\t',  
                    check.names=TRUE, fill=TRUE, na.strings=c('', ''))  
x <- cbind(Nettomieten=mieten$nm, Wohnflaeche=mieten$wfl)  
  
library("geneplotter") ## from BioConductor  
smoothScatter(x, nrpoints=Inf,  
              colramp=colorRampPalette(brewer.pal(9, "YlOrRd")),  
              bandwidth=c(30, 3))
```



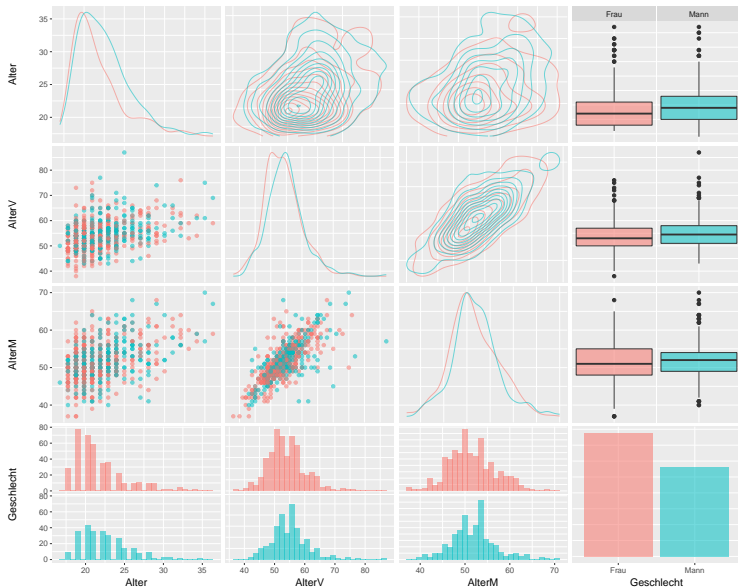
- 1. Einführung
- 2. Deskriptive Statistik
 - Häufigkeiten
 - Lage und Streuung
 - Konzentration
 - Zwei Merkmale
 - Korrelation
 - Preisindizes
 - Lineare Regression
- 3. W-Theorie
- 4. Induktive Statistik
- Quellen
- Tabellen

```
x = cbind("Alter des Vaters"=AlterV, "Alter der Mutter"=AlterM)  
require("geneplotter") ## from BioConductor  
smoothScatter(x, colramp=colorRampPalette(brewer.pal(9,"YlOrRd")) )
```



1. Einführung
 2. Deskriptive Statistik
 - Häufigkeiten
 - Lage und Streuung
 - Konzentration
 - Zwei Merkmale
 - Korrelation
 - Preisindizes
 - Lineare Regression
 3. W-Theorie
 4. Induktive Statistik
- Quellen
- Tabellen

```
require(GGally)
ggpairs(MyData[, c("Alter", "AlterV", "AlterM", "Geschlecht")],
        upper = list(continuous = "density", combo = "box"),
        color='Geschlecht', alpha=0.5)
```



1. Einführung

2. Deskriptive Statistik

Häufigkeiten
Lage und Streuung
Konzentration

Zwei Merkmale
Korrelation
Preisindizes
Lineare Regression

3. W-Theorie


4. Induktive Statistik

Quellen

Tabellen


Bagplot: Boxplot in 2 Dimensionen

```
require(aplpack)  
bagplot(jitter(AlterV), jitter(AlterM), xlab="Alter des Vaters", ylab="Alter der Mutter")  
