

# Statistik

## für Betriebswirtschaft und internationales Management

Sommersemester 2015

HSA Statistik PLUS SS 2015 Sessionlist		
Datum	PLUS	Nr.
Dienstag, 17. März 2015	Einführung	1
Dienstag, 24. März 2015	univ. deskr. Stat., Konzentration	2
Dienstag, 31. März 2015	Konzentration	3
Dienstag, 7. April 2015	Ostern	
Dienstag, 14. April 2015	Korrelation, Preisindizes, Regression	4
Dienstag, 21. April 2015	Wahrscheinlichkeiten	5
Dienstag, 28. April 2015	diskrete Zufallsvariablen: Binomial, Hypergeo, Poisson	6
Dienstag, 5. Mai 2015	stetige ZV: Gleichvtlg., Normalvtlg.	7
Dienstag, 12. Mai 2015	Verteilungsparameter, Schätzfunktionen	8
Dienstag, 19. Mai 2015	Punktschätzer, Konfidenzintervalle	9
Dienstag, 26. Mai 2015	Pfingsten	
Dienstag, 2. Juni 2015	Tests	10
Dienstag, 9. Juni 2015	multivariate Verfahren	11
Dienstag, 16. Juni 2015	multivariate Verfahren	12
Dienstag, 23. Juni 2015	WH,Puffer, evtl. Fragen zu Probeklausur	13
Dienstag, 30. Juni 2015	Prüfungszeit	

Prof. Dr. Stefan Etschberger  
Hochschule Augsburg



► Berühmte Daten aus den 1970er Jahren:

$i$	$x_{1i}$	$x_{2i}$	$x_{3i}$	$x_{4i}$	$y_{1i}$	$y_{2i}$	$y_{3i}$	$y_{4i}$
1	10	10	10	8	8,04	9,14	7,46	6,58
2	8	8	8	8	6,95	8,14	6,77	5,76
3	13	13	13	8	7,58	8,74	12,74	7,71
4	9	9	9	8	8,81	8,77	7,11	8,84
5	11	11	11	8	8,33	9,26	7,81	8,47
6	14	14	14	8	9,96	8,10	8,84	7,04
7	6	6	6	8	7,24	6,13	6,08	5,25
8	4	4	4	19	4,26	3,10	5,39	12,50
9	12	12	12	8	10,84	9,13	8,15	5,56
10	7	7	7	8	4,82	7,26	6,42	7,91
11	5	5	5	8	5,68	4,74	5,73	6,89

(Quelle: **anscombe**)

## 1. Einführung

## 2. Deskriptive Statistik

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

## 3. W-Theorie

## 4. Induktive Statistik

### Quellen

### Tabellen



- ▶ In folgender Tabelle: Jeweils Ergebnisse der linearen Regressionsanalyse
- ▶ dabei:  $x_k$  unabhängige Variable und  $y_k$  abhängige Variable
- ▶ Modell jeweils:  $y_k = a_k + b_k x_k$

$k$	$\hat{a}_k$	$\hat{b}_k$	$R_k^2$
1	3,0001	0,5001	0,6665
2	3,0010	0,5000	0,6662
3	3,0025	0,4997	0,6663
4	3,0017	0,4999	0,6667

## 1. Einführung

## 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression





## 3. W-Theorie

## 4. Induktive Statistik

Quellen

Tabellen

# Plot der Anscombe-Daten



## 1. Einführung

## 2. Deskriptive Statistik

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

## 3. W-Theorie

## 4. Induktive Statistik


Quellen

Tabellen

```
meineRegression = lm(AlterM ~ AlterV)  
meineRegression
```

```
plot(AlterV, AlterM,  
     xlab="Alter des Vaters",  
     ylab="Alter der Mutter")  
abline(meineRegression)
```

```
##  
## Call:  
## lm(formula = AlterM ~ AlterV)  
##  
## Coefficients:  
## (Intercept)      AlterV  
##      16.7247      0.6447
```



## 1. Einführung

## 2. Deskriptive Statistik

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

## 3. W-Theorie

## 4. Induktive Statistik

Quellen

Tabellen



- ▶ Oft Kritisch: Einzelne Punkte, die Modell stark beeinflussen
- ▶ Idee: Was würde sich ändern, wenn solche Punkte weggelassen würden?
- ▶ **Cook-Distanz**: Misst den Effekt eines gelöschten Objekts
- ▶ Formel für ein lineares Modell mit einem unabh. Merkmal:

$$D_i = \frac{\sum_{j=1}^n (\hat{y}_j - \hat{y}_{j(\text{ohne } i)})^2}{\text{MSE}}$$