## [1] "Warning: NA elements have been exchanged by median values!!"
```



1. Einführung
 2. Deskriptive Statistik
 - Häufigkeiten
 - Lage und Streuung
 - Konzentration
 - Zwei Merkmale
 - Korrelation
 - Preisindizes
 - Lineare Regression
 3. W-Theorie
 4. Induktive Statistik
- Quellen
- Tabellen

```
require(DescTools)
My.ohne.NA = na.exclude(MyData[,c("AlterM", "AlterV", "Alter")])
with(My.ohne.NA, {
  Alter.skaliert = (Alter-min(Alter))/(max(Alter)-min(Alter))
  PlotBubble(jitter(AlterM), jitter(AlterV), Alter.skaliert,
    col=SetAlpha("deeppink4", 0.3),
    border=SetAlpha("darkblue", 0.3),
    xlab="Alter der Mutter", ylab="Alter des Vaters",
    panel.first=grid(),
    main="")
})
```

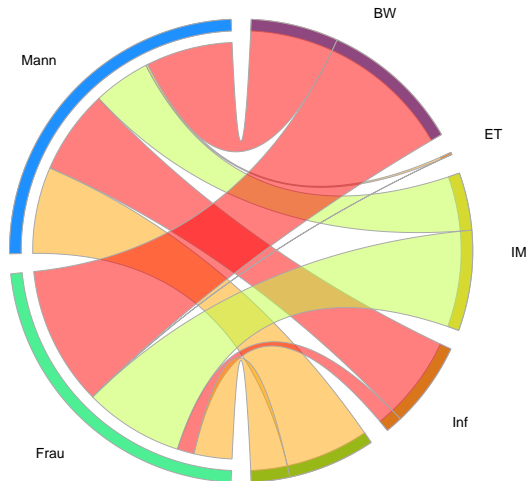


Größe der Blasen: Alter zwischen 0 (Jüngster) und 1 (Ältester)



1. Einführung
 2. Deskriptive Statistik
 - Häufigkeiten
 - Lage und Streuung
 - Konzentration
 - Zwei Merkmale
 - Korrelation
 - Preisindizes
 - Lineare Regression
 3. W-Theorie
 4. Induktive Statistik
- Quellen
- Tabellen

```
require(DescTools)
with(MyData, {
  PlotCirc(table(Studiengang, Geschlecht),
    acol=c("dodgerblue", "seagreen2", "limegreen", "olivedrab2", "goldenrod2", "tomato2"),
    rcol=SetAlpha(c("red", "orange", "olivedrab1"), 0.5)
  ))
```



1. Einführung
 2. Deskriptive Statistik
 - Häufigkeiten
 - Lage und Streuung
 - Konzentration
 - Zwei Merkmale
 - Korrelation
 - Preisindizes
 - Lineare Regression
 3. W-Theorie
 4. Induktive Statistik
- Quellen
- Tabellen

- ▶ Frage: Wie stark ist der Zusammenhang zwischen X und Y?
- ▶ Dazu: **Korrelationskoeffizienten**
- ▶ Verschiedene Varianten: Wahl abhängig vom Skalenniveau von X und Y:

Skalierung von X	Skalierung von Y		
	kardinal	ordinal	nominal
kardinal	Bravais-Pearson-Korrelationskoeffizient	Rangkorrelationskoeffizient von Spearman	Kontingenzkoeffizient
ordinal			
nominal			



- 1. Einführung
- 2. Deskriptive Statistik
 - Häufigkeiten
 - Lage und Streuung
 - Konzentration
 - Zwei Merkmale
 - Korrelation
 - Preisindizes
 - Lineare Regression
- 3. W-Theorie
- 4. Induktive Statistik
- Quellen
- Tabellen

Bravais-Pearson-Korrelationskoeffizient







Voraussetzung: X, Y kardinalskaliert

$$r = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sqrt{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \sqrt{\sum_{i=1}^n y_i^2 - n \bar{y}^2}} \in [-1; +1]$$

Kovarianz
von x und y

Standardabweichung
von x

Std. abw.
von y



1. Einführung

2. Deskriptive Statistik

- Häufigkeiten
- Loge und Streuung
- Konzentration
- Zwei Merkmale
- Korrelation
- Preisindizes
- Lineare Regression

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen

Bravais-Pearson-Korrelationskoeffizient




Im Beispiel:

i	x_i	y_i	x_i^2	y_i^2	$x_i y_i$
1	2	4	4	16	8
2	4	3	16	9	12
3	3	6	9	36	18
4	9	7	81	49	63
5	7	8	49	64	56
Σ	25	28	159	174	157

\Rightarrow

$$\bar{x} = 25/5 = 5$$

$$\bar{y} = 28/5 = 5,6$$



1. Einführung

2. Deskriptive Statistik

- Häufigkeiten
- Lage und Streuung
- Konzentration
- Zwei Merkmale
- Korrelation
- Preisindizes
- Lineare Regression

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen

(deutliche positive Korrelation)

$$r = \frac{157 - 5 \cdot 5 \cdot 5,6}{\sqrt{159 - 5 \cdot 5^2} \sqrt{174 - 5 \cdot 5,6^2}} = 0,703$$

Bravais-Pearson - Korrelationskoeffizient mit dem TR

x_i y_i

2	4
4	3
3	6
9	7
7	8

▶ Mode → STAT → A+Bx

▶ Daten eingeben ...

▶ **AC**; Shift → STAT → REG
(0.703) r ↙

Rangkorr. nach Spearman

Beispiel: X: Inhalt Geldbeutel
Y: Wie reich?

i	x_i	y_i	R_x		R_y
1	5,23	nicht	6	6	6
2	25,83	schon	4	3	4
3	134,17	sehr	1	1	1,5
4	27,80	sehr	3	2	1,5
5	12,17	schon	5	4	4
6	34,50	schon	2	5	4

Rangkorrelationskoeffizient nach Spearman entspricht dem korr. Koeff. von Bravais-Pearson auf Basis der Ränge beider Merkmale




guessthecorrelation.com

GUESS THE CORRELATION

NEW GAME
RESUME GAME
TWO PLAYERS
SCORE BOARD
ABOUT
SETTINGS

HIGH SCORE 
0

ETSCHSTE



HIGH SCORE MAIN MENU
0

NEXT

TRUE R	0.70
GUESSED R	0.70
DIFFERENCE	0.00

STREAKS	3
MEAN ERROR	0.07

 +1  +5
BONUS +5

Go for the Highscore!

1. Einführung

2. Deskriptive Statistik

Häufigkeiten
Lage und Streuung
Konzentration
Zwei Merkmale
Korrelation

Preisindizes
Lineare Regression

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen



- ▶ Voraussetzungen: X, Y (mindestens) ordinalskaliert, Ränge eindeutig (keine Doppelbelegung von Rängen)
- ▶ Vorgehensweise:
 - ① Rangnummern $R_i(X)$ bzw. $R'_i(Y)$ mit $R_i^{(j)} = 1$ bei größtem Wert usw.
 - ② Berechne

$$r_{SP} = 1 - \frac{6 \sum_{i=1}^n (R_i - R'_i)^2}{(n-1)n(n+1)} \in [-1; +1]$$

- ▶ Hinweise:
 - $r_{SP} = +1$ wird erreicht bei $R_i = R'_i \quad \forall i = 1, \dots, n$
 - $r_{SP} = -1$ wird erreicht bei $R_i = n + 1 - R'_i \quad \forall i = 1, \dots, n$
- ▶ Falls Ränge nicht eindeutig: Bindungen, dann Berechnung von r_{SP} über Ränge und Formel des Korr.-Koeff. von Bravais-Pearson

1. Einführung

2. Deskriptive Statistik

Häufigkeiten
Lage und Streuung
Konzentration
Zwei Merkmale
Korrelation

Preisindizes
Lineare Regression

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen



Im Beispiel:

x_i	R_i	y_i	R'_i
2	5	4	4
4	3	3	5
3	4	6	3
9	1	7	2
7	2	8	1

$$r_{SP} = 1 - \frac{6 \cdot [(5-4)^2 + (3-5)^2 + (4-3)^2 + (1-2)^2 + (2-1)^2]}{(5-1) \cdot 5 \cdot (5+1)} = 0,6$$