- ▶ Dabei bedeutet:
  - $\hat{y}_j$ : Prognosewert des kompletten Modells für das j-te Objekt
  - $\hat{y}_{j(\text{ohne } i)}$ : Prognosewert des Modells ohne Objekt i für das j-te Objekt
  - $\text{MSE} = \frac{1}{n} \cdot \sum (\hat{y}_i - y_i)^2$ : Normierender Term (Schätzwert für Fehlerstreuung)

## 1. Einführung

## 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

## 3. W-Theorie

## 4. Induktive Statistik

Quellen

Tabellen

## ► Anscombe-Daten: Regressionsmodell Nr. 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



- ▶ Anscombe-Daten: Regressionsmodell Nr. 3
- ▶ Darstellung der Cook-Distanz neben Punkten
- ▶ Faustformel: Werte über 1 sollten genau untersucht werden



## 1. Einführung

## 2. Deskriptive Statistik


Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale  
Korrelation  
Preisindizes  
Lineare Regression

## 3. W-Theorie

## 4. Induktive Statistik

Quellen

Tabellen



- ▶ Oft aufschlussreich: Verteilung der **Residuen**  $e_i$
- ▶ Verbreitet: Graphische Darstellungen der Residuen
- ▶ Z.B.:  $e_i$  über  $\hat{y}_i$



## 1. Einführung

## 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale  
Korrelation  
Preisindizes





Lineare Regression

## 3. W-Theorie

## 4. Induktive Statistik

Quellen



Tabellen





## Wichtige Eigenschaften der Residuenverteilung

- ▶ Möglichst **keine systematischen Muster**
- ▶ Keine Änderung der Varianz in Abhängigkeit von  $\hat{y}_i$  (**Homoskedastizität**)
- ▶ Nötig für inferentielle Analysen: Näherungsweise **Normalverteilung** der Residuen (q-q-plots)



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale  
Korrelation  
Preisindizes

### Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen



## Exkurs: Kausalität vs. Korrelation

- ▶ Meist wichtig für sinnvolle Regressionsanalysen:
- ▶ **Kausale Verbindung** zwischen unabhängigem und abhängigem Merkmal
- ▶ Sonst bei Änderung der unabhängigen Variablen keine sinnvollen Prognosen möglich
- ▶ Oft: **Latente Variablen** im Hintergrund

### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression


### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

- 1 Statistik: Einführung
- 2 Deskriptive Statistik
- 3 Wahrscheinlichkeitstheorie
- 4 Induktive Statistik



- 3 Wahrscheinlichkeitstheorie
  - Kombinatorik
  - Zufall und Wahrscheinlichkeit
  - Zufallsvariablen und Verteilungen
  - Verteilungsparameter



allgemein :

$$\binom{n+k-1}{k}$$

mit Wiederholung  
dieser Reihenfolge

---



2-mal Würfeln, das heißt Auswahl von  $k = 2$  aus  $n = 6$  Zahlen.



(1,1)	(1,2)	(1,3)	(1,4)	(1,5)	(1,6)
(2,1)	(2,2)	(2,3)	(2,4)	(2,5)	(2,6)
(3,1)	(3,2)	(3,3)	(3,4)	(3,5)	(3,6)
(4,1)	(4,2)	(4,3)	(4,4)	(4,5)	(4,6)
(5,1)	(5,2)	(5,3)	(5,4)	(5,5)	(5,6)
(6,1)	(6,2)	(6,3)	(6,4)	(6,5)	(6,6)

- ▶ mit WH, mit RF: alle Möglichkeiten,  $6^2 = 36$
- ▶ ohne WH, mit RF: Diagonale entfällt,  $36 - 6 = 30 = 6 \cdot 5 = \frac{6!}{(6-2)!}$

- ▶ ohne WH, ohne RF: Hälfte des letzten Ergebnisses:  $\frac{30}{2} = 15 = \frac{6!}{4!2!} = \binom{6}{2}$
- ▶ mit WH, ohne RF: Letztes Ergebnis plus Diagonale,  $15 + 6 = 21 = \binom{7}{2}$

---

## Auswahl von $k$ aus $n$ Dingen

---

	mit Wiederholung	ohne Wiederholung
mit Reihenfolge	$n^k$	$\frac{n!}{(n-k)!}$
ohne Reihenfolge	$\binom{n+k-1}{k}$	$\binom{n}{k}$

---



### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

#### Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und Verteilungen

Verteilungsparameter

### 4. Induktive Statistik

#### Quellen

#### Tabellen



- ▶ **Zufallsvorgang:** Geschehen mit ungewissem Ausgang, z.B. Münzwurf
- ▶ **Elementarereignis**  $\omega$ : Ein möglicher Ausgang, z.B. „Kopf“  
Elementarereignisse schließen sich gegenseitig aus („Kopf“ oder „Zahl“)!
- ▶ **Ergebnismenge**  $\Omega$ : Menge aller  $\omega$
- ▶ **Beispiel:** Werfen zweier Würfel:

$$\Omega : \left\{ \begin{array}{cccc} (1,1) & (1,2) & \cdots & (1,6) \\ (2,1) & (2,2) & \cdots & (2,6) \\ \vdots & \vdots & \ddots & \vdots \\ (6,1) & (6,2) & \cdots & (6,6) \end{array} \right\}$$

$$\Rightarrow \Omega = \{(x_1, x_2) : x_1, x_2 \in \{1, \dots, 6\}\}$$

## 1. Einführung

## 2. Deskriptive Statistik

## 3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und  
Verteilungen

Verteilungsparameter

## 4. Induktive Statistik

Quellen

Tabellen



$$\Omega = \{(x_1, x_2) : x_i \in \{1, \dots, 6\}\}$$

$$\omega = (1, 3) \quad A = \{(1, 3)\}$$

$$\omega \in \Omega \quad A \subset \Omega$$

► **Ereignis** A: Folgeerscheinung eines Elementarereignisses

► **Formal:**

$$A \subset \Omega$$

► Ereignisse schließen sich nicht gegenseitig aus!

► **Beispiel:** Werfen zweier Würfel:

Ereignis	verbal	formal
A	Augensumme = 4	$\{(1,3), (2,2), (3,1)\}$
B	Erste Zahl = 2	$\{(2,1), (2,2), \dots, (2,6)\}$

► **Wahrscheinlichkeit**  $P(A)$ : Chance für das Eintreten von A

► **Laplace-Wahrscheinlichkeit:**

$$P(A) = \frac{|A|}{|\Omega|} = \frac{\text{Anzahl der für A günstigen Fälle}}{\text{Anzahl aller möglichen Fälle}}$$

funktioniert  
falls alle  $\omega$  die gleiche „Chance“ haben

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und  
Verteilungen

Verteilungsparameter

4. Induktive Statistik

Quellen

Tabellen



► **Beispiel:** Werfen zweier Würfel:

$$\text{Augensumme} = 4 : A = \{(1,3), (2,2), (3,1)\}$$

$$|\Omega| = 36, |A| = 3 \Rightarrow P(A) = \frac{3}{36} = \frac{1}{12} = 0,083$$

- **Urnenmodell:** Ziehe  $n$  Objekte aus einer Menge mit  $N$  Objekten  
Anzahl Möglichkeiten:

mit Zurücklegen:  $N^n$

ohne Zurücklegen:  $N \cdot (N - 1) \cdots (N - (n - 1)) = \frac{N!}{(N-n)!}$

► **Beispiel:**

Wie groß ist die Wahrscheinlichkeit, aus einem gut gemischten 32-er Kartenblatt bei viermaligem Ziehen vier Asse zu bekommen?

- a) Ziehen mit Zurücklegen,  
b) Ziehen ohne Zurücklegen

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und  
Verteilungen

Verteilungsparameter

4. Induktive Statistik

Quellen

Tabellen




► Wichtige Rechenregeln:

leere Menge

1.  $P(A) \leq 1$

2.  $P(\emptyset) = 0$

A ist Teilmenge von B



3.  $A \subset B \Rightarrow P(A) \leq P(B)$



4.  $P(\bar{A}) = 1 - P(A)$

5.  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$

$\bar{A} = \Omega \setminus A$   
ohne

► Beispiel:

$$P(\text{„Augenzahl} \leq 5\text{“}) = 1 - P(\text{„Augenzahl} = 6\text{“}) = 1 - \frac{1}{6} = \frac{5}{6}$$



$$\begin{aligned} &P(A \cup B \cup C) \\ &= P(A) + P(B) + P(C) \\ &\quad - P(A \cap B) - P(A \cap C) - P(B \cap C) \\ &\quad + P(A \cap B \cap C) \end{aligned}$$


- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
  - Kombinatorik
  - Zufall und Wahrscheinlichkeit
  - Zufallsvariablen und Verteilungen
  - Verteilungsparameter
- 4. Induktive Statistik
  - Quellen
  - Tabellen

## Der Fall Sally Clark

- ▶ Sally Clarks Söhne Christopher und Harry sterben 1996 und 1997 beide kurz nach der Geburt an plötzlichem Kindstod.
- ▶ Kinderarzt: „Wahrscheinlich Mord, da 2 maliger plötzlicher Kindstod sehr unwahrscheinlich!“ (ohne konkrete Hinweise)
- ▶ Gerichtliche Untersuchung
- ▶ Hauptargument der Anklage gestützt durch Gerichtsgutachter Sir Roy Meadow (renommierter Facharzt für Kinderheilkunde): Wahrscheinlichkeit für plötzlichen Kindstod ist 1:8500, d.h. Wahrscheinlichkeit für 2 maliges Auftreten in einer Familie

$$p = \left(\frac{1}{8500}\right)^2 \approx 1 : 72\,000\,000$$

- ▶ Urteil: Doppelmord; Strafe: 2 mal lebenslang; Inhaftierung von Sally Clark 1999



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
  - Kombinatorik
  - Zufall und Wahrscheinlichkeit
  - Zufallsvariablen und Verteilungen
  - Verteilungsparameter
- 4. Induktive Statistik
- Quellen
- Tabellen

## Der Fall Sally Clark

- ▶ Problem: Es gibt sehr viele Familien mit 2 Kindern
- ▶ Europa: ca. 80 Mio Familien mit Kindern, davon ca. 50% mit mindestens zwei Kindern, also ca. 40 Mio.
- ▶ Wahrscheinlichkeit, dass in einer solchen Familie kein zweifacher plötzlicher Kindstod auftritt:  $1 - \left(\frac{1}{8500}\right)^2$   
Annahmen:
  - Jede dieser Familien hat genau 2 Kinder; in Wirklichkeit: ca. 20% dieser Familien haben mindestens 3 Kinder
  - Zweiter plötzlicher Kindstod unabhängig von erstem (nicht untersucht)
- ▶ Wahrscheinlichkeit, dass in 40 Mio. Familien mindestens ein zweifacher plötzlicher Kindstod auftritt:

$$1 - \left(1 - \left(\frac{1}{8500}\right)^2\right)^{40\,000\,000} \approx 42,5\%$$



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
  - Kombinatorik
  - Zufall und Wahrscheinlichkeit
  - Zufallsvariablen und Verteilungen
  - Verteilungsparameter
- 4. Induktive Statistik
- Quellen
- Tabellen

## Der Fall Sally Clark



- ▶ Problem: Es gibt sehr viele Familien mit 2 Kindern
- ▶ Europa: ca. 80 Mio Familien mit Kindern, davon ca. 50% mit mindestens zwei Kindern, also ca. 40 Mio.
- ▶ Wahrscheinlichkeit, dass in einer solchen Familie kein zweifacher plötzlicher Kindstod auftritt:  $1 - \left(\frac{1}{8500}\right)^2$   
Annahmen:
  - Jede dieser Familien hat genau 2 Kinder; in Wirklichkeit: ca. 20% dieser Familien haben mindestens 3 Kinder
  - Zweiter plötzlicher Kindstod unabhängig von erstem (nicht untersucht)
- ▶ Wahrscheinlichkeit, dass in 40 Mio. Familien mindestens ein zweifacher plötzlicher Kindstod auftritt:

$$1 - \left(1 - \left(\frac{1}{8500}\right)^2\right)^{40\,000\,000} \approx 42,5\%$$

- ▶ 2001: Royal Statistical Society interveniert
- ▶ 2003: Sally Clark wird nach Revision freigesprochen
- ▶ 2007 findet man sie tot in ihrer Wohnung auf - gestorben an einer akuten Alkoholvergiftung. Sie habe sich, so ihre Familie, von dem Justizirrtum nie erholt.



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
  - Kombinatorik
  - Zufall und Wahrscheinlichkeit
  - Zufallsvariablen und Verteilungen
  - Verteilungsparameter
- 4. Induktive Statistik
- Quellen
- Tabellen




- ▶ Wahrscheinlichkeit von  $A$  hängt von anderem Ereignis  $B$  ab. (B kann zeitlich vor  $A$  liegen, muss aber nicht!)
- ▶ **Beispiel:** Wahrscheinlichkeit für Statistiknote hängt von Mathenote ab.

- ▶ Formal:

Wahrsch. von Ereignis  $A$   
unter Bedingung, dass  
Ereignis  $B$  eintritt

$$P(A | B) = \frac{P(A \cap B)}{P(B)}$$

- ▶ Im Venndiagramm:



## 1. Einführung

## 2. Deskriptive Statistik

## 3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und  
Verteilungen

Verteilungsparameter

## 4. Induktive Statistik


Quellen

Tabellen


Bedingte Wahrscheinlichkeit:  $P(A) = 0.5$ ,  $P(B) = \frac{1}{3}$



$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$
$$= 0$$



$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$
$$= \frac{\frac{2}{16}}{\frac{4}{16}} = \frac{1}{2}$$



$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$
$$= \frac{P(B)}{P(B)} = 1$$