1. Einführung

2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen



- ▶ Gegeben: Kontingenztabelle mit k Zeilen und l Spalten (vgl. hier)
- ▶ Vorgehensweise:

- ① Ergänze Randhäufigkeiten

$$h_{i\cdot} = \sum_{j=1}^l h_{ij} \quad \text{und} \quad h_{\cdot j} = \sum_{i=1}^k h_{ij}$$

- ② Berechne **theoretische Häufigkeiten**

$$\tilde{h}_{ij} = \frac{h_{i\cdot} \cdot h_{\cdot j}}{n}$$

- ③ Berechne

$$\chi^2 = \sum_{i=1}^k \sum_{j=1}^l \frac{(h_{ij} - \tilde{h}_{ij})^2}{\tilde{h}_{ij}}$$

χ^2 hängt von n ab! ($h_{ij} \mapsto 2 \cdot h_{ij} \Rightarrow \chi^2 \mapsto 2 \cdot \chi^2$)

1. Einführung

2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen

	Verletzung			
	leicht	schwer	tödlich	
angegurtet	264 239,4	90 111,6	6 9	360 400
nicht angegurtet	2 26,6	34 42,4	4 1	40
	266	124	10	400

$$\frac{360 \cdot 124}{400}$$

chi-Quadrat

$$\chi^2 = \frac{(264 - 239,4)^2}{239,4} + \frac{(90 - 111,6)^2}{111,6} + \frac{(6 - 9)^2}{9} + \frac{(2 - 26,6)^2}{26,6} + \frac{(34 - 42,4)^2}{42,4} + \frac{(4 - 1)^2}{1}$$



④ Kontingenzkoeffizient:

$$K = \sqrt{\frac{\chi^2}{n + \chi^2}} \in [0; K_{\max}]$$

wobei

$$K_{\max} = \sqrt{\frac{M-1}{M}} \quad \text{mit}$$

$$M = \min\{k, l\}$$

$\Rightarrow M = \min\{2, 3\} = 2$
(2 Zeilen)

$$\Rightarrow K_{\max} = \sqrt{\frac{2-1}{2}} = \sqrt{0.5} \approx 0,707$$


$$K_* \approx \frac{0,40}{0,707} \approx 0,56$$

⑤ Normierter Kontingenzkoeffizient:

$$K_* = \frac{K}{K_{\max}} \in [0; 1]$$

$$K_* = +1 \iff$$

bei Kenntnis von x_i kann y_i erschlossen werden u.u.



Unfall bsp: $\chi^2 \approx 77, \dots$, $n = 400$
 $\Rightarrow K \approx 0,40$
 3 Spalten in Kont. Tabelle

- 1. Einführung
- 2. Deskriptive Statistik
 - Häufigkeiten
 - Lage und Streuung
 - Konzentration
 - Zwei Merkmale
 - Korrelation
 - Preisindizes
 - Lineare Regression
- 3. W-Theorie
- 4. Induktive Statistik
- Quellen
- Tabellen

Beispiel

X: Staatsangehörigkeit (d,a)

Y: Geschlecht (m,w)

h_{ij}	m	w	$h_{i.}$
d	30	30	60
a	10	30	40
$h_{.j}$	40	60	100

 \Rightarrow

\tilde{h}_{ij}	m	w
d	24	36
a	16	24

wobei $\tilde{h}_{11} = \frac{60 \cdot 40}{100} = 24$ usw.

$$\chi^2 = \frac{(30-24)^2}{24} + \frac{(30-36)^2}{36} + \frac{(10-16)^2}{16} + \frac{(30-24)^2}{24} = 6,25$$

$$K = \sqrt{\frac{6,25}{100+6,25}} = 0,2425; \quad M = \min\{2,2\} = 2; \quad K_{\max} = \sqrt{\frac{2-1}{2}} = 0,7071$$

$$K_* = \frac{0,2425}{0,7071} = 0,3430$$

6.4.2016

Aufgabe 22: Preisindex	30
Aufgabe 23: Rangkorrelation	31
Aufgabe 24: Lage Korrelation	32
Aufgabe 25: Kontingenzkoeffizient	33
Aufgabe 26: Kontingenzkoeffizient	34



1. Einführung

2. Deskriptive Statistik

Häufigkeiten
Lage und Streuung
Konzentration
Zwei Merkmale
Korrelation

Preisindizes
Lineare Regression

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen