

# Statistik für


## Informatik im Wintersemester 2016/2017

Was?	Wer?	Wann?	Wo?	ab wann?
Vorlesung	Anett Wins	Di., 14:00 - 17:00 Uhr	W3.02	Di., 04. Oktober 2016
Übung 1 Statistik	Eugen Ivanov	Do., 14:00 - 15:30 Uhr	J3.19	Do., 13. Oktober 2016
Übung 2 Statistik	Eugen Ivanov	Do., 15:30 - 17:00 Uhr	J3.19	Do., 13. Oktober 2016

<u>Vorlesung Statistik WS 2016/17 Sessionlist</u>			<u>Übungen</u>	
Session	Datum	Thema	Übung	Datum
1	Di., 04. Oktober 2016	Einführung, R-Installation, R-Studio, Skalen		
2	Di., 11. Oktober 2016	univariate deskriptive Statistik, Plots	1	Do., 13. Oktober 2016
3	Di., 18. Oktober 2016	Streuung, Konzentrationsmaße	2	Do., 20. Oktober 2016
4	Di., 25. Oktober 2016	Kontingenztabellen, Mosaikplots, Korrelation	3	Do., 27. Oktober 2016
	Di., 01. November 2016	Feiertag	4	Do., 03. November 2016
5	Di., 08. November 2016	Preisindizes, lineare Regression	5	Do., 10. November 2016
6	Di., 15. November 2016	Kominatorik, Wahrscheinlichkeiten	6	Do., 17. November 2016
7	Di., 22. November 2016	Wahrscheinlichkeit, diskrete Zufallsvariablen	7	Do., 24. November 2016
8	Di., 29. November 2016	Binomial-, Hypergeom.-, Poisson-Verteilung	8	Do., 01. Dezember 2016
9	Di., 06. Dezember 2016	stetige Zufallsvariablen, Gleichverteilung	9	Do., 08. Dezember 2016
10	Di., 13. Dezember 2016	Normalverteilung, Verteilungsparameter	10	Do., 15. Dezember 2016
11	Di., 20. Dezember 2016	Schätzfunktionen, Punktschätzer	11	Do., 22. Dezember 2016
	Di., 27. Dezember 2016	Weihnachtsferien		Do., 29. Dezember 2016
	Di., 03. Januar 2017	Weihnachtsferien		Do., 05. Januar 2017
12	Di., 10. Januar 2017	Konfidenzintervalle	12	Do., 12. Januar 2017
13	Di., 17. Januar 2017	Tests	13	Do., 19. Januar 2017

Dipl. Stat. Anett Wins  
nach dem Skript von

Prof. Dr. Stefan Etschberger  
Hochschule Augsburg



### 1 Statistik: Einführung

- Berühmte Leute zur Statistik
- Wie lügt man mit Statistik?
- Gute und schlechte Grafiken
- Begriff Statistik
- Grundbegriffe der Datenerhebung
- R und RStudio

### 2 Deskriptive Statistik

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

### 3 Wahrscheinlichkeitstheorie

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

### 4 Induktive Statistik

- Grundlagen
- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests

1. Einführung

2. Deskriptive Statistik

3. W-Theorie



4. Induktive Statistik

Quellen

Tabellen

### Kursmaterial:

- ▶ Aufgabensatz (beinhaltet Aufgaben zu R)
- ▶ Folienskript
- ▶ Anmerkungen zur Vorlesung (im Anschluss an die Veranstaltung)
- ▶ Beispieldaten



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik

Quellen

Tabellen

### Literatur:

-  Bamberg, Günter, Franz Baur und Michael Krapp (2011). **Statistik**. 16. Aufl. München: Oldenbourg Verlag. ISBN: 3486702580.
-  Dalgaard, Peter (2002). **Introductory Statistics with R**. New York: Springer.
-  Fahrmeir, Ludwig, Rita Künstler, Iris Pigeot und Gerhard Tutz (2009). **Statistik: Der Weg zur Datenanalyse**. 7. Aufl. Berlin, Heidelberg: Springer. ISBN: 3642019382.

## Klausur:

- ▶ **Klausur** am Ende des Semesters
- ▶ Bearbeitungszeit: **90 Minuten**
- ▶ Erreichbare Punktzahl: 90
- ▶ R ist prüfungsrelevant: Siehe Anmerkungen in Übungsaufgaben!
- ▶ Hilfsmittel:
  - **Schreibzeug**,
  - **Taschenrechner**, der nicht 70! berechnen kann,
  - **ein** Blatt (DIN-A4, vorne und hinten beschrieben) mit handgeschriebenen Notizen (keine Kopien oder Ausdrücke),
- ▶ "gemeinsame" Klausur mit der Wiederholungsklausur Statistik für Betriebswirtschaft, Internationales Management, Wirtschaftsinformatik und Informatik vom Sommersemester 2016 (Prof. Dr. Stefan Etschberger)



# Statistik: Table of Contents


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



- 1 Statistik: Einführung
  - Berühmte Leute zur Statistik
  - Wie lügt man mit Statistik?
  - Gute und schlechte Grafiken
  - Begriff Statistik
  - Grundbegriffe der Datenerhebung
  - R und RStudio

► **Leonard Henry Courtney (1832-1918):**

„ *There are three kinds of lies: lies, damned lies and statistics.* “



► **Winston Churchill (1874-1965) angeblich:**

„ *Ich glaube nur den Statistiken, die ich selbst gefälscht habe.* “



► **Andrew Lang (1844-1912):**

„ *Wir benutzen die Statistik wie ein Betrunkener einen Laternenpfahl: Vor allem zur Stütze unseres Standpunktes und weniger zum Beleuchten eines Sachverhalts.* “



DRAWN BY BURNE MURDOCK.

ENGRAVED BY J. F. JUNGLING.



## 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

## 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

## Morgens in Zeitung: Mehr Statistiken als Goethe und Schiller im ganzen Leben gesehen haben:

- ▶ Arbeitslosenzahlen wachsen
- ▶ Vogelgrippe breitet sich aus
- ▶ 78,643% der Deutschen unzufrieden mit Löw
- ▶ Bundesbürger verzehrt 5,8 Liter Speiseeis pro Jahr
- ▶ Musiker leben länger als andere Leute
- ▶ Tennisspieler B hat noch nie gegen einen brilletragenden Linkshänder verloren, der jünger ist als er
- ▶ in New York schläft man am sichersten im Central Park

## Viele dieser Statistiken: Falsch, bewußt manipuliert oder unpassend ausgesucht.

### Fehlerquellen:

- ▶ Zahlenmanipulation
- ▶ irreführende Darstellung der Zahlen
- ▶ ungenügendes Wissen



### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

### 1. Frage:

„Finden Sie, dass in einem Betrieb alle Arbeiter in der Gewerkschaft sein sollten?“

#### Resultat:

- ▶ Dafür: 44%
- ▶ Dagegen: 20%
- ▶ Unentschieden: 36%

### 2. Frage:

„Finden Sie, dass in einem Betrieb alle Arbeiter in der Gewerkschaft sein sollten oder muss man es jedem einzelnen überlassen, ob er in der Gewerkschaft sein will oder nicht?“

#### Resultat:

- ▶ Dafür: 24%
- ▶ Dagegen: 70%
- ▶ Unentschieden: 6%



### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

## Laut einem „Bericht zur Bekämpfung des Analphabetismus in Deutschland“:

- ▶ Heute gibt es in Deutschland ca. 7 Millionen Analphabeten
- ▶ Zu Kaiser Wilhelms Zeiten gab es weniger als 10 000

### BILDUNG

#### 7,5 Millionen Deutsche sind Analphabeten

Ein Siebtel der erwerbsfähigen Bevölkerung kann laut einer Studie kaum lesen und schreiben – doppelt so viel wie bisher gedacht. Bildungsministerin Schavan will reagieren [weiter...]



### ANALPHABETISMUS

#### Ein Land verlernt das Lesen

Studenten verstehen abstrakte Texte nicht mehr, ein Schulbuchverlag kürzt Klassiker, Banker besuchen Lesekurse: Viele Deutsche haben keine Lust mehr zu lesen. [weiter...]

### ANALPHABETISMUS

#### Buchstäblich resigniert

Mehr als sieben Millionen Deutsche können kaum lesen und schreiben. Erst jetzt hat die Politik das Problem erkannt. Aber es gibt zu wenig Geld für Kurse. Von M. Spiewak [weiter...]

Quelle: Zeit.de



## 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

## 2. Deskriptive Statistik

## 3. W-Theorie

## 4. Induktive Statistik

Quellen

Tabellen

## Definition

### Zu Kaiser Wilhelms Zeiten:

„Analphabet ist, wer seinen Namen nicht schreiben kann.“

### Definition heute:

„Ein Analphabet ist eine Person, die sich nicht beteiligen kann an all den zielgerichteten Aktivitäten ihrer Gruppe und ihrer Gemeinschaft, bei denen Lesen, Schreiben und Rechnen erforderlich ist und an der weiteren Nutzung dieser Kulturtechniken für ihre weitere Entwicklung und die der Gesellschaft“.



## Aussage des Vertriebsleiters:

„Unser Umsatz stieg vor einem Jahr um 1%. Dieses Jahr stieg das **Umsatzwachstum um 50%!**“

## Im Klartext:

- ▶ Basisjahr: Umsatz 100
- ▶ Dann: Wachstum auf 101
- ▶ Dieses Jahr: Wachstum des Wachstums um 50% bedeutet 1,5% Wachstum. Also Umsatz dann 102,5049

### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen



Tabellen



## Seit 1983 stabile Gebühren

Sie, lieber Postkunde, sehen es selbst anhand unserer Zeichnung: Seit 1983 sind die Gebühren für Briefe, Päckchen und Pakete nicht mehr gestiegen. Und Sie bleiben auch 1986 stabil.

Das heißt: eine Legislaturperiode ohne Portoerhöhung. Und das seit 20 Jahren zum erstenmal wieder!



— +0% —

Diese erfreuliche Tatsache ist der konsequenten Stabilitäts-politik der Post seit 1983 zu verdanken. **1983-1986 +0%**

Quelle Kramer (2011)

### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

## Grafik aussagekräftig?



Quelle: Bach u. a. (2006)



### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik


### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

11 zu 15



### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen



### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der  
Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie


### 4. Induktive Statistik

Quellen

Tabellen

- ▶ Ein Einzelhändler bezieht ein Produkt zu 100 € und verkauft es für 200 €. Hat er eine Gewinnspanne von 50% oder 100%?
- ▶ Bahn: 9 Tote pro 10 Mio Passagieren je Kilometer  
Flugzeug: 3 Tote pro 10 Mio Passagieren je Kilometer  
Bahn: 7 pro 10 Mio Passagiere je Stunde  
Flugzeug: 24 pro 10 Mio Passagiere je Stunde
- ▶ Nur 40 % aller durch Autounfälle Gestorbenen hatten keinen Sicherheitsgurt angelegt  
Also: Keinen Gurt anlegen ist sicherer
- ▶ Die Hälfte der Todesfälle ereignen sich in Krankenhäusern  
Also: Krankenhäuser sind lebenssgefährlich
- ▶ Zwei Drittel aller alkoholabhängigen Personen sind verheiratet  
Also: die Ehe führt zum Alkohol

## Fernsehumfragen



- ▶ Kostenpflichtige Telefonabstimmung nach regierungsfreundlichem Bericht im Fernsehen
- ▶ In den meisten Umfragen erreichte Bush zu diesem Zeitpunkt nur 30 % Zustimmung



### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

## Challenger-Katastrophe



Am 28. Januar 1986, 73 Sekunden nach dem Start der Mission STS-51-L, brach die Raumfähre in etwa 15 Kilometer Höhe auseinander. Dabei starben alle sieben Astronauten. Es war der bis dahin schwerste Unfall in der Raumfahrtgeschichte der USA.



### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen



## 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

## 2. Deskriptive Statistik

## 3. W-Theorie


## 4. Induktive Statistik

Quellen

Tabellen

- ▶ Grund für Explosion: 2 Gummidichtungsringe waren undicht
- ▶ Die Temperatur der Dichtungsringe: Unter 20° F (ca. -6,7° C).
- ▶ Probleme mit Dichtungsringen bei Start der vorigen Fähre: Umgebungstemperatur 53° F (ca. 11,7° C).
- ▶ Frage: Ist der Dichtungsfehler durch die Umgebungstemperatur zu prognostizieren?

## O-Ring Failure Data





### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik


### 3. W-Theorie


### 4. Induktive Statistik

Quellen

Tabellen

- ▶ Fehler in Analyse: Starts ohne Fehler wurden nicht berücksichtigt
- ▶ Korrekte Modellierung mittels **logistischer Regression** liefert:





### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik


### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

## Aussage?



### 1. Einführung

Berühmte Leute zur Statistik  
Wie lügt man mit Statistik?  
Gute und schlechte Grafiken  
Begriff Statistik  
Grundbegriffe der Datenerhebung  
R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie


### 4. Induktive Statistik

Quellen


Tabellen



## Minards Grafik von 1869 über Napoleons Rußlandfeldzug



Quelle: Wikimedia Commons, <http://goo.gl/T7ZNme>, Stand November 2014



### 1. Einführung

Berühmte Leute zur Statistik  
Wie lügt man mit Statistik?  
Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen



### Beispiel

12 Beschäftigte werden nach der Entfernung zum Arbeitsplatz (in km) befragt.

Antworten: 4, 11, 1, 3, 5, 4, 20, 4, 6, 16, 10, 6

► deskriptiv:

- Durchschnittliche Entfernung: 7,5
- Klassenbildung:

Klasse	[0;5)	[5;15)	[15;30)
Häufigkeit	5	5	2

► induktiv:

- Schätze die mittlere Entfernung **aller** Beschäftigten.
- Prüfe, ob die mittlere Entfernung geringer als 10 km ist.

### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen



### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der  
Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

- ▶ **Merkmalsträger**: Untersuchte statistische Einheit
- ▶ **Merkmal**: Interessierende Eigenschaft des Merkmalsträgers
- ▶ (Merkmals-) **Ausprägung**: Konkret beobachteter Wert des Merkmals
- ▶ **Grundgesamtheit**: Menge aller relevanten Merkmalsträger
- ▶ **Typen** von Merkmalen:
  - a) qualitativ – quantitativ
    - qualitativ: z.B. Geschlecht
    - quantitativ: z.B. Schuhgröße
    - Qualitative Merkmale sind quantifizierbar (z.B.: weiblich 1, männlich 0)
  - b) diskret – stetig
    - **diskret**: Abzählbar viele unterschiedliche Ausprägungen
    - **stetig**: Alle Zwischenwerte realisierbar

### Nominalskala:

- ▶ Zahlen haben nur Bezeichnungsfunktion
- ▶ z.B. Artikelnummern

### Ordinalskala:

- ▶ zusätzlich Rangbildung möglich
- ▶ z.B. Schulnoten
- ▶ Differenzen sind aber **nicht** interpretierbar!  
    ⇒ Addition usw. ist unzulässig.

### Kardinalskala:

- ▶ zusätzlich Differenzbildung sinnvoll
- ▶ z.B. Gewinn
- ▶ Noch feinere Unterscheidung in: **Absolutskala**, **Verhältnisskala**, **Intervallskala**



#### 1. Einführung

Berühmte Leute zur Statistik  
Wie lügt man mit Statistik?  
Gute und schlechte Grafiken  
Begriff Statistik

Grundbegriffe der  
Datenerhebung

R und RStudio

#### 2. Deskriptive Statistik

#### 3. W-Theorie

#### 4. Induktive Statistik

Quellen

Tabellen

Ziel der Skalierung: Gegebene Information angemessen abbilden, möglichst ohne Über- bzw. Unterschätzungen

Es gilt:

- ▶ Grundsätzlich können alle Merkmale nominal skaliert werden.
- ▶ Grundsätzlich kann jedes metrische Merkmal ordinal skaliert werden.

Das nennt man **Skalendegression**. Dabei: **Informationsverlust**

Aber:

- ▶ Nominale Merkmale dürfen **nicht** ordinal- oder metrisch skaliert werden.
- ▶ Ordinale Merkmale dürfen **nicht** metrisch skaliert werden.

Das nennt man **Skalenprogression**. Dabei: Interpretation von **mehr Informationen** in die Merkmale, als inhaltlich vertretbar.  
(Gefahr der **Fehlinterpretation**)



## 1. Einführung

Berühmte Leute zur Statistik  
Wie lügt man mit Statistik?  
Gute und schlechte Grafiken  
Begriff Statistik

Grundbegriffe der  
Datenerhebung

R und RStudio

## 2. Deskriptive Statistik

## 3. W-Theorie

## 4. Induktive Statistik

Quellen


Tabellen

# Was ist R und warum soll man es benutzen?

- ▶ R ist ein **freies** Softwarepaket zu Statistik und Datenanalyse
- ▶ R ist sehr mächtig und **weit verbreitet** in Wissenschaft und Industrie (sogar von mehr Leuten benutzt als z.B. SPSS)




- The average data miner reports using 4 software tools.
- R is used by the most data miners (47%).
- STATISTICA is the primary data mining tool chosen most often (17%).



source: <http://goo.gl/axhGhh>

graphics source: <http://goo.gl/W70kms>



## Statistik



### 1. Einführung

- Berühmte Leute zur Statistik
- Wie lügt man mit Statistik?
- Gute und schlechte Grafiken
- Begriff Statistik
- Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

# Was ist R und warum soll man es benutzen?

- ▶ R ist ein **freies** Softwarepaket zu Statistik und Datenanalyse
- ▶ R ist sehr mächtig und **weit verbreitet** in Wissenschaft und Industrie (sogar von mehr Leuten benutzt als z.B. SPSS)
- ▶ Ursprung von R: **1993** an der Universität Auckland von Ross Ihaka and Robert Gentleman entwickelt
- ▶ Seitdem: Viele Leute haben R verbessert mit **tausenden von Paketen** für viele Anwendungen



## Statistik



### 1. Einführung

Berühmte Leute zur Statistik  
Wie lügt man mit Statistik?  
Gute und schlechte Grafiken  
Begriff Statistik  
Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

# Was ist R und warum soll man es benutzen?

- ▶ R ist ein **freies** Softwarepaket zu Statistik und Datenanalyse
- ▶ R ist sehr mächtig und **weit verbreitet** in Wissenschaft und Industrie (sogar von mehr Leuten benutzt als z.B. SPSS)
- ▶ Ursprung von R: **1993** an der Universität Auckland von Ross Ihaka and Robert Gentleman entwickelt
- ▶ Seitdem: Viele Leute haben R verbessert mit **tausenden von Paketen** für viele Anwendungen
- ▶ Nachteil (auf den ersten Blick): Kein point und click tool

```
> summary(diamonds$price)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
   326    950    2401   3933   5324   18820
> ave_size <- round(mean(diamonds$carat), 4)
> clarity <- levels(diamonds$clarity)
> p <- qplot(carat, price,
+           data=diamonds, color=clarity,
+           xlab="Carat", ylab="Price",
+           main="Diamond Pricing")
> format.plot(p, size=24)
> |
```

## Statistik



### 1. Einführung

Berühmte Leute zur Statistik  
Wie lügt man mit Statistik?  
Gute und schlechte Grafiken  
Begriff Statistik  
Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

# Was ist R und warum soll man es benutzen?

- ▶ R ist ein **freies** Softwarepaket zu Statistik und Datenanalyse
- ▶ R ist sehr mächtig und **weit verbreitet** in Wissenschaft und Industrie (sogar von mehr Leuten benutzt als z.B. SPSS)
- ▶ Ursprung von R: **1993** an der Universität Auckland von Ross Ihaka and Robert Gentleman entwickelt
- ▶ Seitdem: Viele Leute haben R verbessert mit **tausenden von Paketen** für viele Anwendungen
- ▶ Nachteil (auf den ersten Blick): Kein point und click tool
- ▶ Großer Vorteil (auf den zweiten Blick): Kein point und click tool

```
> summary(diamonds$price)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
   326    950    2401   3933   5324  18820
> aveSize <- round(mean(diamonds$carat), 4)
> clarity <- levels(diamonds$clarity)
> p <- qplot(carat, price,
+           data=diamonds, color=clarity,
+           xlab="Carat", ylab="Price",
+           main="Diamond Pricing")
>
> format.plot(p, size=24)
> |
```

**Download: [R-project.org](http://www.r-project.org)**

## Statistik



### 1. Einführung

Berühmte Leute zur Statistik  
Wie lügt man mit Statistik?  
Gute und schlechte Grafiken  
Begriff Statistik  
Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen


Tabellen

# Was ist RStudio?

- ▶ RStudio ist ein **Integrated Development Environment (IDE)** um R leichter benutzen zu können.
- ▶ Gibt's für OSX, Linux und Windows
- ▶ Ist auch frei
- ▶ Trotzdem: Sie müssen Kommandos schreiben
- ▶ Aber: RStudio unterstützt Sie dabei
- ▶ **Download:** [RStudio.com](http://RStudio.com)



Free & Open-Source IDE for R



## Statistik



### 1. Einführung

- Berühmte Leute zur Statistik
- Wie lügt man mit Statistik?
- Gute und schlechte Grafiken
- Begriff Statistik
- Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen



## RStudio Kennenlernen

- ▶ Code
- ▶ Console
- ▶ Workspace
- ▶ History
- ▶ Files
- ▶ Plots
- ▶ Packages
- ▶ Help
- ▶ Auto-Completion
- ▶ Data Import

The screenshot displays the RStudio environment with the following components:

- Source Editor:** Contains R code for loading the 'ggplot2' library, loading a data file, summarizing the 'diamonds' dataset, and creating a faceted scatter plot of Price vs. Carat, colored by Clarity.
- Console:** Shows the execution of the code, including summary statistics for 'diamonds' and 'diamonds\$price'.
- Workspace:** Lists the loaded data object 'diamonds' (53940 observations) and the 'ggplot2' package.
- Plots:** A faceted scatter plot titled 'Diamond Pricing' showing Price on the y-axis (0 to 15000) and Carat on the x-axis (0.0 to 3.5). Points are colored by Clarity (I1, SI2, SI1, VS2, VS1, VVS2, VVS1, IF).

### 1. Einführung

- Berühmte Leute zur Statistik
- Wie lügt man mit Statistik?
- Gute und schlechte Grafiken
- Begriff Statistik
- Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

# Daten einlesen und Struktur anschauen

```
# Arbeitsverzeichnis setzen (alternativ über Menü)
setwd("C:/ste/work/vorlesungen/2015SS_HSA_Statistik")
```

```
# Daten einlesen aus einer csv-Datei (Excel)
MyData = read.csv2(file="../_genericFiles/Daten/Umfrage_HSA_2015_03.csv", header=TRUE)
```

```
# inspect structure of data
str(MyData)
```

```
## 'data.frame': 377 obs. of 17 variables:
## $ Jahrgang : int 2015 2015 2015 2015 2015 2015 2015 2015 2015 2015 2015 ...
## $ Alter : int 20 25 19 21 25 20 25 20 23 21 ...
## $ Groesse : int 174 157 163 185 178 170 165 175 180 161 ...
## $ Geschlecht : Factor w/ 2 levels "Frau","Mann": 1 1 1 2 2 1 1 2 2 1 ...
## $ AlterV : int 55 54 51 52 60 50 60 52 56 70 ...
## $ AlterM : int 53 61 49 50 63 55 60 49 50 55 ...
## $ GroesseV : int 187 185 178 183 170 183 185 175 175 180 ...
## $ GroesseM : int 169 160 168 165 160 160 170 169 170 165 ...
## $ Geschwister : int 3 1 1 4 2 2 4 1 1 2 ...
## $ Farbe : Factor w/ 6 levels "blau","gelb",...: 4 6 4 4 1 6 1 6 4 4 ...
## $ AusgKomm : num 240 119 270 40 550 ...
## $ AnzSchuhe : int 25 30 25 6 5 65 10 7 10 22 ...
## $ AusgSchuhe : int 450 300 100 100 80 250 150 400 150 300 ...
## $ Essgewohnheiten: Factor w/ 5 levels "carnivor","fruktarisch",...: 1 1 1 1 1 1 5 1 1 1 ...
## $ Raucher : Factor w/ 2 levels "ja","nein": NA 2 2 2 1 2 2 2 2 1 ...
## $ NoteMathe : num 2.3 3.3 1.7 2 4 4 3.3 2.7 3.7 3.3 ...
## $ MatheZufr : Ord.factor w/ 4 levels "unzufrieden"<...: 2 2 2 2 2 2 2 2 2 2 ...
```

## Statistik



### 1. Einführung

- Berühmte Leute zur Statistik
- Wie lügt man mit Statistik?
- Gute und schlechte Grafiken
- Begriff Statistik
- Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

# Erste Zeilen der Datentabelle

```
# Erste Zeilen in Datentabelle
```

```
head(MyData, 6)
```

```
##   Jahrgang Alter Groesse Geschlecht AlterV AlterM GroesseV GroesseM Geschwister Farbe AusgKomm
## 1    2015    20    174      Frau     55    53    187    169           3 schwarz   240.0
## 2    2015    25    157      Frau     54    61    185    160           1 weiss    119.4
## 3    2015    19    163      Frau     51    49    178    168           1 schwarz  270.0
## 4    2015    21    185      Mann     52    50    183    165           4 schwarz   40.0
## 5    2015    25    178      Mann     60    63    170    160           2 blau    550.0
## 6    2015    20    170      Frau     50    55    183    160           2 weiss   420.0
##   AnzSchuhe AusgSchuhe Essgewohnheiten Raucher NoteMathe MatheZufr
## 1         25        450      carnivor    <NA>      2.3 geht so
## 2         30        300      carnivor    nein      3.3 geht so
## 3         25        100      carnivor    nein      1.7 geht so
## 4          6        100      carnivor    nein      2.0 geht so
## 5          5         80      carnivor     ja      4.0 geht so
## 6         65       250      carnivor    nein      4.0 geht so
```

```
# lege MyData als den "Standard"-Datensatz fest
```

```
attach(MyData)
```

```
# Wie Viele Objekte gibt's im Datensatz?
```

```
nrow(MyData)
```

```
## [1] 377
```

```
# Wie Viele Merkmale?
```

```
ncol(MyData)
```

```
## [1] 17
```

## Statistik



### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der  
Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen



```
# Auswahl spezieller Objekte und Merkmale über [Zeile, Spalte]
```

```
MyData[1:3, 2:5]
```

```
##   Alter Groesse Geschlecht AlterV
## 1    20     174      Frau     55
## 2    25     157      Frau     54
## 3    19     163      Frau     51
```

```
# Auswahl von Objekten über logische Ausdrücke
```

```
Auswahl = (MyData$Geschlecht=="Mann" & MyData$Alter < 19)
```

```
# zeige die ersten Einträge
```

```
head(Auswahl, 30)
```

```
## [1] FALSE FALSE
## [17] FALSE FALSE FALSE FALSE FALSE FALSE TRUE FALSE FALSE FALSE FALSE FALSE FALSE
```

```
# Ausgabe der Auswahl: Alter, Alter des Vaters und der Mutter
```

```
MyData[Auswahl, # Objektauswahl
        c("Alter", "AlterM", "AlterV")] # Welche Merkmale?
```

```
##   Alter AlterM AlterV
## 23    18     44     48
## 268   18     46     52
```

### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der  
Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen



```
# Zeige die Männer, die mehr als 1000 Euro für Schuhe  
# und Mobilfunk zusammen ausgegeben haben  
MyData[MyData$Geschlecht=="Mann" & MyData$AusgSchuhe + MyData$AusgKomm > 1000,  
       c("Alter", "Geschwister", "Farbe", "AusgSchuhe", "AusgKomm")]
```

##	Alter	Geschwister	Farbe	AusgSchuhe	AusgKomm
## 19	20	0	weiss	300	924
## 23	18	1	silber	300	1000
## 33	25	1	schwarz	300	1000
## 42	24	1	schwarz	1000	600
## 81	25	2	silber	200	1900
## 106	21	1	schwarz	200	860
## 121	22	0	silber	300	1100
## 142	20	2	schwarz	290	1570
## 161	19	1	schwarz	600	800
## 168	21	2	blau	600	505
## 179	21	0	silber	300	825
## 211	23	1	schwarz	450	630
## 223	20	1	rot	400	815
## 227	20	1	schwarz	200	1250
## 249	20	1	blau	1000	350
## 256	25	0	schwarz	280	1200
## 272	24	1	schwarz	300	900
## 281	19	2	schwarz	500	720
## 315	21	1	weiss	200	1300
## 353	20	0	schwarz	400	950

### 1. Einführung

Berühmte Leute zur Statistik

Wie lügt man mit Statistik?

Gute und schlechte Grafiken

Begriff Statistik

Grundbegriffe der  
Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen



```
# Auswahl spezieller Objekte und Merkmale über [Zeile, Spalte]
MyData[1:3, 2:5]
```

```
##   Alter Groesse Geschlecht AlterV
## 1    20     174      Frau     55
## 2    25     157      Frau     54
## 3    19     163      Frau     51
```

```
# Auswahl von Objekten über logische Ausdrücke
Auswahl = (MyData$Geschlecht=="Mann" & MyData$Alter < 19)
# zeige die ersten Einträge
head(Auswahl, 30)
```

```
## [1] FALSE FALSE
## [17] FALSE FALSE FALSE FALSE FALSE FALSE TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE
```

```
# Ausgabe der Auswahl: Alter, Alter des Vaters und der Mutter
MyData[Auswahl, # Objektauswahl
        c("Alter", "AlterM", "AlterV")] # Welche Merkmale?
```

```
##   Alter AlterM AlterV
## 23    18     44     48
## 268   18     46     52
## 424   17     46     50
## 456   18     52     55
## 460   18     50     57
## 464   18     40     44
## 479   18     52     44
## 501   18     51     55
## 566   18     52     57
## 620   18     49     58
```

### 1. Einführung

Berühmte Leute zur Statistik  
Wie lügt man mit Statistik?  
Gute und schlechte Grafiken  
Begriff Statistik  
Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen



### 1. Einführung

Berühmte Leute zur Statistik  
Wie lügt man mit Statistik?  
Gute und schlechte Grafiken  
Begriff Statistik  
Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

```
# Zeige die Männer, die mehr als 1300 Euro für Schuhe  
# und Mobilfunk zusammen ausgegeben haben  
MyData.Auswahl = MyData[MyData$Geschlecht=="Mann" &  
  MyData$AusgSchuhe + MyData$AusgKomm > 1300,  
  c("Alter", "Geschwister", "Farbe",  
    "AusgSchuhe", "AusgKomm")]
```

```
# ohne NAs
```

```
MyData.Auswahl = na.exclude(MyData.Auswahl)
```

```
MyData.Auswahl
```

##	Alter	Geschwister	Farbe	AusgSchuhe	AusgKomm
## 42	24	1.0	schwarz	1000	600
## 81	25	2.0	silber	200	1900
## 121	22	0.0	silber	300	1100
## 142	20	2.0	schwarz	290	1570
## 161	19	1.0	schwarz	600	800
## 227	20	1.0	schwarz	200	1250
## 249	20	1.0	blau	1000	350
## 256	25	0.0	schwarz	280	1200
## 315	21	1.0	weiss	200	1300
## 353	20	0.0	schwarz	400	950
## 415	26	1.0	blau	600	1850
## 419	21	0.0	schwarz	200	1500
## 492	23	2.0	weiss	160	1800
## 493	26	2.0	schwarz	300	2000
## 494	20	2.0	schwarz	250	1500
## 535	20	2.0	weiss	2500	1500
## 548	26	2.0	schwarz	240	1200
## 562	24	1.0	schwarz	70	4668
## 573	21	1.0	schwarz	300	1200
## 581	19	2.0	silber	500	950
## 582	20	1.0	schwarz	500	1000
## 604	24	1.0	schwarz	150	1340
## 605	21	1.0	silber	600	800
## 615	25	4.5	schwarz	1200	600
## 646	22	1.0	rot	200	2500
## 647	23	1.0	schwarz	200	2000



### 1. Einführung

- Berühmte Leute zur Statistik
- Wie lügt man mit Statistik?
- Gute und schlechte Grafiken
- Begriff Statistik
- Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

```
# Neue Spalte Gesamtausgaben:  
MyData.Auswahl$AusgGesamt = MyData.Auswahl$AusgKomm + MyData.Auswahl$AusgSchuhe  
# sortiert nach Gesamtausgaben  
MyData.Auswahl[order(MyData.Auswahl$AusgGesamt), ]
```

##	Alter	Geschwister	Farbe	AusgSchuhe	AusgKomm	AusgGesamt
## 249	20	1.0	blau	1000	350	1350
## 353	20	0.0	schwarz	400	950	1350
## 121	22	0.0	silber	300	1100	1400
## 161	19	1.0	schwarz	600	800	1400
## 605	21	1.0	silber	600	800	1400
## 548	26	2.0	schwarz	240	1200	1440
## 227	20	1.0	schwarz	200	1250	1450
## 581	19	2.0	silber	500	950	1450
## 256	25	0.0	schwarz	280	1200	1480
## 604	24	1.0	schwarz	150	1340	1490
## 315	21	1.0	weiss	200	1300	1500
## 573	21	1.0	schwarz	300	1200	1500
## 582	20	1.0	schwarz	500	1000	1500
## 42	24	1.0	schwarz	1000	600	1600
## 653	27	2.0	schwarz	700	950	1650
## 419	21	0.0	schwarz	200	1500	1700
## 494	20	2.0	schwarz	250	1500	1750
## 615	25	4.5	schwarz	1200	600	1800
## 142	20	2.0	schwarz	290	1570	1860
## 492	23	2.0	weiss	160	1800	1960
## 663	27	2.0	schwarz	200	1800	2000
## 81	25	2.0	silber	200	1900	2100
## 647	23	1.0	schwarz	200	2000	2200
## 493	26	2.0	schwarz	300	2000	2300
## 415	26	1.0	blau	600	1850	2450



### 1. Einführung

- Berühmte Leute zur Statistik
- Wie lügt man mit Statistik?
- Gute und schlechte Grafiken
- Begriff Statistik
- Grundbegriffe der Datenerhebung

R und RStudio

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

# Statistik: Table of Contents

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



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



## Auswertungsmethoden für eindimensionales Datenmaterial

- ▶ Merkmal  $X$  wird an  $n$  Merkmalsträgern beobachtet  $\Rightarrow$

**Urliste**  $(x_1, \dots, x_n)$

Im Beispiel:  $x_1 = 4, x_2 = 11, \dots, x_{12} = 6$

- ▶ Urlisten sind oft unübersichtlich, z.B.:

```
## [1] 4 5 4 1 5 4 3 4 5 6 6 5 5 4 7 4 6 5 6 4 5 4 7 5 5 6 7 3
## [29] 7 6 6 7 4 5 4 7 7 5 5 5 5 6 6 4 5 2 5 4 7 5
```

- ▶ Dann zweckmäßig: **Häufigkeitsverteilungen**

Ausprägung (sortiert)	$a_j$	1	2	3	4	5	6	7	$\Sigma$
absolute Häufigkeit	$h(a_j) = h_j$	1	1	2	12	17	9	8	50
kumulierte abs. H.	$H(a_j) = \sum_{i=1}^j h(a_i)$	1	2	4	16	33	42	50	—
relative Häufigkeit	$f(a_j) = h(a_j)/n$	$\frac{1}{50}$	$\frac{1}{50}$	$\frac{2}{50}$	$\frac{12}{50}$	$\frac{17}{50}$	$\frac{9}{50}$	$\frac{8}{50}$	1
kumulierte rel. H.	$F(a_j) = \sum_{i=1}^j f(a_i)$	$\frac{1}{50}$	$\frac{2}{50}$	$\frac{4}{50}$	$\frac{16}{50}$	$\frac{33}{50}$	$\frac{42}{50}$	1	—

### 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: Alter von Studierenden in Statistik Vorlesung



	$h(a_j)$	$H(a_j) = \sum_{i=1}^j h(a_i)$	$f(a_j) = \frac{h(a_j)}{n}$	$F(a_j) = \sum_{i=1}^j f(a_i)$
17	1	1	0.0015	0.0015
18	37	38	0.0552	0.0567
19	113	151	0.1687	0.2254
20	113	264	0.1687	0.3940
21	94	358	0.1403	0.5343
22	71	429	0.1060	0.6403
23	67	496	0.1000	0.7403
24	49	545	0.0731	0.8134
25	24	569	0.0358	0.8493
26	25	594	0.0373	0.8866
27	19	613	0.0284	0.9149
28	20	633	0.0299	0.9448
29	11	644	0.0164	0.9612
30	5	649	0.0075	0.9687
31	5	654	0.0075	0.9761
32	7	661	0.0104	0.9866
33	2	663	0.0030	0.9896
34	3	666	0.0045	0.9940
35	2	668	0.0030	0.9970
36	2	670	0.0030	1.0000

## 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. Einführung

## 2. Deskriptive Statistik

### Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

## 3. W-Theorie

## 4. Induktive Statistik

### Quellen

### Tabellen

- ▶ für metrische Merkmale
- ▶ Anteil der Ausprägungen, die **höchstens so hoch** sind wie  $x$ .
- ▶ Exakt:

$$F(x) = \sum_{a_i \leq x} f(a_i)$$

## Beispiel

```
Studenten.ueber.32 = sort(MyData$Alter[MyData$Alter > 32])
```

```
Studenten.ueber.32
```


```
## [1] 33 33 34 34 34 35 35 36 36
```

```
# empirical cumulative distribution function (ecdf)
```

```
Studenten.F = ecdf(Studenten.ueber.32)
```

```
plot(Studenten.F, col=rgb(0.8,0,0,.7), lwd=3, main="", xlab="x", ylab="F(x)")
```

```
grid(lty=2) # Gitternetz
```





## 1. Einführung

## 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

## 3. W-Theorie

## 4. Induktive Statistik

Quellen

Tabellen

- ▶ für metrische Merkmale; Voraussetzung: **sortierte Urliste**
- ▶ Umkehrung der Verteilungsfunktion
- ▶ Anteil  $p$  gegeben, gesucht:  $F^{-1}(p)$ , falls vorhanden.
- ▶ Definition  $p$ -Quantil:

$$\tilde{x}_p = \begin{cases} \frac{1}{2}(x_{n \cdot p} + x_{n \cdot p + 1}), & \text{wenn } n \cdot p \in \mathbb{N}_0 \\ x_{\lceil n \cdot p \rceil}, & \text{sonst} \end{cases}$$

## Beispiel

```
## [1] 33 33 34 34 34 35 35 36 36
```

```
n = length(Studenten.ueber.32)
```

```
p = c(0.05, 2/n, 0.3, 0.5, 0.75, 0.9)
```

```
quantile(Studenten.ueber.32, probs=p, type=2)
```


```
##          5% 22.22222%          30%          50%          75%          90%
##          33.0          33.5          34.0          34.0          35.0          36.0
```

## 1 Balkendiagramm

```
M.t = table(MyData$Studiengang)  
M.t
```

```
##  
##  BW  ET  IM Inf  WI  
## 107  1  74  48  59
```

```
barplot(M.t, col="azure2")
```



(Höhe proportional zu Häufigkeit)


## 2 Kreissektorendiagramm

Winkel:  $w_j = 360^\circ \cdot f(a_j)$

z.B.  $w_{BW} = 360^\circ \cdot \frac{107}{289} \approx 133.2^\circ$

z.B.  $w_{IM} = 360^\circ \cdot \frac{74}{289} \approx 93.6^\circ$

```
pie(M.t)
```



(Fläche proportional zu Häufigkeit)



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik


Quellen

Tabellen




## Kreisdiagramm

```
pie(table(MyData$Farbe),  
     col=c("blue", "yellow", "red",  
           "black", "grey", "white"))
```



```
pie(table(MyData$Geschlecht),  
     col=c("coral1", "aquamarine"))
```



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik


Quellen

Tabellen


# Balkendiagramm, Klassen getrennt oder gestapelt



```
barplot(xtabs(~ Geschlecht + Studiengang),  
        legend=TRUE, beside=TRUE, col=c("mistyrose", "lightblue"))
```



```
barplot(xtabs(~ Geschlecht + Alter),  
        legend=TRUE, beside=FALSE, col=c("mistyrose", "lightblue"))
```



- 1. Einführung
- 2. Deskriptive Statistik

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

- 3. W-Theorie
- 4. Induktive Statistik

Quellen

Tabellen



## ③ Histogramm

- ▶ für klassierte Daten
- ▶ Fläche proportional zu Häufigkeit:


$$\text{Höhe}_j \cdot \text{Breite}_j = c \cdot h(a_j)$$

$$\Rightarrow \text{Höhe}_j = c \cdot \frac{h(a_j)}{\text{Breite}_j}$$

- ▶ Im Beispiel mit  $c = \frac{1}{12}$ :

Klasse	[0; 5)	[5; 15)	[15; 30]
$h(a_j)$	5	5	2
$\text{Breite}_j$	5	10	15
$\text{Höhe}_j$	$\frac{1}{12}$	$\frac{1}{24}$	$\frac{1}{90}$

```
require(MASS)
histData <- c(0,1,2,3,4,
             5,6,7,10,14,
             15,30)
truehist(histData,
         breaks=c(0, 4.999, 14.999, 30),
         col="azure2", ylab='')
```



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie


### 4. Induktive Statistik

Quellen

Tabellen

## Histogramm

```
plot(hist(AlterM, plot=F, breaks=20),  
      col=rgb(1,0,0,1/4), # make red transparent  
      main="",  
      xlim=c(40,80)) # draw from 40 to 80  
plot(hist(AlterV, plot=F, breaks=20),  
      col=rgb(0,0,1,1/4),  
      add=TRUE)
```



Histogramm: Alter der Väter (blau) und Mütter (rosa)



### 1. Einführung

### 2. Deskriptive Statistik

#### Häufigkeiten

#### Lage und Streuung

#### Konzentration

#### Zwei Merkmale

#### Korrelation

#### Preisindizes

#### Lineare Regression

### 3. W-Theorie


### 4. Induktive Statistik

### Quellen

### Tabellen

## Dichteplot

```
densMutter = density(na.exclude(AlterM))  
densVater = density(na.exclude(AlterV))  
plot(densMutter, main="", xlab="Alter",  
      xlim=c(40,80), # draw from 40 to 80  
      panel.first=grid()) # draw a grid  
polygon(densVater, density=-1, col=rgb(0,0,1,1/4))  
polygon(densMutter, density=-1, col=rgb(1,0,0,1/4))
```



Dichteplot: Alter der Väter (blau) und Mütter (rosa)



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen



"Sollen wir das arithmetische Mittel als durchschnittliche Körpergröße nehmen und den Gegner erschrecken, oder wollen wir ihn einlullen und nehmen den Median?"

### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

**Modus**  $x_{\text{Mod}}$ : häufigster Wert

**Beispiel:**

$a_j$	1	2	4
$h(a_j)$	4	3	1

}  $\Rightarrow x_{\text{Mod}} = 1$

Sinnvoll bei allen Skalenniveaus.

**Median**  $x_{\text{Med}}$ : ‚mittlerer Wert‘, d.h.

1. Urliste aufsteigend sortieren:  $x_1 \leq x_2 \leq \dots \leq x_n$

2. Dann

$$x_{\text{Med}} \begin{cases} = x_{\frac{n+1}{2}}, & \text{falls } n \text{ ungerade} \\ \in [x_{\frac{n}{2}}; x_{\frac{n}{2}+1}], & \text{falls } n \text{ gerade (meist } x_{\text{Med}} = \frac{1}{2} (x_{\frac{n}{2}} + x_{\frac{n}{2}+1})) \end{cases}$$

Im Beispiel oben:

1, 1, 1, 1, 2, 2, 2, 4  $\Rightarrow x_{\text{Med}} \in [1; 2]$ , z.B.  $x_{\text{Med}} = 1,5$

Sinnvoll ab ordinalem Skalenniveau.



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

- Quellen
- Tabellen

► **Arithmetisches Mittel**  $\bar{x}$ : Durchschnitt, d.h.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \sum_{j=1}^k a_j \cdot h(a_j)$$

Im Beispiel:

$$\bar{x} = \frac{1}{8} \cdot \left( \underbrace{1 + 1 + 1 + 1}_{1 \cdot 4} + \underbrace{2 + 2 + 2}_{2 \cdot 3} + \underbrace{4}_{4 \cdot 1} \right) = 1,75$$

Sinnvoll nur bei kardinalen Skalenniveau.

Bei klassierten Daten:

$$\bar{x}^* = \frac{1}{n} \sum \text{Klassenmitte} \cdot \text{Klassenhäufigkeit}$$

Im Beispiel:

$$\bar{x}^* = \frac{1}{12} \cdot (2,5 \cdot 5 + 10 \cdot 5 + 22,5 \cdot 2) = 8,96 \neq 7,5 = \bar{x}$$



## Lageparameter

### Ausgaben für Schuhe

```
median(na.exclude(AusgSchuhe))
```

```
## [1] 200
```

```
mean(na.exclude(AusgSchuhe))
```

```
## [1] 270.4529
```

### Alter

```
median(Alter)
```

```
## [1] 21
```

```
mean(Alter)
```

```
## [1] 22.12537
```

```
summary(Geschlecht)
```

```
## Frau Mann
```

```
## 389 281
```

### Alter der Mutter

```
median(na.exclude(AlterM))
```

```
## [1] 51
```

```
mean(na.exclude(AlterM))
```

```
## [1] 51.63677
```

### 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. Einführung

## 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

## 3. W-Theorie

## 4. Induktive Statistik

Quellen

Tabellen

- ▶ Voraussetzung: kardinale Werte  $x_1, \dots, x_n$

- ▶ **Beispiel:**

$$\left. \begin{array}{l} \text{a) } x_i \mid 1950 \quad 2000 \quad 2050 \\ \text{b) } x_i \mid 0 \quad 0 \quad 6000 \end{array} \right\} \text{je } \bar{x} = 2000$$

- ▶ **Spannweite:**  $SP = \max_i x_i - \min_i x_i$

Im Beispiel:

$$\text{a) } SP = 2050 - 1950 = 100$$

$$\text{b) } SP = 6000 - 0 = 6000$$

- ▶ **Mittlere quadratische Abweichung:**

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \underbrace{\frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2}_{\text{Verschiebungssatz}}$$



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

Quellen

Tabellen

## ► Mittlere quadratische Abweichung im Beispiel:

$$\begin{aligned} \text{a) } s^2 &= \frac{1}{3} \cdot (50^2 + 0^2 + 50^2) \\ &= \frac{1}{3} \cdot (1950^2 + 2000^2 + 2050^2) - 2000^2 = 1666,67 \end{aligned}$$

$$\begin{aligned} \text{b) } s^2 &= \frac{1}{3} \cdot (2000^2 + 2000^2 + 4000^2) \\ &= \frac{1}{3} \cdot (0^2 + 0^2 + 6000^2) - 2000^2 = 8000000 \end{aligned}$$

## ► Standardabweichung: $s = \sqrt{s^2}$

Im Beispiel:

$$\text{a) } s = \sqrt{1666,67} = 40,82$$

$$\text{b) } s = \sqrt{8000000} = 2828,43$$

## ► Variationskoeffizient: $V = \frac{s}{\bar{x}}$ (maßstabsunabhängig)

Im Beispiel:

$$\text{a) } V = \frac{40,82}{2000} = 0,02 (\hat{=} 2\%)$$

$$\text{b) } V = \frac{2828,43}{2000} = 1,41 (\hat{=} 141\%)$$



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen


### Tabellen

```
LageStreuung = function(x) {  
  x=na.omit(x) # ignoriere fehlende Werte  
  n = length(x) # Anzahl nicht fehlender Werte  
  popV = var(x)*(n-1)/n # var() ist nicht mittl. qu. Abweichung  
  return(list(mean=mean(x),  
              median=median(x),  
              Variance=popV,  
              StdDev=sqrt(popV),  
              VarCoeff=sqrt(popV)/mean(x)))  
}  
mat1 = sapply(MyData[c("Alter", "AlterV", "AlterM", # sapply: pro Spalte anwenden  
                      "Geschwister", "AnzSchuhe", "AusgSchuhe")],  
              LageStreuung)
```

	Alter	AlterV	AlterM	Geschwister	AnzSchuhe	AusgSchuhe
mean	22.13	54.28	51.64	1.51	21.22	270.45
median	21.00	54.00	51.00	1.00	16.00	200.00
Variance	11.36	35.35	25.74	1.18	415.51	56333.39
StdDev	3.37	5.95	5.07	1.08	20.38	237.35
VarCoeff	0.15	0.11	0.10	0.72	0.96	0.88

- ▶ Graphische Darstellung von Lage und Streuung
- ▶ **Box**: Oberer/Unterer Rand: 3. bzw. 1. Quartil ( $\tilde{x}_{0,75}$  bzw.  $\tilde{x}_{0,25}$ ),
- ▶ Linie in Mitte: Median
- ▶ **Whiskers**: Länge: Max./Min Wert, aber beschränkt durch das 1,5-fache des Quartilsabstands (falls größter/kleinster Wert größeren/kleineren Abstand von Box: Länge Whiskers durch größten/kleinsten Wert innerhalb dieser Schranken)
- ▶ **Ausreißer**: Alle Objekte außerhalb der Whisker-Grenzen

```
boxplot(AusgSchuhe ~ Geschlecht,  
        col=c("mistyrose", "lightblue"),  
        data=MyData, main="", las=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



summary(MyData)

```
##      Jahrgang      Alter      Groesse  Geschlecht  AlterV      AlterM
## Min.   :2014  Min.   :17.00  Min.   :150.0  Frau:389  Min.   :38.00  Min.   :37.00
## 1st Qu.:2014  1st Qu.:20.00  1st Qu.:166.0  Mann:281  1st Qu.:50.00  1st Qu.:48.00
## Median :2015  Median :21.00  Median :172.0                Median :54.00  Median :51.00
## Mean   :2015  Mean   :22.13  Mean   :173.1                Mean   :54.28  Mean   :51.64
## 3rd Qu.:2016  3rd Qu.:24.00  3rd Qu.:180.0                3rd Qu.:57.00  3rd Qu.:55.00
## Max.   :2016  Max.   :36.00  Max.   :198.0                Max.   :87.00  Max.   :70.00
##
##      GroesseV      GroesseM      Geschwister      Farbe      AusgKomm      AnzSchuhe
## Min.   :160.0  Min.   : 76.0  Min.   :0.000  blau   : 31  Min.   :  0.0  Min.   :  2.00
## 1st Qu.:175.0  1st Qu.:162.0  1st Qu.:1.000  gelb   :  5  1st Qu.: 207.5  1st Qu.:  8.00
## Median :180.0  Median :165.0  Median :1.000  rot    : 24  Median : 360.0  Median : 16.00
## Mean   :179.1  Mean   :166.2  Mean   :1.509  schwarz:333  Mean   : 458.1  Mean   : 21.22
## 3rd Qu.:183.0  3rd Qu.:170.0  3rd Qu.:2.000  silber : 82  3rd Qu.: 600.0  3rd Qu.: 30.00
## Max.   :204.0  Max.   :192.0  Max.   :9.000  weiss  :195  Max.   :4668.0  Max.   :275.00
## NA's   :11    NA's   :8
##      AusgSchuhe      Essgewohnheiten Raucher      NoteMathe      MatheZufr      Studiengang
## Min.   :  0.0  carnivor   :420  ja   : 81  Min.   :1.000  unzufrieden :185  BW   :107
## 1st Qu.: 100.0  fruktarisch : 1  nein:381  1st Qu.:2.650  geht so     :151  ET   :  1
## Median : 200.0  pescetarisch: 26  NA's:208  Median :3.300  zufrieden   :114  IM   : 74
## Mean   : 270.5  vegan       : 3  Mean   :3.233  sehr zufrieden: 74  Inf  : 48
## 3rd Qu.: 350.0  vegetarisch : 15  3rd Qu.:4.000  NA's       :146  WI   : 59
## Max.   :2500.0  NA's        :205  Max.   :5.000  NA's       :146  NA's:381
## NA's   :1    NA's        :162
```

1. Einführung

2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

3. W-Theorie


4. Induktive Statistik

Quellen

Tabellen

## Boxplots

```
for(attribute in c("Alter", "AlterV", "AlterM", "Geschwister",  
                  "AusgSchuhe", "AusgKomm")) {  
  data=MyData[, attribute]  
  boxplot(data, # all rows, column of attribute  
          col="lightblue", # fill color  
          lwd=3, # line width  
          cex=2, # character size  
          oma=c(1,1,2,1)  
          )  
  text(0.7,max(data), attribute, srt=90, adj=1)  
}
```



### 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. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

## ► Mittlere quadratische Abweichung im Beispiel:

$$\begin{aligned} \text{a) } s^2 &= \frac{1}{3} \cdot (50^2 + 0^2 + 50^2) \\ &= \frac{1}{3} \cdot (1950^2 + 2000^2 + 2050^2) - 2000^2 = 1666,67 \end{aligned}$$

$$\begin{aligned} \text{b) } s^2 &= \frac{1}{3} \cdot (2000^2 + 2000^2 + 4000^2) \\ &= \frac{1}{3} \cdot (0^2 + 0^2 + 6000^2) - 2000^2 = 8000000 \end{aligned}$$

## ► Standardabweichung: $s = \sqrt{s^2}$

Im Beispiel:

$$\text{a) } s = \sqrt{1666,67} = 40,82$$

$$\text{b) } s = \sqrt{8000000} = 2828,43$$

## ► Variationskoeffizient: $V = \frac{s}{\bar{x}}$ (maßstabsunabhängig)

Im Beispiel:

$$\text{a) } V = \frac{40,82}{2000} = 0,02 (\hat{=} 2\%)$$

$$\text{b) } V = \frac{2828,43}{2000} = 1,41 (\hat{=} 141\%)$$



```
LageStreuung = function(x) {  
  x=na.omit(x) # ignoriere fehlende Werte  
  n = length(x) # Anzahl nicht fehlender Werte  
  popV = var(x)*(n-1)/n # var() ist nicht mittl. qu. Abweichung  
  return(list(mean=mean(x),  
              median=median(x),  
              Variance=popV,  
              StdDev=sqrt(popV),  
              VarCoeff=sqrt(popV)/mean(x)))  
}  
mat1 = sapply(MyData[c("Alter", "AlterV", "AlterM", # sapply: pro Spalte anwenden  
                      "Geschwister", "AnzSchuhe", "AusgSchuhe")],  
              LageStreuung)
```

	Alter	AlterV	AlterM	Geschwister	AnzSchuhe	AusgSchuhe
mean	22.13	54.28	51.64	1.51	21.22	270.45
median	21.00	54.00	51.00	1.00	16.00	200.00
Variance	11.36	35.35	25.74	1.18	415.51	56333.39
StdDev	3.37	5.95	5.07	1.08	20.38	237.35
VarCoeff	0.15	0.11	0.10	0.72	0.96	0.88

### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie


### 4. Induktive Statistik

### Quellen

### Tabellen

- ▶ Graphische Darstellung von Lage und Streuung
- ▶ **Box**: Oberer/Unterer Rand: 3. bzw. 1. Quartil ( $\tilde{x}_{0,75}$  bzw.  $\tilde{x}_{0,25}$ ),
- ▶ Linie in Mitte: Median
- ▶ **Whiskers**: Länge: Max./Min Wert, aber beschränkt durch das 1,5-fache des Quartilsabstands (falls größter/kleinster Wert größeren/kleineren Abstand von Box: Länge Whiskers durch größten/kleinsten Wert innerhalb dieser Schranken)
- ▶ **Ausreißer**: Alle Objekte außerhalb der Whisker-Grenzen

```
boxplot(AusgSchuhe ~ Geschlecht,  
        col=c("mistyrose", "lightblue"),  
        data=MyData, main="", las=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



summary(MyData)

```
##      Jahrgang      Alter      Groesse      Geschlecht      AlterV      AlterM
## Min. :2014      Min. :17.00      Min. :150.0      Frau:389      Min. :38.00      Min. :37.00
## 1st Qu.:2014      1st Qu.:20.00      1st Qu.:166.0      Mann:281      1st Qu.:50.00      1st Qu.:48.00
## Median :2015      Median :21.00      Median :172.0                                Median :54.00      Median :51.00
## Mean  :2015      Mean  :22.13      Mean  :173.1                                Mean  :54.28      Mean  :51.64
## 3rd Qu.:2016      3rd Qu.:24.00      3rd Qu.:180.0                                3rd Qu.:57.00      3rd Qu.:55.00
## Max.  :2016      Max.  :36.00      Max.  :198.0                                Max.  :87.00      Max.  :70.00
##
##                                NA's :1      NA's :1
##      GroesseV      GroesseM      Geschwister      Farbe      AusgKomm      AnzSchuhe
## Min. :160.0      Min. : 76.0      Min. :0.000      blau : 31      Min. : 0.0      Min. : 2.00
## 1st Qu.:175.0      1st Qu.:162.0      1st Qu.:1.000      gelb : 5      1st Qu.: 207.5      1st Qu.: 8.00
## Median :180.0      Median :165.0      Median :1.000      rot  : 24      Median : 360.0      Median : 16.00
## Mean  :179.1      Mean  :166.2      Mean  :1.509      schwarz:333      Mean  : 458.1      Mean  : 21.22
## 3rd Qu.:183.0      3rd Qu.:170.0      3rd Qu.:2.000      silber : 82      3rd Qu.: 600.0      3rd Qu.: 30.00
## Max.  :204.0      Max.  :192.0      Max.  :9.000      weiss :195      Max.  :4668.0      Max.  :275.00
## NA's :11      NA's :8
##      AusgSchuhe      Essgewohnheiten Raucher      NoteMathe      MatheZufr      Studiengang
## Min. : 0.0      carnivor :420      ja : 81      Min. :1.000      unzufrieden :185      BW :107
## 1st Qu.:100.0      fruktarisch : 1      nein:381      1st Qu.:2.650      geht so :151      ET : 1
## Median :200.0      pescetarisch: 26      NA's:208      Median :3.300      zufrieden :114      IM : 74
## Mean : 270.5      vegan : 3      Mean :3.233      sehr zufrieden: 74      Inf : 48
## 3rd Qu.:350.0      vegetarisch : 15      3rd Qu.:4.000      NA's :146      WI : 59
## Max. :2500.0      NA's :205      Max. :5.000      NA's:381
## NA's :1      NA's :162
```

1. Einführung

2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

3. W-Theorie


4. Induktive Statistik

Quellen

Tabellen

## Boxplots

```
for(attribute in c("Alter", "AlterV", "AlterM", "Geschwister",  
                  "AusgSchuhe", "AusgKomm")) {  
  data=MyData[, attribute]  
  boxplot(data, # all rows, column of attribute  
          col="lightblue", # fill color  
          lwd=3, # line width  
          cex=2, # character size  
          oma=c(1,1,2,1)  
          )  
  text(0.7,max(data), attribute, srt=90, adj=1)  
}
```



### 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. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

- ▶ Gegeben: kardinale Werte  $0 \leq x_1 \leq x_2 \leq \dots \leq x_n$
- ▶ **Achtung!** Die Werte müssen aufsteigend sortiert werden!
- ▶ **Lorenzkurve:**

Wieviel Prozent der Merkmalssumme entfällt auf die  $x$  Prozent kleinsten Merkmalsträger?

- ▶ **Beispiel:** Die 90 % ärmsten besitzen 20 % des Gesamtvermögens.
- ▶ Streckenzug:  $(0,0), (u_1, v_1), \dots, (u_n, v_n), (1,1)$  mit

$$v_k = \text{Anteil der } k \text{ kleinsten MM-Träger an der MM-Summe} = \frac{\sum_{i=1}^k x_i}{\sum_{i=1}^n x_i}$$


$$u_k = \text{Anteil der } k \text{ kleinsten an der Gesamtzahl der MM-Träger} = \frac{k}{n}$$

# Lorenzkurve: Beispiel

Markt mit fünf Unternehmen; Umsätze: 6, 3, 11, 2, 3 (Mio. €)

$$\Rightarrow n = 5, \sum_{k=1}^5 x_k = 25$$

k	1	2	3	4	5
$x_k$	2	3	3	6	11
$p_k$	$\frac{2}{25}$	$\frac{3}{25}$	$\frac{3}{25}$	$\frac{6}{25}$	$\frac{11}{25}$
$v_k$	$\frac{2}{25}$	$\frac{5}{25}$	$\frac{8}{25}$	$\frac{14}{25}$	1
$u_k$	$\frac{1}{5}$	$\frac{2}{5}$	$\frac{3}{5}$	$\frac{4}{5}$	1



## 1. Einführung

## 2. Deskriptive Statistik

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

## 3. W-Theorie

## 4. Induktive Statistik

### Quellen

### Tabellen




## Knickstellen:

- ▶ Bei  $i$ -tem Merkmalsträger  $\iff x_{i+1} > x_i$
- ▶ Empirische Verteilungsfunktion liefert Knickstellen:

$a_j$	2	3	6	11
$h(a_j)$	1	2	1	1
$f(a_j)$	$\frac{1}{5}$	$\frac{2}{5}$	$\frac{1}{5}$	$\frac{1}{5}$
$F(a_j)$	$\frac{1}{5}$	$\frac{3}{5}$	$\frac{4}{5}$	1

## Vergleich von Lorenzkurven:




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

# Lorenzkurve: Beispiel Bevölkerungsanteil gegen BSP

Bangladesch  
Brasilien  
Deutschland  
Ungarn  
USA

(Stand 2000)



## Statistik



### 1. Einführung

### 2. Deskriptive Statistik

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

### 3. W-Theorie

### 4. Induktive Statistik


### Quellen

### Tabellen

# Lorenzkurve: Beispiel Bevölkerungsanteil gegen BSP

Bangladesch  
Brasilien  
Deutschland  
Ungarn  
USA

(Stand 2000)



- 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. Einführung

### 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale  
Korrelation  
Preisindizes  
Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

- ▶ Numerisches Maß der Konzentration: **Gini-Koeffizient**  $G$

$$G = \frac{\text{Fläche zwischen } 45^\circ\text{-Linie und } L}{\text{Fläche unter } 45^\circ\text{-Linie}} = \frac{\quad}{\quad}$$

- ▶ Aus den Daten:

$$G = \frac{2 \sum_{i=1}^n i x_i - (n+1) \sum_{i=1}^n x_i}{n \sum_{i=1}^n x_i} = \frac{2 \sum_{i=1}^n i p_i - (n+1)}{n} \quad \text{wobei} \quad p_i = \frac{x_i}{\sum_{i=1}^n x_i}$$

- ▶ Problem:  $G_{\max} = \frac{n-1}{n}$

- ⇒ **Normierter Gini-Koeffizient:**

$$G_* = \frac{n}{n-1} \cdot G \in [0; 1]$$



## Beispiel:

$i$	1	2	3	4	$\Sigma$
$x_i$	1	2	2	15	20
$p_i$	$\frac{1}{20}$	$\frac{2}{20}$	$\frac{2}{20}$	$\frac{15}{20}$	1

$$G = \frac{2 \cdot \left(1 \cdot \frac{1}{20} + 2 \cdot \frac{2}{20} + 3 \cdot \frac{2}{20} + 4 \cdot \frac{15}{20}\right) - (4 + 1)}{4} = 0,525$$

Mit  $G_{\max} = \frac{4-1}{4} = 0,75$  folgt

$$G_* = \frac{4}{4-1} \cdot 0,525 = 0,7$$

### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten

Lage und Streuung

Konzentration

Zwei Merkmale

Korrelation

Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen


### Tabellen

### Armutsbericht der Bundesregierung 2008



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



- ▶ Verteilung der Bruttoeinkommen in Preisen von 2000
- ▶ aus unselbständiger Arbeit der Arbeitnehmer/-innen insgesamt



	2002	2003	2004	2005
Arithmetisches Mittel	24.873	24.563	23.987	23.648
Median	21.857	21.531	20.438	20.089
Gini-Koeffizient	0,433	0,441	0,448	0,453



```
require(ineq) # inequality Paket
Lorenz = Lc(na.exclude(MyData$AusgSchuhe))
plot(Lorenz, xlab="", ylab="", main="") # Standard plot
plot(c(0,1), c(0,1), type="n", # bisschen netter
      panel.first=grid(lwd=1.5, col=rgb(0,0,0,1/2)),
      xlab="", main="", ylab="")
polygon(Lorenz$p, Lorenz$L, density=-1, col=rgb(0,0,1,1/4), lwd=2)
```



```
Gini(na.exclude(AusgSchuhe)) # Gini-Koeffizient
```

```
## [1] 0.4069336
```

## 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. Einführung

## 2. Deskriptive Statistik

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

## 3. W-Theorie

## 4. Induktive Statistik

### Quellen

### Tabellen

### ► 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:

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

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

### ► Exponentialindex:

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

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

$$\begin{aligned} CR_2 &= \frac{17}{20} = 0,85 \\ H &= \left( \frac{1}{20} \right)^2 + \dots + \left( \frac{15}{20} \right)^2 = 0,59 \\ E &= \left( \frac{1}{20} \right)^{\frac{1}{20}} \dots \left( \frac{15}{20} \right)^{\frac{15}{20}} = 0,44 \end{aligned}$$



## 1. Einführung

## 2. Deskriptive Statistik

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

## 3. W-Theorie

## 4. Induktive Statistik

### Quellen

### Tabellen

### ► 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:

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

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

### ► Exponentialindex:

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

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

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

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

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

## Zweidimensionale Urliste

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

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

## Kontingenztafel:

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 (= $n$ )

$$f_2(b_3 | a_2) = \frac{4}{40} = 0,1 \quad (10\% \text{ der nicht angegurteten starben.})$$

$$f_1(a_2 | b_3) = \frac{4}{10} = 0,4 \quad (40\% \text{ der Todesopfer waren nicht angegurtet.})$$

## 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	$\Sigma$
$x_i$	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 Streuungsdiagramm



(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

# Beispiel Streuungsdiagramm

```
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("genepLOT") ## from BioConductor
smoothScatter(x, nrpoints=Inf,
              colramp=colorRampPalette(brewer.pal(9, "YlOrRd")),
              bandwidth=c(30, 3))
```



## Statistik



### 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 Streuungsdiagramm

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



## Statistik



### 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)
```




## Statistik



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!!"
```



## Statistik



### 1. Einführung

### 2. Deskriptive Statistik

- Häufigkeiten
- Lage und Streuung
- Konzentration

### Zwei Merkmale

- Korrelation
- Preisindizes
- Lineare Regression

### 3. W-Theorie


### 4. Induktive Statistik

### Quellen

### Tabellen

# Bubbleplot: 3 metrische Variablen

```
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)

## Statistik



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration

Zwei Merkmale

Korrelation  
Preisindizes  
Lineare Regression

### 3. W-Theorie


### 4. Induktive Statistik

Quellen

Tabellen

# Circular Plots: Assoziationen

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



## Statistik



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

## Bravais-Pearson-Korrelationskoeffizient

Voraussetzung: X, Y kardinalskaliert

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



- 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:

$i$	$x_i$	$y_i$	$x_i^2$	$y_i^2$	$x_i y_i$
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
$\Sigma$	25	28	159	174	157

$\Rightarrow$

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

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

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

(deutliche positive Korrelation)

## 1. Einführung

## 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale

## Korrelation

Preisindizes  
Lineare Regression

## 3. W-Theorie

## 4. Induktive Statistik

## Quellen

## Tabellen

guessthecorrelation.com



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale

Korrelation

Preisindizes  
Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

Quellen


Tabellen

**GUESS THE  
CORRELATION**

NEW GAME  
RESUME GAME  
TWO PLAYERS  
SCORE BOARD  
ABOUT  
SETTINGS

**HIGH SCORE** 0

ETSCHSTE



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  $R_i^{(r)} = 1$  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



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



## 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

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

- ② Berechne **theoretische Häufigkeiten**

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

- ③ Berechne

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

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



## ④ Kontingenzkoeffizient:

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

wobei

$$K_{\max} = \sqrt{\frac{M-1}{M}} \quad \text{mit} \quad M = \min\{k, l\}$$

## 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.

### 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.

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

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

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

### 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 Autounfälle

	Verletzung			
	leicht	schwer	tödlich	
angegurtet	264	90	6	360
nicht angegurtet	2	34	4	40
	266	124	10	400



Mosaikplot Autounfälle

### 1. Einführung

### 2. Deskriptive Statistik

- Häufigkeiten
- Lage und Streuung
- Konzentration
- Zwei Merkmale

### Korrelation

- Preisindizes
- Lineare Regression

### 3. W-Theorie


### 4. Induktive Statistik

### Quellen

### Tabellen



```
Data.complete = na.omit(MyData[,c("MatheZufr", "NoteMathe")])
Noten.complete =
  ordered(cut(Data.complete$NoteMathe, breaks=c(0,1.5,2.5,3.5,4.1,5.0)),
    labels=c("sehr gut", "gut", "befriedigend", "ausreichend", "nicht bestanden"))
tab = table("Note"=Noten.complete, "Zufrieden mit Leistung"=Data.complete$MatheZufr)
require(vcd)
mosaic(tab, shade = TRUE, gp_args = list(interpolate = function(x) pmin(x/4, 1)), labeling_args =
  list(rot_labels = c(90,0,0,0), just_labels = c("left", "left", "right", "right"),
    offset_varnames = c(left = 5, top=5.5), offset_labels = c(right = 3)),
  margins = c(right = 1, bottom = 3, left=6, top=5))
```



„Note in Matheklausur“ gegen „Zufrieden mit Leistung“


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

# Mosaicplot Geschlecht, Wunschfarbe für Smartphone

```
tab = table(Farbe, Geschlecht)
tab
```

```
##           Geschlecht
## Farbe      Frau  Mann
## blau       15   16
## gelb        3    2
## rot        19    5
## schwarz   143  190
## silber     57   25
## weiss    152   43
```

```
mosaicplot(t(tab), shade = TRUE,
           sort=2:1, main="")
```



## Statistik



### 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(vcd)
Data.complete = na.omit(MyData[,c("Geschlecht", "Studiengang")])
with(Data.complete, {
  tab = table("Studiengang"=Studiengang, "Geschlecht"=Geschlecht)
  mosaic(tab, shade = TRUE, gp_args = list(interpolate = function(x) pmin(x/4, 1)), labeling_args =
    list(rot_labels = c(90,0,0,0), just_labels = c("left", "left", "right", "right"),
      offset_varnames = c(left = 5, top=5.5), offset_labels = c(right = 3)),
    margins = c(right = 1, bottom = 3, left=6, top=5))
})
```



## Studiengang vs. Geschlecht

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


# Mosaicplot Geschlecht, Anzahl Schuhe

```
tab = table(  
  "Anzahl Schuhe" =  
  cut(AnzSchuhe,  
      breaks =  
        quantile(  
          AnzSchuhe,  
          probs = (0:4)/4  
        )  
  ),  
  Geschlecht)
```

tab

```
##           Geschlecht  
## Anzahl Schuhe Frau Mann  
## (2,8]           22  148  
## (8,16]           53  108  
## (16,30]          195   18  
## (30,275]         119    1
```

```
mosaicplot(t(tab), shade = TRUE,  
           main="", las=1)
```



## Statistik



### 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. Einführung

### 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale  
Korrelation

### Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

- ▶ **Preismesszahl:** Misst Preisveränderung eines einzelnen Gutes:

$$\frac{\text{Preis zum Zeitpunkt } j}{\text{Preis zum Zeitpunkt } i}$$

dabei:  $j$ : Berichtsperiode,  $i$ : Basisperiode

- ▶ **Preisindex:** Misst Preisveränderung mehrerer Güter (Aggregation von Preismesszahlen durch Gewichtung)
- ▶ Notation:

$p_0(i)$  : Preis des  $i$ -ten Gutes in Basisperiode 0

$p_t(i)$  : Preis des  $i$ -ten Gutes in Berichtsperiode  $t$

$q_0(i)$  : Menge des  $i$ -ten Gutes in Basisperiode 0

$q_t(i)$  : Menge des  $i$ -ten Gutes in Berichtsperiode  $t$



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale  
Korrelation

### Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

- ▶ Gleichgewichteter Preisindex:

$$P_{0t}^G = \frac{1}{n} \sum_{i=1}^n \frac{p_t(i)}{p_0(i)} = \sum_{i=1}^n \frac{p_t(i)}{p_0(i)} \cdot g(i) \quad \text{mit} \quad g(i) = \frac{1}{n}$$

**Nachteil:** Auto und Streichhölzer haben gleiches Gewicht

**Lösung:** Preise mit Mengen gewichten!

- ▶ Preisindex von Laspeyres:

$$P_{0t}^L = \frac{\sum_{i=1}^n p_t(i) q_0(i)}{\sum_{i=1}^n p_0(i) q_0(i)} = \sum_{i=1}^n \frac{p_t(i)}{p_0(i)} \cdot g_0(i) \quad \text{mit} \quad g_0(i) = \frac{p_0(i) q_0(i)}{\sum_{j=1}^n p_0(j) q_0(j)}$$

- ▶ Preisindex von Paasche:

$$P_{0t}^P = \frac{\sum_{i=1}^n p_t(i) q_t(i)}{\sum_{i=1}^n p_0(i) q_t(i)} = \sum_{i=1}^n \frac{p_t(i)}{p_0(i)} \cdot g_t(i) \quad \text{mit} \quad g_t(i) = \frac{p_0(i) q_t(i)}{\sum_{j=1}^n p_0(j) q_t(j)}$$



### 1. Einführung

### 2. Deskriptive Statistik

- Häufigkeiten
- Lage und Streuung
- Konzentration
- Zwei Merkmale
- Korrelation

### Preisindizes

- Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

## Warenkorb: Kartoffeln und Kaffee

	1950		2013	
	Preis (€)	Menge pro Woche	Preis (€)	Menge pro Woche
1 kg Kartoffeln	0,04	3,58	1,10	1,25
100 g Kaffeebohnen	3,00	0,25	0,70	1,31

$$P_{1950,2013}^L = \frac{1,10 \cdot 3,58 + 0,70 \cdot 0,25}{0,04 \cdot 3,58 + 3,00 \cdot 0,25} \approx 4,6048$$

$$P_{1950,2013}^P = \frac{1,10 \cdot 1,25 + 0,70 \cdot 1,31}{0,04 \cdot 1,25 + 3,00 \cdot 1,31} \approx 0,5759$$



## Idealindex von Fisher:

$$P_{0t}^F = \sqrt{P_{0t}^L P_{0t}^P}$$

## Marshall-Edgeworth-Index:

$$P_{0t}^{ME} = \frac{\sum_{i=1}^n p_t(i)[q_0(i) + q_t(i)]}{\sum_{i=1}^n p_0(i)[q_0(i) + q_t(i)]}$$

## Preisindex von Lowe:

$$P_{0t}^{LO} = \frac{\sum_{i=1}^n p_t(i)q(i)}{\sum_{i=1}^n p_0(i)q(i)}$$

wobei  $q(i) \hat{=}$   $\begin{cases} \text{Durchschn. Menge von} \\ \text{Gut } i \text{ über alle (bekannten)} \\ \text{Perioden} \end{cases}$

### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale  
Korrelation

### Preisindizes

Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen



## Warenkorb: Kartoffeln und Kaffee

	1950		2013	
	Preis (€)	Menge pro Woche	Preis (€)	Menge pro Woche
1 kg Kartoffeln	0,04	3,58	1,10	1,25
100 g Kaffeebohnen	3,00	0,25	0,70	1,31

$$P_{1950,2013}^F \approx \sqrt{4,6048 \cdot 0,5759} = 1,6284$$

$$P_{1950,2013}^{ME} = \frac{1,10 \cdot (3,58 + 1,25) + 0,70 \cdot (0,25 + 1,31)}{0,04 \cdot (3,58 + 1,25) + 3,00 \cdot (0,25 + 1,31)} = 1,3143$$

$$P_{1950,2013}^{Lo} = \frac{1,10 \cdot 2,5 + 0,70 \cdot 0,75}{0,04 \cdot 2,5 + 3,00 \cdot 0,75} = 1,3936$$

Annahme bei  $P^{Lo}$ : Durchschn. Mengen bei Kartoffeln bzw. Kaffeebohnen von 1950 bis 2013 sind 2,5 bzw. 0,75.

### 1. Einführung

### 2. Deskriptive Statistik

- Häufigkeiten
- Lage und Streuung
- Konzentration
- Zwei Merkmale
- Korrelation

### Preisindizes

- Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

### Bundesliga 2008/2009

- ▶ Gegeben: Daten zu den 18 Vereinen der ersten Bundesliga in der Saison 2008/09
- ▶ Merkmale:  
**Vereinssetat** für Saison (nur direkte Gehälter und Spielergehälter)
- ▶ und **Ergebnispunkte** in Tabelle am Ende der Saison

	Etat	Punkte
FC Bayern	80	67
VfL Wolfsburg	60	69
SV Werder Bremen	48	45
FC Schalke 04	48	50
VfB Stuttgart	38	64
Hamburger SV	35	61
Bayer 04 Leverkusen	35	49
Bor. Dortmund	32	59
Hertha BSC Berlin	31	63
1. FC Köln	28	39
Bor. Mönchengladbach	27	31
TSG Hoffenheim	26	55
Eintracht Frankfurt	25	33
Hannover 96	24	40
Energie Cottbus	23	30
VfL Bochum	17	32
Karlsruher SC	17	29
Arminia Bielefeld	15	28

(Quelle: Welt)



#### 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. Einführung

### 2. Deskriptive Statistik


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

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen





### 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. Einführung

## 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale  
Korrelation  
Preisindizes

Lineare Regression

## 3. W-Theorie

## 4. Induktive Statistik

Quellen

Tabellen

- ▶ Kann man die **Tabellenpunkte** näherungsweise über einfache Funktion **in Abhängigkeit des Vereinsatzes** darstellen?
- ▶ Allgemein: Darstellung einer Variablen  $Y$  als Funktion von  $X$ :

$$y = f(x)$$

- ▶ Dabei:
  - $X$  heißt **Regressor** bzw. **unabhängige Variable**
  - $Y$  heißt **Regressand** bzw. **abhängige Variable**
- ▶ Wichtiger (und einfachster) Spezialfall:  $f$  beschreibt einen linearen Trend:

$$y = a + b x$$

- ▶ Dabei anhand der Daten zu schätzen:  $a$  (Achsenabschnitt) und  $b$  (Steigung)
- ▶ Schätzung von  $a$  und  $b$ : **Lineare Regression**



### 1. Einführung

### 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale  
Korrelation  
Preisindizes  
Lineare Regression

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

- ▶ Pro Datenpunkt gilt mit Regressionsmodell:

$$y_i = a + bx_i + \epsilon_i$$

- ▶ Dabei:  $\epsilon_i$  ist jeweils Fehler (der Grundgesamtheit),
- ▶ mit  $e_i = y_i - (\hat{a} + \hat{b}x_i)$ : Abweichung (**Residuen**) zwischen gegebenen Daten der Stichprobe und durch Modell geschätzten Werten
- ▶ Modell gut wenn alle Residuen  $e_i$  zusammen möglichst klein
- ▶ Einfache Summe aber nicht möglich, denn  $e_i$  positiv oder negativ
- ▶ Deswegen: Summe der Quadrate von  $e_i$
- ▶ **Prinzip der kleinsten Quadrate**: Wähle  $a$  und  $b$  so, dass

$$Q(a, b) = \sum_{i=1}^n [y_i - (a + bx_i)]^2 \rightarrow \min$$



### 1. Einführung

### 2. Deskriptive Statistik

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

### 3. W-Theorie

### 4. Induktive Statistik

### Quellen

### Tabellen

## ► Beste und eindeutige Lösung:

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



## ► Regressionsgerade:

$$\hat{y} = \hat{a} + \hat{b} x$$



## 1. Einführung

## 2. Deskriptive Statistik

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

## 3. W-Theorie

## 4. Induktive Statistik

### Quellen

### Tabellen


- ▶ Berechnung eines linearen Modells der Bundesligadaten
- ▶ dabei: Punkte  $\hat{=}$   $y$  und Etat  $\hat{=}$   $x$ :

$\bar{x}$	33,83
$\bar{y}$	46,89
$\sum x_i^2$	25209
$\sum x_i y_i$	31474
$n$	18

$$\Rightarrow \hat{b} = \frac{31474 - 18 \cdot 33,83 \cdot 46,89}{25209 - 18 \cdot 33,83^2}$$
$$\approx 0,634$$

$$\Rightarrow \hat{a} = 46,89 - \hat{b} \cdot 33,83$$
$$\approx 25,443$$

- ▶ Modell:  $\hat{y} = 25,443 + 0,634 \cdot x$




- ▶ Prognosewert für Etat = 30:

$$\hat{y}(30) = 25,443 + 0,634 \cdot 30$$
$$\approx 44,463$$



- ▶ **Varianz** der Daten in abhängiger Variablen  $y_i$  als Repräsentant des **Informationsgehalts**
- ▶ Ein Bruchteil davon kann in Modellwerten  $\hat{y}_i$  abgebildet 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



## 1. Einführung

## 2. Deskriptive Statistik

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


## 3. W-Theorie

## 4. Induktive Statistik

### Quellen

### Tabellen

- ▶ **Varianz** der Daten in abhängiger Variablen  $y_i$  als Repräsentant des **Informationsgehalts**
- ▶ Ein Bruchteil davon kann in Modellwerten  $\hat{y}_i$  abgebildet werden



- ▶ Empirische Varianz (mittlere quadratische Abweichung) für „rot“ bzw. „grün“ ergibt jeweils

$$\frac{1}{18} \sum_{i=1}^{18} (y_i - \bar{y})^2 \approx 200,77 \quad \text{bzw.} \quad \frac{1}{18} \sum_{i=1}^{18} (\hat{y}_i - \bar{y})^2 \approx 102,78$$



## 1. Einführung

## 2. Deskriptive Statistik

Häufigkeiten  
Lage und Streuung  
Konzentration  
Zwei Merkmale  
Korrelation  
Preisindizes

Lineare Regression

## 3. W-Theorie

## 4. Induktive Statistik

Quellen

Tabellen

- ▶ Gütemaß für die Regression: **Determinationskoeffizient** (Bestimmtheitskoeffizient):

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{\sum_{i=1}^n \hat{y}_i^2 - n\bar{y}^2}{\sum_{i=1}^n y_i^2 - n\bar{y}^2} = r^2 \in [0; 1]$$

- ▶ Mögliche Interpretation von  $R^2$ :  
**Durch die Regression erklärter Anteil der Varianz**
- ▶  $R^2 = 0$  wird erreicht wenn  $X, Y$  unkorreliert  
 $R^2 = 1$  wird erreicht wenn  $\hat{y}_i = y_i \forall i$  (alle Punkte auf Regressionsgerade)
- ▶ Im (Bundesliga-)Beispiel:

$$R^2 = \frac{\sum_{i=1}^{18} (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^{18} (y_i - \bar{y})^2} \approx \frac{102,78}{200,77} \approx 51,19\%$$



► 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 (1973))

## 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. 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

# Plot der Anscombe-Daten



## Statistik



### 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  
##    18.2234      0.6159
```



### 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. 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)



## ► 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



- ▶ 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

# Statistik: Table of Contents

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



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



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



### 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:

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

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



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

Quellen

Tabellen

► **Ereignis** A: Folgerscheinung 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:**

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



- 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**:

1.  $P(A) \leq 1$
2.  $P(\emptyset) = 0$
3.  $A \subset B \Rightarrow P(A) \leq P(B)$
4.  $P(\bar{A}) = 1 - P(A)$
5.  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$



► **Beispiel:**



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

## 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:

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

- ▶ 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





- 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:

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

- ▶ Im Venndiagramm:





## Zufallsvariablen und Verteilungen

- ▶ Beschreibung von Ereignissen durch reelle Zahlen
- ▶ Formal: **Zufallsvariable** ist Abbildung von Ereignisraum in reelle Zahlen:

$$X : \Omega \rightarrow \mathbb{R}$$

- ▶ **Nach** Durchführung des Zufallsvorgangs:

**Realisation:**  $x = X(\omega)$

- ▶ **Vor** Durchführung des Zufallsvorgangs:

**Wertebereich:**  $X(\Omega) = \{x : x = X(\omega), \omega \in \Omega\}$

- ▶ **Beispiel:** Würfeln,  $X$ : Augenzahl,  $X(\Omega) = \{1, 2, \dots, 6\}$ ,  $x = 4$  (z.B.)

$$P(X = 4) = \frac{1}{6}, \quad P(X \leq 3) = \frac{3}{6} = \frac{1}{2}$$

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit


Zufallsvariablen und Verteilungen

Verteilungsparameter

### 4. Induktive Statistik

### Quellen

### Tabellen



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

Quellen

Tabellen

▶ Zuweisung von Wahrscheinlichkeiten zu Realisationen


▶ Formal:

$$F(x) = P(X \leq x)$$


▶ Eigenschaften der **Verteilungsfunktion**:

- $F(x) \in [0; 1]$
- Definitionsbereich:  $\mathbb{R}$  mit  $F(-\infty) = 0$ ,  $F(\infty) = 1$
- monoton wachsend, d.h.  $x_1 < x_2 \Rightarrow F(x_1) \leq F(x_2)$
- Es gilt:

$$P(a < X \leq b) = F(b) - F(a)$$



Beispiel einer Verteilungsfunktion



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
  - Kombinatorik
  - Zufall und Wahrscheinlichkeit
  - Zufallsvariablen und Verteilungen

Verteilungsparameter

4. Induktive Statistik

Quellen

Tabellen



- ▶  $X$  heißt **diskret**, wenn  $X(\Omega) = \{x_1, x_2, \dots\}$  endlich ist.
- ▶ Wahrscheinlichkeitsfunktion dann:


$$f(x) = P(X = x)$$

**Beispiel:** Münze 2 mal werfen;  $X$ : Anzahl "Kopf"

	(Z, Z)	(Z, K), (K, Z)	(K, K)
$x_i$	0	1	2
$f(x_i)$	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$

$$F(x) = \begin{cases} 0, & \text{falls } x < 0 \\ \frac{1}{4}, & \text{falls } 0 \leq x < 1 \\ \frac{3}{4}, & \text{falls } 1 \leq x < 2 \\ 1, & \text{falls } x \geq 2 \end{cases}$$





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

- ▶ **Wiederholter** Zufallsvorgang
- ▶  $n$  Durchführungen (jeweils unabhängig)
- ▶ Pro Durchführung:  $A$  oder  $\bar{A}$  mit  $P(A) = p$  ( $\hat{=}$  Ziehen mit Zurücklegen)
- ▶ Schreibe:


$$X_i = \begin{cases} 1, & \text{falls } A \text{ bei } i\text{-ter Durchführung eintritt} \\ 0, & \text{falls } \bar{A} \text{ bei } i\text{-ter Durchführung eintritt} \end{cases}$$

- ▶ Dann gibt

$$X = \sum_{i=1}^n X_i$$

an, wie oft  $A$  eintritt.

- ▶ Gesucht: Wahrscheinlichkeitsfunktion von  $X$



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

## ► Herleitung:


- 1)  $P(X_i = 1) = P(A) = p$ ,  $P(X_i = 0) = P(\bar{A}) = 1 - p$
- 2)  $\sum_{i=1}^n x_i = x$  entspricht "x mal Ereignis A und  $n - x$  mal  $\bar{A}$ "  
Wahrscheinlichkeit (bei Unabhängigkeit):  $p^x \cdot (1 - p)^{n-x}$
- 3) Aber: Reihenfolge irrelevant! Anzahl Anordnungen:  $\binom{n}{x}$

## ⇒ **Wahrscheinlichkeitsfunktion der Binomialverteilung:**

$$f(x) = \begin{cases} \binom{n}{x} \cdot p^x \cdot (1 - p)^{n-x}, & \text{falls } x \in \{0, 1, \dots, n\} \\ 0, & \text{sonst} \end{cases}$$

- Kurzschreibweise:  $X \sim B(n; p)$   
**X ist binomialverteilt mit Parametern n und p**
- Tabellen zeigen meist  $F(x)$
- für  $f(x)$  gilt:  $f(x) = F(x) - F(x - 1)$

# $X \sim B(n, 0.25)$ , Tabelle der Binomialverteilung $F(x) = P(X \leq x)$



$x \setminus n$	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	0.7500	0.5625	0.4219	0.3164	0.2373	0.1780	0.1335	0.1001	0.0751	0.0563	0.0422	0.0317	0.0238	0.0178	0.0134
1	1.0000	0.9375	0.8438	0.7383	0.6328	0.5339	0.4450	0.3671	0.3003	0.2440	0.1971	0.1584	0.1267	0.1010	0.0802
2		1.0000	0.9844	0.9492	0.8965	0.8306	0.7564	0.6786	0.6007	0.5256	0.4552	0.3907	0.3326	0.2811	0.2361
3			1.0000	0.9961	0.9844	0.9624	0.9295	0.8862	0.8343	0.7759	0.7133	0.6488	0.5843	0.5213	0.4613
4				1.0000	0.9990	0.9954	0.9871	0.9727	0.9511	0.9219	0.8854	0.8424	0.7940	0.7415	0.6865
5					1.0000	0.9998	0.9987	0.9958	0.9900	0.9803	0.9657	0.9456	0.9198	0.8883	0.8516
6						1.0000	0.9999	0.9996	0.9987	0.9965	0.9924	0.9858	0.9757	0.9617	0.9434
7							1.0000	1.0000	0.9999	0.9996	0.9988	0.9972	0.9944	0.9897	0.9827
8								1.0000	1.0000	1.0000	0.9999	0.9996	0.9990	0.9979	0.9958
9									1.0000	1.0000	1.0000	1.0000	0.9999	0.9997	0.9992
10										1.0000	1.0000	1.0000	1.0000	1.0000	0.9999
11											1.0000	1.0000	1.0000	1.0000	1.0000

$x \setminus n$	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
0	0.0100	0.0075	0.0056	0.0042	0.0032	0.0024	0.0018	0.0013	0.0010	0.0008	0.0006	0.0004	0.0003	0.0002	0.0002
1	0.0635	0.0501	0.0395	0.0310	0.0243	0.0190	0.0149	0.0116	0.0090	0.0070	0.0055	0.0042	0.0033	0.0025	0.0020
2	0.1971	0.1637	0.1353	0.1114	0.0913	0.0745	0.0607	0.0492	0.0398	0.0321	0.0258	0.0208	0.0166	0.0133	0.0106
3	0.4050	0.3530	0.3057	0.2631	0.2252	0.1917	0.1624	0.1370	0.1150	0.0962	0.0802	0.0666	0.0551	0.0455	0.0375
4	0.6302	0.5739	0.5187	0.4654	0.4149	0.3674	0.3235	0.2832	0.2467	0.2138	0.1844	0.1583	0.1354	0.1153	0.0979
5	0.8104	0.7653	0.7175	0.6678	0.6172	0.5666	0.5168	0.4685	0.4222	0.3783	0.3372	0.2990	0.2638	0.2317	0.2026
6	0.9205	0.8929	0.8610	0.8251	0.7858	0.7436	0.6994	0.6537	0.6074	0.5611	0.5154	0.4708	0.4279	0.3869	0.3481
7	0.9729	0.9598	0.9431	0.9226	0.8982	0.8701	0.8385	0.8037	0.7662	0.7265	0.6852	0.6427	0.5998	0.5568	0.5143
8	0.9925	0.9876	0.9807	0.9713	0.9591	0.9439	0.9254	0.9037	0.8787	0.8506	0.8196	0.7860	0.7502	0.7126	0.6736
9	0.9984	0.9969	0.9946	0.9911	0.9861	0.9794	0.9705	0.9592	0.9453	0.9287	0.9092	0.8868	0.8616	0.8337	0.8034
10	0.9997	0.9994	0.9988	0.9977	0.9961	0.9936	0.9900	0.9852	0.9787	0.9703	0.9599	0.9472	0.9321	0.9145	0.8943
11	1.0000	0.9999	0.9998	0.9995	0.9991	0.9983	0.9971	0.9954	0.9928	0.9893	0.9845	0.9784	0.9706	0.9610	0.9494
12	1.0000	1.0000	1.0000	0.9999	0.9998	0.9996	0.9993	0.9988	0.9979	0.9966	0.9948	0.9922	0.9888	0.9842	0.9784
13	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9997	0.9995	0.9991	0.9985	0.9976	0.9962	0.9944	0.9918
14	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9996	0.9993	0.9989	0.9982	0.9973
15	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9997	0.9995	0.9992
16	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998
17		1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
18			1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000

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

Quellen

Tabellen

### Beispiel

Aus einem 32-er Kartenblatt wird **3-mal eine Karte mit Zurücklegen** gezogen.

Wie wahrscheinlich ist es, **2-mal Herz** zu ziehen?

$$X_i = \begin{cases} 1, & \text{falls } i\text{-te Karte Herz} \\ 0, & \text{sonst} \end{cases} \Rightarrow X_i \sim B\left(1; \frac{8}{32}\right)$$


$$X = \sum_{i=1}^n X_i = X_1 + X_2 + X_3 \Rightarrow X \sim B\left(3; \frac{1}{4}\right)$$

Mithilfe der **Wahrscheinlichkeitsfunktion**:

$$P(X = 2) = f(2) = \binom{3}{2} \cdot 0,25^2 \cdot 0,75^1 = 0,1406$$

Mithilfe der **Tabelle** ( $n = 3$ ):

$$P(X = 2) = F(2) - F(1) = 0,9844 - 0,8438 = 0,1406$$




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




►  $X \sim B(3, \frac{1}{4})$

Binomial-Vtlg. mit  $n=3$   $p=0.25$




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

# Binomialverteilung: Wahrscheinlichkeitsfunktion




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


Binomial-Vtlg. mit  $n=10$   $p=0.25$




Binomial-Vtlg. mit  $n=100$   $p=0.25$




Binomial-Vtlg. mit  $n=30$   $p=0.25$



Binomial-Vtlg. mit  $n=500$   $p=0.25$





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

- ▶  $n$ -faches Ziehen **ohne** Zurücklegen aus  $N$  Objekten, davon  $M$  markiert.


$X$  = Anzahl gezogener Objekte mit Markierung

heißt **hypergeometrisch verteilt** mit den Parametern  $N, M, n$ .

- ▶ Kurzschreibweise:  $X \sim \text{Hyp}(N; M; n)$
- ▶ Wahrscheinlichkeitsfunktion:

$$f(x) = \begin{cases} \frac{\binom{M}{x} \binom{N-M}{n-x}}{\binom{N}{n}}, & \text{falls } x \text{ möglich} \\ 0, & \text{sonst} \end{cases}$$

- ▶ Ist  $n \leq \frac{N}{20}$ , so gilt:  $\text{Hyp}(N; M; n) \approx B(n; \frac{M}{N})$



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

- ▶ Aus einem 32-Kartenblatt wird 3-mal eine Karte ohne Zurücklegen gezogen.
- ▶ Wie wahrscheinlich ist es, 2-mal "Herz" zu ziehen?
- ▶ D.h.:  $N = 32$ ,  $M = 8$ ,  $n = 3$ ,  $x = 2$ .

$$\begin{aligned} P(X = 2) = f(2) &= \frac{\binom{8}{2} \binom{32-8}{3-2}}{\binom{32}{3}} = \frac{\binom{8}{2} \binom{24}{1}}{\binom{32}{3}} = \frac{8!}{2! \cdot 6!} \cdot 24 \\ &= \frac{29! \cdot 8! \cdot 3! \cdot 24}{32! \cdot 6! \cdot 2!} = \frac{8 \cdot 7 \cdot 3 \cdot 24}{32 \cdot 31 \cdot 30} = \frac{4032}{29760} = \frac{21}{155} \\ &= 0,1355 \end{aligned}$$



Dabei wurde verwendet:

$$\binom{n}{k} = \frac{n!}{k!(n-k)!} \quad \text{und} \quad \binom{n}{1} = n.$$

## Beispiel: $x$ Treffer im Lotto 6 aus 49

►  $X \sim \text{Hyp}(49, 6, 6)$

$x$	$P(X = x)$ (in %)
0	43.596498
1	41.301945
2	13.237803
3	1.765040
4	0.096862
5	0.001845
6	0.000007



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




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


- ▶ Approximation für  $B(n; p)$  und  $\text{Hyp}(N; M; n)$
- ▶ Geeignet, wenn  $p$  klein ( $\leq 0,1$ ),  $n$  groß ( $\geq 50$ ) und  $np \leq 10$ .
- ▶ „Verteilung der seltenen Ereignisse“ (z.B. Anzahl 6-er pro Lottoauspielung)
- ▶  $X$  ist **poissonverteilt mit Parameter  $\lambda$** :  $X \sim P(\lambda)$
- ▶ Wahrscheinlichkeitsfunktion:

$$f(x) = \begin{cases} \frac{\lambda^x}{x!} \cdot e^{-\lambda}, & \text{falls } x = 0, 1, 2, \dots \\ 0, & \text{sonst} \end{cases}$$

- ▶  $F(x)$  in Tabelle
- ▶ Überblick: Approximation




# Poissonverteilung: $X \sim P(\lambda)$ , Tabelle der Verteilungsfunktionen



$x \setminus \lambda$	1.6	1.7	1.8	1.9	2	2.1	2.2	2.3	2.4	2.5	2.6	2.7	2.8	2.9	3
0	0.2019	0.1827	0.1653	0.1496	0.1353	0.1225	0.1108	0.1003	0.0907	0.0821	0.0743	0.0672	0.0608	0.0550	0.0498
1	0.5249	0.4933	0.4628	0.4338	0.4060	0.3796	0.3546	0.3309	0.3085	0.2873	0.2674	0.2487	0.2311	0.2146	0.1992
2	0.7834	0.7572	0.7306	0.7037	0.6767	0.6496	0.6227	0.5960	0.5697	0.5438	0.5184	0.4936	0.4695	0.4460	0.4232
3	0.9212	0.9068	0.8913	0.8747	0.8571	0.8387	0.8194	0.7994	0.7787	0.7576	0.7360	0.7141	0.6919	0.6696	0.6472
4	0.9763	0.9704	0.9636	0.9559	0.9474	0.9379	0.9275	0.9163	0.9041	0.8912	0.8774	0.8629	0.8477	0.8318	0.8153
5	0.9940	0.9920	0.9896	0.9868	0.9834	0.9796	0.9751	0.9700	0.9643	0.9580	0.9510	0.9433	0.9349	0.9258	0.9161
6	0.9987	0.9981	0.9974	0.9966	0.9955	0.9941	0.9925	0.9906	0.9884	0.9858	0.9828	0.9794	0.9756	0.9713	0.9665
7	0.9997	0.9996	0.9994	0.9992	0.9989	0.9985	0.9980	0.9974	0.9967	0.9958	0.9947	0.9934	0.9919	0.9901	0.9881
8	1.0000	0.9999	0.9999	0.9998	0.9998	0.9997	0.9995	0.9994	0.9991	0.9989	0.9985	0.9981	0.9976	0.9970	0.9962
9	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9999	0.9998	0.9997	0.9996	0.9995	0.9993	0.9992	0.9989
10	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9999	0.9998	0.9998	0.9997
11	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999
12	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000

$x \setminus \lambda$	3.1	3.2	3.3	3.4	3.5	3.6	3.7	3.8	3.9	4	4.1	4.2	4.3	4.4	4.5
0	0.0451	0.0408	0.0369	0.0334	0.0302	0.0273	0.0247	0.0224	0.0203	0.0183	0.0166	0.0150	0.0136	0.0123	0.0111
1	0.1847	0.1712	0.1586	0.1469	0.1359	0.1257	0.1162	0.1074	0.0992	0.0916	0.0845	0.0780	0.0719	0.0663	0.0611
2	0.4012	0.3799	0.3594	0.3397	0.3209	0.3028	0.2854	0.2689	0.2531	0.2381	0.2238	0.2102	0.1974	0.1852	0.1736
3	0.6248	0.6025	0.5803	0.5584	0.5366	0.5152	0.4942	0.4735	0.4533	0.4335	0.4142	0.3954	0.3772	0.3595	0.3423
4	0.7982	0.7806	0.7626	0.7442	0.7255	0.7064	0.6872	0.6679	0.6484	0.6288	0.6093	0.5898	0.5704	0.5512	0.5321
5	0.9057	0.8946	0.8829	0.8706	0.8576	0.8441	0.8301	0.8156	0.8006	0.7851	0.7693	0.7532	0.7367	0.7199	0.7029
6	0.9612	0.9554	0.9490	0.9422	0.9347	0.9267	0.9182	0.9091	0.8995	0.8893	0.8787	0.8675	0.8558	0.8437	0.8311
7	0.9858	0.9832	0.9802	0.9769	0.9733	0.9692	0.9648	0.9599	0.9546	0.9489	0.9427	0.9361	0.9290	0.9214	0.9134
8	0.9953	0.9943	0.9931	0.9917	0.9901	0.9883	0.9863	0.9840	0.9815	0.9786	0.9755	0.9721	0.9683	0.9642	0.9598
9	0.9986	0.9982	0.9978	0.9973	0.9967	0.9960	0.9952	0.9942	0.9931	0.9919	0.9905	0.9889	0.9871	0.9851	0.9829
10	0.9996	0.9995	0.9994	0.9992	0.9990	0.9987	0.9984	0.9981	0.9977	0.9972	0.9966	0.9959	0.9952	0.9943	0.9933
11	0.9999	0.9999	0.9998	0.9998	0.9997	0.9996	0.9995	0.9994	0.9993	0.9991	0.9989	0.9986	0.9983	0.9980	0.9976
12	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9999	0.9998	0.9998	0.9997	0.9997	0.9996	0.9995	0.9994	0.9992
13	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9999	0.9999	0.9998	0.9998
14	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999
15	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000

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



## Beispiel

- ▶  $X \sim B(10\,000; 0,0003)$ ; In Tabelle der Binomialverteilung nicht vertafelt! Approximation:

$$\left. \begin{array}{l} p = 0,0003 < 0,1 \\ n = 10\,000 > 50 \\ np = 3 < 10 \end{array} \right\} \Rightarrow B(10\,000; 0,0003) \approx P(3)$$

- ▶ Mithilfe der Wahrscheinlichkeitsfunktion:

$$P(X = 5) = \frac{3^5}{5!} \cdot e^{-3} = 0,1008188$$

- ▶ Mithilfe der Tabelle der Poissonverteilung:

$$P(X = 5) = F(5) - F(4) = 0,9161 - 0,8153 = 0,1008$$

- ▶ Exakter Wert:  $P(X = 5) = 0,1008239$

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und Verteilungen


Verteilungsparameter

### 4. Induktive Statistik

### Quellen

### Tabellen

# Poisson- versus Binomialverteilung: Vergleich




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


Quellen

Tabellen


$n=5$   $p=0.8$




$n=10$   $p=0.4$




$n=100$   $p=0.04$



$n=1000$   $p=0.004$







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

▶  $X$  heißt **stetig**, wenn  $F(x)$  stetig ist.

▶ Dann existiert ein  $f(t)$  mit:


$$F(x) = \int_{-\infty}^x f(t) dt$$

$f(x)$  heißt **Dichtefunktion** von  $X$ .



▶ Dann:

$$\begin{aligned} P(a < X < b) &= P(a \leq X < b) \\ &= P(a < X \leq b) \\ &= P(a \leq X \leq b) \\ &= \int_a^b f(x) dx \\ &= F(b) - F(a) \end{aligned}$$




## Eigenschaften der Dichtefunktion

- ▶  $f(x) \geq 0$  für alle  $x \in \mathbb{R}$
- ▶ Wegen  $F(\infty) = 1$  muss stets gelten:

$$\int_{-\infty}^{\infty} f(x) dx = 1$$

- ▶  $P(X = x) = 0$  für alle  $x \in \mathbb{R}$
- ▶  $f(x) > 1$  ist möglich
- ▶ für  $x \in \mathbb{R}$  ist  $F(x)$  differenzierbar  $\Rightarrow F'(x) = f(x)$ .
- ▶ Intervallgrenzen spielen keine Rolle:

$$\begin{aligned} P(X \in [a; b]) &= P(X \in (a; b)) \\ &= P(X \in [a; b)) \\ &= P(X \in (a; b]) \\ &= F(b) - F(a) \end{aligned}$$



### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit


Zufallsvariablen und  
Verteilungen

Verteilungsparameter

### 4. Induktive Statistik

### Quellen

### Tabellen



## Beispiel

$$f(x) = \begin{cases} 0, & \text{falls } x < 0 \\ \frac{1}{10}, & \text{falls } 0 \leq x \leq 10 \\ 0, & \text{falls } x > 10 \end{cases}$$

Verteilungsfunktion:

$$\int_0^x f(t) dt = \int_0^x \frac{1}{10} dt = \left[ \frac{t}{10} \right]_0^x = \frac{x}{10} \Rightarrow$$

$$F(x) = \begin{cases} 0, & \text{falls } x < 0 \\ \frac{x}{10}, & \text{falls } 0 \leq x \leq 10 \\ 1, & \text{falls } x > 10 \end{cases}$$

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und  
Verteilungen

Verteilungsparameter

### 4. Induktive Statistik



### Quellen

### Tabellen


Eine Zufallsvariable  $X$  mit

$$f(x) = \begin{cases} \frac{1}{b-a}, & \text{falls } a \leq x \leq b \\ 0, & \text{sonst} \end{cases}$$

heißt **gleichverteilt** im Intervall  $[a; b]$ .



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



### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und  
Verteilungen

Verteilungsparameter

### 4. Induktive Statistik

#### Quellen

#### Tabellen

## ► Verteilungsfunktion der Gleichverteilung:

$$F(x) = \begin{cases} 0, & \text{falls } x < a \\ \frac{x-a}{b-a}, & \text{falls } a \leq x \leq b \\ 1, & \text{falls } x > b \end{cases}$$


## ► Beispiel: $X$ gleichverteilt in $[1; 20]$

$$\begin{aligned} P(2 \leq X \leq 12) &= F(12) - F(2) = \frac{12-1}{20-1} - \frac{2-1}{20-1} \\ &= \frac{12-2}{20-1} = \frac{10}{19} \\ &= 0,5263 \end{aligned}$$


Eine Zufallsvariable  $X$  mit einer Dichtefunktion

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$


und  $\sigma > 0$  heißt **normalverteilt**.



Kurzschreibweise:  $X \sim N(\mu; \sigma)$



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



Normalverteilung

C.F. Gauß




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

Quellen

Tabellen


# Verteilungsfunktion $\Phi$ der **Standardnormalverteilung**

Dabei bedeutet  $\Phi(x)$  zum Beispiel:  $\Phi(2,13) = \Phi(2,1 + 0,03) = 0,9834$ . Diesen Wert findet man in der Zeile mit  $x_1 = 2,1$  und der Spalte mit  $x_2 = 0,03$ .



$x_1 \setminus x_2$	0	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0	0.5000	0.5040	0.5080	0.5120	0.5160	0.5199	0.5239	0.5279	0.5319	0.5359
0.1	0.5398	0.5438	0.5478	0.5517	0.5557	0.5596	0.5636	0.5675	0.5714	0.5754
0.2	0.5793	0.5832	0.5871	0.5910	0.5948	0.5987	0.6026	0.6064	0.6103	0.6141
0.3	0.6179	0.6217	0.6255	0.6293	0.6331	0.6368	0.6406	0.6443	0.6480	0.6517
0.4	0.6554	0.6591	0.6628	0.6664	0.6700	0.6737	0.6773	0.6808	0.6844	0.6879
0.5	0.6915	0.6950	0.6985	0.7020	0.7054	0.7089	0.7123	0.7157	0.7191	0.7224
0.6	0.7258	0.7291	0.7324	0.7357	0.7389	0.7422	0.7454	0.7486	0.7518	0.7549
0.7	0.7580	0.7612	0.7642	0.7673	0.7704	0.7734	0.7764	0.7794	0.7823	0.7852
0.8	0.7882	0.7910	0.7939	0.7967	0.7996	0.8023	0.8051	0.8079	0.8106	0.8133
0.9	0.8159	0.8186	0.8212	0.8238	0.8264	0.8290	0.8315	0.8340	0.8365	0.8389
1	0.8414	0.8438	0.8461	0.8485	0.8508	0.8532	0.8554	0.8577	0.8599	0.8622
1.1	0.8643	0.8665	0.8687	0.8708	0.8729	0.8749	0.8770	0.8790	0.8810	0.8830
1.2	0.8849	0.8869	0.8888	0.8907	0.8925	0.8944	0.8962	0.8980	0.8997	0.9015
1.3	0.9032	0.9049	0.9066	0.9083	0.9099	0.9115	0.9131	0.9147	0.9162	0.9177
1.4	0.9193	0.9207	0.9222	0.9237	0.9251	0.9265	0.9279	0.9292	0.9306	0.9319
1.5	0.9332	0.9345	0.9358	0.9370	0.9382	0.9394	0.9406	0.9418	0.9430	0.9441
1.6	0.9452	0.9463	0.9474	0.9485	0.9495	0.9505	0.9516	0.9526	0.9535	0.9545
1.7	0.9554	0.9564	0.9573	0.9582	0.9591	0.9600	0.9608	0.9616	0.9625	0.9633
1.8	0.9641	0.9649	0.9656	0.9664	0.9671	0.9679	0.9686	0.9693	0.9700	0.9706
1.9	0.9713	0.9719	0.9726	0.9732	0.9738	0.9744	0.9750	0.9756	0.9762	0.9767
2	0.9773	0.9778	0.9783	0.9788	0.9793	0.9798	0.9803	0.9808	0.9812	0.9817
<b>2.1</b>	0.9821	0.9826	0.9830	<b>0.9834</b>	0.9838	0.9842	0.9846	0.9850	0.9854	0.9857
2.2	0.9861	0.9865	0.9868	0.9871	0.9875	0.9878	0.9881	0.9884	0.9887	0.9890
2.3	0.9893	0.9896	0.9898	0.9901	0.9904	0.9906	0.9909	0.9911	0.9914	0.9916
2.4	0.9918	0.9920	0.9922	0.9925	0.9927	0.9929	0.9931	0.9933	0.9934	0.9936
2.5	0.9938	0.9940	0.9941	0.9943	0.9945	0.9946	0.9948	0.9949	0.9951	0.9952
2.6	0.9953	0.9955	0.9956	0.9957	0.9959	0.9960	0.9961	0.9962	0.9963	0.9964
2.7	0.9965	0.9966	0.9967	0.9968	0.9969	0.9970	0.9971	0.9972	0.9973	0.9974
2.8	0.9975	0.9975	0.9976	0.9977	0.9978	0.9978	0.9979	0.9980	0.9980	0.9981
2.9	0.9981	0.9982	0.9983	0.9983	0.9984	0.9984	0.9985	0.9985	0.9986	0.9986
3	0.9987	0.9987	0.9987	0.9988	0.9988	0.9989	0.9989	0.9989	0.9990	0.9990
3.1	0.9990	0.9991	0.9991	0.9991	0.9992	0.9992	0.9992	0.9992	0.9993	0.9993
3.2	0.9993	0.9993	0.9994	0.9994	0.9994	0.9994	0.9995	0.9995	0.9995	0.9995

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



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

- ▶ Dichte ist symmetrisch zu  $\mu$ :

$$f(\mu - x) = f(\mu + x)$$

- ▶  $\mu$  ist Lage-,  $\sigma$  ist Streuungsparameter

- ▶ **Standardnormalverteilung:**

$N(0; 1)$  mit Verteilungsfunktion  $\Phi(x)$  ( $\rightarrow$  Tabelle 3)


- ▶ Kenntnis von  $\Phi(x)$ ,  $\mu$  und  $\sigma$  genügt, denn:

$$X \sim N(\mu; \sigma) \iff \frac{X - \mu}{\sigma} \sim N(0; 1) \implies$$

$$F(x) = \Phi\left(\frac{x - \mu}{\sigma}\right)$$

- ▶ Tabelle enthält nur positive  $x$ : Deswegen

$$\Phi(-x) = 1 - \Phi(x)$$



### Beispiel:

Projektdauer  $X \sim N(39; 2)$ .

Wahrscheinlichkeit für Projektdauer zwischen 37 und 41 Wochen?

### Lösung:

$$\begin{aligned} P(37 \leq X \leq 41) &= F(41) - F(37) \\ &= \Phi\left(\frac{41-39}{2}\right) - \Phi\left(\frac{37-39}{2}\right) \\ &= \Phi(1) - \Phi(-1) \\ &= \Phi(1) - [1 - \Phi(1)] \\ &= 2 \cdot \Phi(1) - 1 \\ &= 2 \cdot 0,8413 - 1 \\ &= 0,6826 \end{aligned}$$

#### 1. Einführung

#### 2. Deskriptive Statistik

#### 3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit


Zufallsvariablen und  
Verteilungen

Verteilungsparameter

#### 4. Induktive Statistik

#### Quellen

#### Tabellen



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

- 4. Induktive Statistik
- Quellen
- Tabellen

a) **Modus**  $x_{\text{Mod}}$ :  $f(x_{\text{Mod}}) \geq f(x)$  für alle  $x$   
(i.A. nicht eindeutig, z.B. Gleichverteilung)

### Beispiele:

- Normalverteilung:  $x_{\text{Mod}} = \mu$
- Diskrete Verteilung mit:


$x$	0	1	2
$f(x)$	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$

} $\Rightarrow x_{\text{Mod}} = 1$ 

b) **Median**  $x_{\text{Med}}$ :  $F(x_{\text{Med}}) = \frac{1}{2}$  bzw. kleinstes  $x$  mit  $F(x) > \frac{1}{2}$

### Beispiele:

- Normalverteilung:  $x_{\text{Med}} = \mu$
- Diskrete Verteilung  
oben:  $F(0) = \frac{1}{4} < \frac{1}{2}$ ,  $F(1) = \frac{3}{4} > \frac{1}{2} \Rightarrow x_{\text{Med}} = 1$



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

### Quellen

### Tabellen

c)  **$\alpha$ -Fraktile**  $x_\alpha$ :  $F(x_\alpha) = \alpha$  (für stetige Verteilungen)

**Beispiel:**  $X \sim N(0; 1)$ ,  $Y \sim N(3; 2)$

$$\begin{aligned}x_{0,975} &= 1,96 && \text{(Tab. 3)} \\x_{0,025} &= -x_{0,975} = -1,96 \\y_{0,025} &= 2 \cdot x_{0,025} + 3 = -0,92\end{aligned}$$


Hinweise:

- $x_{\text{Med}} = x_{0,5}$
- Wenn  $x_\alpha$  nicht vertafelt  $\rightarrow$  **Interpolation:**

$$x_\alpha \approx x_a + (x_b - x_a) \cdot \frac{\alpha - a}{b - a}$$

mit  $a$  : größte vertafelte Zahl  $< \alpha$   
 $b$  : kleinste vertafelte Zahl  $> \alpha$

**Beispiel:**  $X \sim N(0; 1)$ ;  $x_{0,6} \approx$   
 $0,25 + (0,26 - 0,25) \cdot \frac{0,6 - 0,5987}{0,6026 - 0,5987} = 0,2533$



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

Quellen

Tabellen

Verteilungsparameter

d) Erwartungswert  $E(X)$  bzw.  $\mu$ :

$$E(X) = \begin{cases} \sum_i x_i f(x_i), & \text{falls } X \text{ diskret} \\ \int_{-\infty}^{\infty} x f(x) dx, & \text{falls } X \text{ stetig} \end{cases}$$

**Beispiel:** Diskrete Verteilung mit


$x$	0	1	2
$f(x)$	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$

 $\Rightarrow E(X) = 0 \cdot \frac{1}{4} + 1 \cdot \frac{1}{2} + 2 \cdot \frac{1}{4} = 1$

**Beispiel:** Für eine **exponentialverteilte** Zufallsvariable  $X$  mit der Dichte

$$f(x) = \begin{cases} \lambda \cdot e^{-\lambda x} & \text{für } x \geq 0 \\ 0 & \text{sonst} \end{cases} \quad \text{folgt}$$

$$\begin{aligned} E(X) &= \int_{-\infty}^{\infty} x \cdot f(x) dx = \lambda \int_0^{\infty} x \cdot e^{-\lambda x} dx = \lambda \left[ -\frac{1}{\lambda} x e^{-\lambda x} - \int_0^{\infty} 1 \cdot \left( -\frac{1}{\lambda} e^{-\lambda x} \right) dx \right] \\ &= -x e^{-\lambda x} - \frac{1}{\lambda} e^{-\lambda x} \Big|_0^{\infty} = -0 - \left( -0 - \frac{1}{\lambda} \right) = \frac{1}{\lambda} \end{aligned}$$



### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

Kombinatorik  
Zufall und Wahrscheinlichkeit  
Zufallsvariablen und  
Verteilungen

Verteilungsparameter

### 4. Induktive Statistik

### Quellen

### Tabellen

- ▶ Ist  $f$  **symmetrisch** bzgl.  $a$ , so gilt  $E(X) = a$   
**Beispiel:**  $f$  der Gleichverteilung symmetrisch  
bzgl.  $\frac{a+b}{2} \Rightarrow E(X) = \frac{a+b}{2}$

- ▶ Lineare Transformation:

$$E(a + bX) = a + b \cdot E(X)$$

- ▶ Summenbildung:


$$E\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n E(X_i)$$

**Beispiel:**  $X$  gleichverteilt in  $[0; 10]$ ,  $Y \sim N(1; 1)$ ;  $Z = X + 5Y$

$$E(Z) = E(X + 5Y) = E(X) + E(5Y) = E(X) + 5 \cdot E(Y) = \frac{10+0}{2} + 5 \cdot 1 = 10$$

- ▶ Unabhängigkeit:

$$X, Y \text{ unabhängig} \Rightarrow E(X \cdot Y) = E(X) \cdot E(Y)$$



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

► **Varianz**  $\text{Var}(X)$  bzw.  $\sigma^2$ :

$$\text{Var}(X) = E([X - E(X)]^2) = \begin{cases} \sum_i [x_i - E(X)]^2 f(x_i), & \text{wenn } X \text{ diskret} \\ \int_{-\infty}^{\infty} [x - E(X)]^2 f(x) dx, & \text{wenn } X \text{ stetig} \end{cases}$$

► **Standardabweichung**  $\text{Sta}(X)$  bzw.  $\sigma$ :

$$\text{Sta}(X) = \sqrt{\text{Var}(X)}$$


**Beispiel:** Diskrete Verteilung

$x$	0	1	2	:
$f(x)$	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$	

$$\text{Var}(X) = (0 - 1)^2 \cdot \frac{1}{4} + (1 - 1)^2 \cdot \frac{1}{2} + (2 - 1)^2 \cdot \frac{1}{4} = \frac{1}{2}$$

**Beispiel:** Für eine **exponentialverteilte** Zufallsvariable  $X$  (Dichte siehe Erwartungswert) folgt

$$\begin{aligned} \text{Var}(X) &= \int_{-\infty}^{\infty} (x - E(X))^2 f(x) dx = \lambda \int_0^{\infty} (x - \frac{1}{\lambda})^2 \cdot e^{-\lambda x} dx \\ &= e^{-\lambda x} \left( -x^2 + \frac{2x}{\lambda} - (\frac{1}{\lambda})^2 - \frac{2}{\lambda^2} - \frac{2x}{\lambda} + \frac{2}{\lambda^2} \right) \Big|_0^{\infty} \\ &= 0 - \left( -0^2 - (\frac{1}{\lambda})^2 \right) = \frac{1}{\lambda^2} \end{aligned}$$



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

► **Verschiebungssatz:**

$$\text{Var}(X) = E(X^2) - [E(X)]^2$$

**Beispiel:** Diskrete Verteilung

$x$	$0$	$1$	$2$	$:$
$f(x)$	$\frac{1}{4}$	$\frac{1}{2}$	$\frac{1}{4}$	

$$\begin{aligned} E(X^2) &= 0^2 \cdot \frac{1}{4} + 1^2 \cdot \frac{1}{2} + 2^2 \cdot \frac{1}{4} \\ &= \frac{3}{2} \end{aligned}$$


$$\Rightarrow E(X^2) - [E(X)]^2 = \frac{3}{2} - 1^2 = \frac{1}{2} = \text{Var}(X)$$

► **Lineare Transformation:**

$$\text{Var}(a + bX) = b^2 \text{Var}(X)$$


► **Summenbildung** gilt nur, wenn die  $X_i$  unabhängig! Dann:

$$\text{Var}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \text{Var}(X_i)$$



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

Verteilung von $X$	$E(X)$	$\text{Var}(X)$
Binomialverteilung $B(n; p)$	$np$	$np(1 - p)$
Hypergeometrische Verteilung mit den Parametern $N, M, n$	$n \frac{M}{N}$	$n \frac{M}{N} \frac{N-M}{N} \frac{N-n}{N-1}$
Poisson-Verteilung $P(\lambda)$	$\lambda$	$\lambda$
Gleichverteilung in $[a; b]$ mit $a < b$	$\frac{a + b}{2}$	$\frac{(b - a)^2}{12}$
Normalverteilung $N(\mu; \sigma)$	$\mu$	$\sigma^2$



### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

Kombinatorik  
Zufall und Wahrscheinlichkeit  
Zufallsvariablen und  
Verteilungen

Verteilungsparameter

### 4. Induktive Statistik

### Quellen

### Tabellen

- ▶ Für beliebige Zufallsvariablen  $X$  und  $\varepsilon > 0$  gilt die **Ungleichung von Tschebyschow**:

$$P(|X - E[X]| \geq \varepsilon) \leq \frac{\text{Var}[X]}{\varepsilon^2}$$


## Beispiele:

- ▶  $X$  ist gleichverteilt mit Parametern  $a, b$  und  $\varepsilon = \frac{1}{3}(a - b)$ , also  $E[X] = \frac{1}{2}(a + b)$  und  $\text{Var}[X] = \frac{1}{12}(a - b)^2$

$$\Rightarrow P\left(|X - \frac{1}{2}(a + b)| \geq \frac{1}{3}(a - b)\right) \leq \frac{(a - b)^2}{12} \cdot \frac{3^2}{(a - b)^2} = 3/4$$

- ▶  $X \sim B(100; 0,2)$  und  $\varepsilon = 10$   
damit:  $E[X] = 100 \cdot 0,2 = 20$  und  $\text{Var}[X] = 100 \cdot 0,2 \cdot (1 - 0,2) = 16$

$$\Rightarrow P(|X - 20| \geq 10) \leq \frac{16}{10^2} = 0,16$$



### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

Kombinatorik

Zufall und Wahrscheinlichkeit

Zufallsvariablen und  
Verteilungen

Verteilungsparameter

### 4. Induktive Statistik

Quellen

Tabellen

## ► Kovarianz:

$$\begin{aligned}\text{Cov}(X, Y) &= E[(X - E(X))(Y - E(Y))] \\ &= E(X \cdot Y) - E(X) \cdot E(Y) \\ &\text{(Verschiebungssatz)}\end{aligned}$$

## ► Korrelationskoeffizient:

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X) \cdot \text{Var}(Y)}}$$

## ► Bemerkungen:


- $\rho$  ist  $r$  nachgebildet  $\Rightarrow \rho \in [-1; 1]$
- $|\rho| = 1 \iff Y = a + bX$  (mit  $b \neq 0$ )
- $\rho = 0 \iff X, Y$  **unkorreliert**

## ► Varianz einer Summe zweier ZV:


$$\text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y) + 2 \text{Cov}(X, Y)$$

# Statistik: Table of Contents

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



- 4 Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik

Grundlagen

Punkt-Schätzung  
Intervall-Schätzung  
Signifikanztests

Quellen

Tabellen

- ▶ Vollerhebung of unmöglich,
- ▶ Deshalb: Beobachte Teilgesamtheit und schließe auf Grundgesamtheit

## Beispiel


Warensendung von 1000 Stück; darunter  $M$  Stück Ausschuss.  
 $M$  ist unbekannt.

→ Zufällige Entnahme von  $n = 30$  Stück („Stichprobe“).

Darunter 2 Stück Ausschuss.

Denkbare Zielsetzungen:

- ▶ Schätze  $M$  durch eine Zahl (z.B.  $\frac{2}{30} \cdot 1000 = 66,67$ )
- ▶ Schätze ein Intervall für  $M$  (z.B.  $M \in [58; 84]$ )
- ▶ Teste die Hypothese, dass  $M > 50$  ist.



- ▶ **Grundgesamtheit (G):** Menge aller relevanten Merkmalsträger.
- ▶ **Verteilung von G:**  $F(x) = P(X \leq x)$  = Wahrscheinlichkeit, dass ein Merkmalsträger ausgewählt wird, der beim untersuchten Merkmal maximal die Ausprägung  $x$  aufweist.
- ▶ **Uneingeschränkte (reine) Zufallsauswahl:**  
Jedes Element von  $G$  hat die selbe Chance, ausgewählt zu werden.
- ▶ **Stichprobenumfang (n):** Anzahl der Merkmalsträger in der Stichprobe.
- ▶ **Einfache Stichprobe:**  
Uneingeschränkte Zufallsauswahl und unabhängige Ziehung.  
→ Alle **Stichprobenvariablen**  $X_1, \dots, X_n$  sind iid.
- ▶ **Stichprobenergebnis:**  
 $n$ -Tupel der Realisationen der Stichprobenvariablen,  $(x_1, \dots, x_n)$ .

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

#### Grundlagen

Punkt-Schätzung


Intervall-Schätzung

Signifikanztests

#### Quellen

#### Tabellen

# Wichtige Stichprobenfunktionen



- Gegeben: Einfache Stichprobe  $X_1, \dots, X_n$ , Beliebige Verteilung, mit  $E(X_i) = \mu$ ,  $\text{Var}(X_i) = \sigma^2$

Stichprobenfunktion $V$	Bezeichnung	$E(V)$	$\text{Var}(V)$
$\sum_{i=1}^n X_i$	Merkmalssumme	$n\mu$	$n\sigma^2$
$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$	Stichprobenmittel	$\mu$	$\frac{\sigma^2}{n}$
$\frac{\bar{X} - \mu}{\sigma} \sqrt{n}$	Gauß-Statistik	0	1
$\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2$	mittlere quadratische Abweichung bezüglich $\mu$	$\sigma^2$	
$\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$	mittlere quadratische Abweichung	$\frac{n-1}{n} \sigma^2$	
$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$	Stichprobenvarianz	$\sigma^2$	
$S = \sqrt{S^2}$	Stichproben-Standardabweichung		
$\frac{\bar{X} - \mu}{S} \sqrt{n}$	t-Statistik		

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik

Grundlagen






- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests

Quellen

Tabellen

# Auswirkungen der Stichprobengröße

Ziehen von 10.000 Stichproben (jeweils vom Umfang  $n$ ) und Berechnung der Stichprobenmittel (Verteilung: zwei überlagerte Gleichverteilungen):



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik





## Grundlagen

- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests


## Quellen

## Tabellen

# Auswirkungen der Stichprobengröße



## Statistik



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik



Grundlagen

Punkt-Schätzung  
Intervall-Schätzung  
Signifikanztests


Quellen

Tabellen


# Auswirkungen der Stichprobengröße




Stichprobenmittel für Stichprobenumfang = 10



Theoretical Quantiles



Stichprobenmittel für Stichprobenumfang = 30



Theoretical Quantiles

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik

Grundlagen

- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests

Quellen


Tabellen

## Chi-Quadrat-Verteilung


- Sind  $X_1, \dots, X_n$  iid  $N(0; 1)$ -verteilte Zufallsvariablen, so wird die Verteilung von

$$Z = \sum_{i=1}^n X_i^2$$

als **Chi-Quadrat-Verteilung mit  $n$  Freiheitsgraden** bezeichnet.



- Kurzschreibweise:  $Z \sim \chi^2(n)$
- **Beispiel:**  $\chi^2(30): x_{0,975} = 46,98$



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik


Grundlagen

- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests

Quellen

Tabellen

# Quantiltabelle der $\chi^2$ -Verteilung mit n Freiheitsgraden



$\alpha \setminus n$	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0.005	0.00	0.01	0.07	0.21	0.41	0.68	0.99	1.34	1.73	2.16	2.60	3.07	3.56	4.07	4.60
0.01	0.00	0.02	0.11	0.30	0.55	0.87	1.24	1.65	2.09	2.56	3.05	3.57	4.11	4.66	5.23
0.025	0.00	0.05	0.22	0.48	0.83	1.24	1.69	2.18	2.70	3.25	3.82	4.40	5.01	5.63	6.26
0.05	0.00	0.10	0.35	0.71	1.15	1.64	2.17	2.73	3.33	3.94	4.57	5.23	5.89	6.57	7.26
0.1	0.02	0.21	0.58	1.06	1.61	2.20	2.83	3.49	4.17	4.87	5.58	6.30	7.04	7.79	8.55
0.2	0.06	0.45	1.01	1.65	2.34	3.07	3.82	4.59	5.38	6.18	6.99	7.81	8.63	9.47	10.31
0.25	0.10	0.58	1.21	1.92	2.67	3.45	4.25	5.07	5.90	6.74	7.58	8.44	9.30	10.17	11.04
0.4	0.28	1.02	1.87	2.75	3.66	4.57	5.49	6.42	7.36	8.30	9.24	10.18	11.13	12.08	13.03
0.5	0.45	1.39	2.37	3.36	4.35	5.35	6.35	7.34	8.34	9.34	10.34	11.34	12.34	13.34	14.34
0.6	0.71	1.83	2.95	4.04	5.13	6.21	7.28	8.35	9.41	10.47	11.53	12.58	13.64	14.69	15.73
0.75	1.32	2.77	4.11	5.39	6.63	7.84	9.04	10.22	11.39	12.55	13.70	14.85	15.98	17.12	18.25
0.8	1.64	3.22	4.64	5.99	7.29	8.56	9.80	11.03	12.24	13.44	14.63	15.81	16.98	18.15	19.31
0.9	2.71	4.61	6.25	7.78	9.24	10.64	12.02	13.36	14.68	15.99	17.27	18.55	19.81	21.06	22.31
0.95	3.84	5.99	7.81	9.49	11.07	12.59	14.07	15.51	16.92	18.31	19.68	21.03	22.36	23.68	25.00
0.975	5.02	7.38	9.35	11.14	12.83	14.45	16.01	17.53	19.02	20.48	21.92	23.34	24.74	26.12	27.49
0.99	6.63	9.21	11.34	13.28	15.09	16.81	18.48	20.09	21.67	23.21	24.73	26.22	27.69	29.14	30.58
0.995	7.88	10.60	12.84	14.86	16.75	18.55	20.28	21.95	23.59	25.19	26.76	28.30	29.82	31.32	32.80


$\alpha \setminus n$	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
0.005	5.14	5.70	6.26	6.84	7.43	8.03	8.64	9.26	9.89	10.52	11.16	11.81	12.46	13.12	13.79
0.01	5.81	6.41	7.01	7.63	8.26	8.90	9.54	10.20	10.86	11.52	12.20	12.88	13.56	14.26	14.95
0.025	6.91	7.56	8.23	8.91	9.59	10.28	10.98	11.69	12.40	13.12	13.84	14.57	15.31	16.05	16.79
0.05	7.96	8.67	9.39	10.12	10.85	11.59	12.34	13.09	13.85	14.61	15.38	16.15	16.93	17.71	18.49
0.1	9.31	10.09	10.86	11.65	12.44	13.24	14.04	14.85	15.66	16.47	17.29	18.11	18.94	19.77	20.60
0.2	11.15	12.00	12.86	13.72	14.58	15.44	16.31	17.19	18.06	18.94	19.82	20.70	21.59	22.48	23.36
0.25	11.91	12.79	13.68	14.56	15.45	16.34	17.24	18.14	19.04	19.94	20.84	21.75	22.66	23.57	24.48
0.4	13.98	14.94	15.89	16.85	17.81	18.77	19.73	20.69	21.65	22.62	23.58	24.54	25.51	26.48	27.44
0.5	15.34	16.34	17.34	18.34	19.34	20.34	21.34	22.34	23.34	24.34	25.34	26.34	27.34	28.34	29.34
0.6	16.78	17.82	18.87	19.91	20.95	21.99	23.03	24.07	25.11	26.14	27.18	28.21	29.25	30.28	31.32
0.75	19.37	20.49	21.60	22.72	23.83	24.93	26.04	27.14	28.24	29.34	30.43	31.53	32.62	33.71	34.80
0.8	20.47	21.61	22.76	23.90	25.04	26.17	27.30	28.43	29.55	30.68	31.79	32.91	34.03	35.14	36.25
0.9	23.54	24.77	25.99	27.20	28.41	29.62	30.81	32.01	33.20	34.38	35.56	36.74	37.92	39.09	40.26
0.95	26.30	27.59	28.87	30.14	31.41	32.67	33.92	35.17	36.41	37.65	38.89	40.11	41.34	42.56	43.77
0.975	28.85	30.19	31.53	32.85	34.17	35.48	36.78	38.08	39.36	40.65	41.92	43.19	44.46	45.72	46.98
0.99	32.00	33.41	34.81	36.19	37.57	38.93	40.29	41.64	42.98	44.31	45.64	46.96	48.28	49.59	50.89
0.995	34.27	35.72	37.16	38.58	40.00	41.40	42.80	44.18	45.56	46.93	48.29	49.64	50.99	52.34	53.67

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

- Grundlagen
- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests

## Quellen

## Tabellen



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik

Grundlagen

- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests

Quellen

Tabellen


- ▶ Ist  $X \sim N(0; 1)$ ,  $Z \sim \chi^2(n)$ ,  $X$ ,  $Z$  unabhängig, so wird die Verteilung von

$$T = \frac{X}{\sqrt{\frac{1}{n} Z}}$$

als **t-Verteilung** mit  $n$  Freiheitsgraden bezeichnet.




William Sealy Gosset  
1876 – 1937



- ▶ Kurzschreibweise:  $T \sim t(n)$
- ▶ **Beispiel:**  $t(10)$   $x_{0,6} = 0,260$ ,  $x_{0,5} = 0$ ,  $x_{0,1} = -x_{0,9} = -1,372$

# Quantilstabelle der t-Verteilung mit n Freiheitsgraden

$\alpha \setminus n$	0.6	0.75	0.8	0.9	0.95	0.975	0.99	0.995
1	0.325	1.000	1.376	3.078	6.314	12.706	31.820	63.657
2	0.289	0.816	1.061	1.886	2.920	4.303	6.965	9.925
3	0.277	0.765	0.979	1.638	2.353	3.183	4.541	5.841
4	0.271	0.741	0.941	1.533	2.132	2.776	3.747	4.604
5	0.267	0.727	0.920	1.476	2.015	2.571	3.365	4.032
6	0.265	0.718	0.906	1.440	1.943	2.447	3.143	3.707
7	0.263	0.711	0.896	1.415	1.895	2.365	2.998	3.499
8	0.262	0.706	0.889	1.397	1.860	2.306	2.897	3.355
9	0.261	0.703	0.883	1.383	1.833	2.262	2.821	3.250
10	0.260	0.700	0.879	1.372	1.812	2.228	2.764	3.169
11	0.260	0.698	0.875	1.363	1.796	2.201	2.718	3.106
12	0.259	0.696	0.873	1.356	1.782	2.179	2.681	3.054
13	0.259	0.694	0.870	1.350	1.771	2.160	2.650	3.012
14	0.258	0.692	0.868	1.345	1.761	2.145	2.624	2.977
15	0.258	0.691	0.866	1.341	1.753	2.131	2.603	2.947
16	0.258	0.690	0.865	1.337	1.746	2.120	2.583	2.921
17	0.257	0.689	0.863	1.333	1.740	2.110	2.567	2.898
18	0.257	0.688	0.862	1.330	1.734	2.101	2.552	2.878
19	0.257	0.688	0.861	1.328	1.729	2.093	2.539	2.861
20	0.257	0.687	0.860	1.325	1.725	2.086	2.528	2.845
21	0.257	0.686	0.859	1.323	1.721	2.080	2.518	2.831
22	0.256	0.686	0.858	1.321	1.717	2.074	2.508	2.819
23	0.256	0.685	0.858	1.319	1.714	2.069	2.500	2.807
24	0.256	0.685	0.857	1.318	1.711	2.064	2.492	2.797
25	0.256	0.684	0.856	1.316	1.708	2.059	2.485	2.787
26	0.256	0.684	0.856	1.315	1.706	2.055	2.479	2.779
27	0.256	0.684	0.855	1.314	1.703	2.052	2.473	2.771
28	0.256	0.683	0.855	1.312	1.701	2.048	2.467	2.763
29	0.256	0.683	0.854	1.311	1.699	2.045	2.462	2.756
30	0.256	0.683	0.854	1.310	1.697	2.042	2.457	2.750



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik



- Grundlagen
- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests

Quellen

Tabellen

## Dichtefunktion

- ▶ t-Verteilung mit 1 (blau), 3 (grün) und 10 (lila) Freiheitsgraden
- ▶ Standardnormalverteilung (rot)




1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik

Grundlagen

- Punkt-Schätzung
- Intervall-Schätzung
- Signifikanztests

Quellen

Tabellen



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen

### Tabellen

- ▶ Ein unbekannter Parameter  $\vartheta$  der Verteilung von  $G$  soll auf Basis einer Stichprobe geschätzt werden.
- ▶ Zum Beispiel:  $\sigma$  von  $N(10; \sigma)$
- ▶ Schätzwert:  $\hat{\vartheta}$
- ▶ Vorgehen: Verwendung einer **Schätzfunktion**


$$\hat{\Theta} = g(X_1, \dots, X_n)$$

Beachte: Der Schätzwert  $\hat{\vartheta}$  ist die Realisierung der ZV (!)  $\hat{\Theta}$ .

- ▶ Frage: Welche Stichprobenfunktion ist zur Schätzung geeignet?
- ▶ Kriterien für die Beurteilung/Konstruktion von Schätzfunktionen!
- ▶ Im Folgenden: Vorliegen einer einfachen Stichprobe, d.h.  $X_1, \dots, X_n$  iid.

- ▶ Schätzen des Mittelwertes einer Grundgesamtheit
- ▶ dazu: Einfache Stichprobe vom Umfang 5
- ▶ und den beiden Stichprobenfunktionen

$$\hat{\Theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\Theta}_2 = \frac{1}{n-1} \sum_{i=1}^n X_i$$



### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen


Punkt-Schätzung

Intervall-Schätzung

Signifikanztests


### Quellen

### Tabellen



- ▶ Schätzen des Mittelwertes einer Grundgesamtheit
- ▶ dazu: Einfache Stichprobe vom Umfang 5
- ▶ und den beiden Stichprobenfunktionen

$$\hat{\Theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i, \quad \hat{\Theta}_2 = \frac{1}{n-1} \sum_{i=1}^n X_i$$




Mittelwert Grundgesamtheit = 4.53

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

Quellen

Tabellen



1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

### Quellen

### Tabellen


- Eine Schätzfunktion  $\hat{\Theta} = g(X_1, \dots, X_n)$  heißt **erwartungstreu** oder **unverzerrt** für  $\vartheta$ , wenn unabhängig vom numerischen Wert von  $\vartheta$  gilt:

$$E(\hat{\Theta}) = \vartheta$$

## Beispiel

Sind  $\hat{\Theta}_1 = \bar{X}$ ,  $\hat{\Theta}_2 = \frac{X_1 + X_n}{2}$ ,  $\hat{\Theta}_3 = \frac{1}{n-1} \sum_{i=1}^n X_i$  erwartungstreu für  $\mu$ ?

- a)  $\hat{\Theta}_1$ :  $E(\bar{X}) = \mu$   
 $\Rightarrow \hat{\Theta}_1$  ist erwartungstreu.
- b)  $\hat{\Theta}_2$ :  $E\left(\frac{X_1 + X_n}{2}\right) = \frac{1}{2}[E(X_1) + E(X_n)] = \frac{1}{2}(\mu + \mu) = \mu$   
 $\Rightarrow \hat{\Theta}_2$  ist erwartungstreu.
- c)  $\hat{\Theta}_3$ :  $E\left(\frac{1}{n-1} \sum_{i=1}^n X_i\right) = \frac{1}{n-1} \sum_{i=1}^n E(X_i) = \frac{1}{n-1} \sum_{i=1}^n \mu = \frac{n}{n-1} \mu \neq \mu$   
 $\Rightarrow \hat{\Theta}_3$  ist nicht erwartungstreu



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

### Quellen

### Tabellen

- ▶ Welche der erwartungstreuen Schätzfunktionen  $\hat{\Theta}_1, \hat{\Theta}_2$  ist „besser“?
- ▶ Von zwei erwartungstreuen Schätzfunktionen  $\hat{\Theta}_1, \hat{\Theta}_2$  für  $\vartheta$  heißt  $\hat{\Theta}_1$  **wirksamer** als  $\hat{\Theta}_2$ , wenn unabhängig vom numerischen Wert von  $\vartheta$  gilt:


$$\text{Var}(\hat{\Theta}_1) < \text{Var}(\hat{\Theta}_2)$$

**Beispiel:**  $(\hat{\Theta}_1 = \bar{X}, \hat{\Theta}_2 = \frac{X_1 + X_n}{2})$

Wegen

$$\left. \begin{aligned} \text{Var}(\hat{\Theta}_1) &= \text{Var}(\bar{X}) &&= \frac{\sigma^2}{n} \\ \text{Var}(\hat{\Theta}_2) &= \text{Var}\left(\frac{X_1 + X_n}{2}\right) = \frac{1}{4}(\sigma^2 + \sigma^2) = \frac{\sigma^2}{2} \end{aligned} \right\} \Rightarrow \text{Var}(\hat{\Theta}_1) < \text{Var}(\hat{\Theta}_2)$$

(falls  $n > 2$ ) ist  $\hat{\Theta}_1$  wirksamer als  $\hat{\Theta}_2$ .



### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen

### Tabellen


- ▶ Für einen unbekanntem Verteilungsparameter  $\vartheta$  soll auf Basis einer Stichprobe ein Intervall geschätzt werden.
- ▶ Verwendung der Stichprobenfunktionen  $V_u, V_o$ , so dass  $V_u \leq V_o$  und

$$P(V_u \leq \vartheta \leq V_o) = 1 - \alpha$$

stets gelten.

$[V_u; V_o]$  heißt **Konfidenzintervall** (KI) für  $\vartheta$  zum **Konfidenzniveau**  $1 - \alpha$ .


- ▶ Beachte: Das **Schätzintervall**  $[v_u; v_o]$  ist Realisierung der Zufallsvariablen (!)  $V_u, V_o$ .
  - ▮ Irrtumswahrscheinlichkeit  $\alpha$  (klein, i.d.R.  $\alpha \leq 0,1$ )
- ▶ Frage: Welche Konfidenzintervalle sind zur Schätzung geeignet?
  - ▮ Hängt von Verteilung von  $G$  sowie vom unbekanntem Parameter  $(\mu, \sigma^2)$  ab!
- ▶ Im Folgenden: Einfache Stichprobe  $X_1, \dots, X_n$  mit  $E(X_i) = \mu, \text{Var}(X_i) = \sigma^2$



## Wichtiger Spezialfall: **Symmetrische Konfidenzintervalle**

- ▶ Symmetrisch heißt **nicht**, dass die Dichte symmetrisch ist, sondern
- ▶ übereinstimmende Wahrscheinlichkeiten für Über-/Unterschreiten des Konfidenzintervalls, d.h.

$$P(V_u > \vartheta) = P(V_o < \vartheta) = \frac{\alpha}{2}$$




- ▶ **Wichtig:** Eine Verkleinerung von  $\alpha$  bewirkt eine Vergrößerung des Konfidenzintervalls.

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

### Quellen

### Tabellen



## Vorgehensweise:


- 1 Festlegen des Konfidenzniveaus  $1 - \alpha$
- 2 Bestimmung des  $\left(1 - \frac{\alpha}{2}\right)$ -Fraktils  $c$  der  $N(0, 1)$ -Verteilung
- 3 Berechnen des Stichprobenmittels  $\bar{x}$
- 4 Berechnen des Wertes  $\frac{\sigma c}{\sqrt{n}}$
- 5 Ergebnis der Intervall-Schätzung:

$$\left[ \bar{x} - \frac{\sigma c}{\sqrt{n}} ; \bar{x} + \frac{\sigma c}{\sqrt{n}} \right]$$

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

## Quellen

## Tabellen



## Beispiel

Normalverteilung mit  $\sigma = 2,4$

$(x_1, \dots, x_9) = (184.2, 182.6, 185.3, 184.5, 186.2, 183.9, 185.0, 187.1, 184.4)$

Gesucht: Konfidenzintervall für  $\mu$  zum Konfidenzniveau

$$1 - \alpha = 0,99$$

1.  $1 - \alpha = 0,99$
2.  $N(0; 1): c = x_{1 - \frac{\alpha}{2}} = x_{1 - \frac{0,01}{2}} = x_{0,995} = 2,576$  (Tab. 3; Interpolation)
3.  $\bar{x} = \frac{1}{9} (184,2 + \dots + 184,4) = 184,8$
4.  $\frac{\sigma c}{\sqrt{n}} = \frac{2,4 \cdot 2,576}{\sqrt{9}} = 2,06$
5.  $KI = [184,8 - 2,06; 184,8 + 2,06] = [182,74; 186,86]$

Interpretation: Mit 99 % Wahrscheinlichkeit ist  $\mu \in [182,74; 186,86]$ .

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen


Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen

### Tabellen



Wichtige  $N(0; 1)$ -Fraktilswerte:


$\alpha$	$\chi_{\alpha}$
0,9	1,281552
0,95	1,644854
0,975	1,959964
0,99	2,326348
0,995	2,575829

(I.d.R. genügen drei Nachkommastellen.)

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

Quellen

Tabellen



### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen

### Tabellen

- ▶ Bei bekannter Standardabweichung gilt offenkundig

$$L = V_o - V_u = \frac{2\sigma c}{\sqrt{n}}$$


- ▶ Welcher Stichprobenumfang  $n$  sichert eine vorgegebene (Maximal-)Länge  $L$ ?  $\Rightarrow$  Nach  $n$  auflösen!  $\Rightarrow$

$$n \geq \left( \frac{2\sigma c}{L} \right)^2$$

- ▶ Eine Halbierung von  $L$  erfordert eine Vervierfachung von  $n$ !
- ▶ Angewendet auf letztes **Beispiel**:

$$L = 4 \Rightarrow n \geq \left( \frac{2 \cdot 2,4 \cdot 2,576}{4} \right)^2 = 9,556 \Rightarrow n \geq 10$$

$$L = 2 \Rightarrow n \geq \left( \frac{2 \cdot 2,4 \cdot 2,576}{2} \right)^2 = 38,222 \Rightarrow n \geq 39$$



## Konfidenzintervall für $\mu$ bei Normalverteilung mit unbekanntem $\sigma^2$

### ► Vorgehensweise:

- 1 Festlegen des Konfidenzniveaus  $1 - \alpha$
- 2 Bestimmung des  $\left(1 - \frac{\alpha}{2}\right)$ -Fraktils  $c$  der  $t(n - 1)$ -Verteilung
- 3 Berechnen des Stichprobenmittels  $\bar{x}$  und der Stichproben-Standardabweichung  $s$
- 4 Berechnen des Wertes  $\frac{sc}{\sqrt{n}}$
- 5 Ergebnis der Intervall-Schätzung:

$$\left[ \bar{x} - \frac{sc}{\sqrt{n}} ; \bar{x} + \frac{sc}{\sqrt{n}} \right]$$

- Zu Schritt 2: Falls  $n - 1 > 30$  wird die  $N(0; 1)$ -Verteilung verwendet.

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen


Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen

### Tabellen



## Beispiel:

Wie das letzte Beispiel, jedoch  $\sigma$  unbekannt.

- 1  $1 - \alpha = 0,99$
- 2  $t(8): c = x_{1-\frac{\alpha}{2}} = x_{1-\frac{0,01}{2}} = x_{0,995} = 3,355$  (Tab. 4)
- 3  $\bar{x} = \frac{1}{9} (184,2 + \dots + 184,4) = 184,8$   
 $s = \sqrt{\frac{1}{8} [(184,2^2 + \dots + 184,4^2) - 9 \cdot 184,8^2]} = 1,31$
- 4  $\frac{sc}{\sqrt{n}} = \frac{1,31 \cdot 3,355}{\sqrt{9}} = 1,47$
- 5  $KI = [184,8 - 1,47; 184,8 + 1,47] = [183,33; 186,27]$

Interpretation: Mit 99 % Wahrscheinlichkeit ist  $\mu \in [183,33; 186,27]$ .

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen


Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen

### Tabellen




```
x <- c(184.2, 182.6, 185.3, 184.5, 186.2,  
       183.9, 185.0, 187.1, 184.4)  
t.test(x, conf.level=.99)  
  
##  
## One Sample t-test  
##  
## data: x  
## t = 422.1129, df = 8, p-value < 2.2e-16  
## alternative hypothesis: true mean is not equal to 0  
## 99 percent confidence interval:  
## 183.331 186.269  
## sample estimates:  
## mean of x  
## 184.8
```

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

### Quellen

### Tabellen

# Konfidenzintervall für $\mu$ bei beliebiger Verteilung



► Voraussetzung:  $n > 30$ , bzw. falls G dichotom:  $5 \leq \sum_{i=1}^n x_i \leq n - 5$

► Vorgehensweise:

- 1 Festlegen des Konfidenzniveaus  $1 - \alpha$
- 2 Bestimmung des  $(1 - \frac{\alpha}{2})$ -Fraktils  $c$  der Standardnormalverteilung  $N(0; 1)$
- 3 Berechnung des Stichprobenmittels  $\bar{x}$  sowie eines Schätzwertes  $\hat{\sigma}$  für die Standardabweichung  $\sigma$  der GG mittels

$$\hat{\sigma} = \begin{cases} \sigma, & \text{falls } \sigma \text{ bekannt} \\ \sqrt{\bar{x}(1 - \bar{x})}, & \text{falls GG dichotom} \\ s, & \text{sonst} \end{cases}$$

- 4 Berechnung von  $\frac{\hat{\sigma}c}{\sqrt{n}}$
- 5 Ergebnis der Intervallschätzung:


$$\left[ \bar{x} - \frac{\hat{\sigma}c}{\sqrt{n}}; \bar{x} + \frac{\hat{\sigma}c}{\sqrt{n}} \right]$$

► Zu Schritt 3: Manchmal kann anderer Schätzwert  $\hat{\sigma}$  sinnvoller sein.

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

## Quellen

## Tabellen



## Beispiel:

Poisson-Verteilung mit  $\lambda$  ( $= \mu = \sigma^2$ ) unbekannt.

$(x_1, \dots, x_{40}) = (3; 8; \dots; 6)$

Gesucht: KI für  $\lambda$  zum Konfidenzniveau  $1 - \alpha = 0,9$

①  $1 - \alpha = 0,9$

②  $N(0; 1) : c = x_{1 - \frac{\alpha}{2}} = x_{1 - \frac{0,1}{2}} = x_{0,95} = 1,645$

③  $\bar{x} = \frac{1}{40} (3 + 8 + \dots + 6) = 6,5$   
 $\hat{\sigma} = \sqrt{\bar{x}} = \sqrt{6,5} = 2,55$  (da  $\sigma^2 = \lambda$ )

④  $\frac{\hat{\sigma}c}{\sqrt{n}} = \frac{2,55 \cdot 1,645}{\sqrt{40}} = 0,66$

⑤  $KI = [6,5 - 0,66; 6,5 + 0,66] = [5,84; 7,16]$

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen


Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen

### Tabellen



## Vorgehensweise

- 1 Festlegen eines Konfidenzniveaus  $1 - \alpha$
- 2 Bestimmung der  $\frac{\alpha}{2}$ - bzw.  $(1 - \frac{\alpha}{2})$ -Fraktile ( $c_1$  bzw.  $c_2$ ) der  $\chi^2(n - 1)$ -Verteilung
- 3 Aus der Stichprobe: Berechnung der Größe

$$(n - 1)s^2 = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - n\bar{x}^2$$


- 4 Berechnung des Konfidenzintervalls

$$\left[ \frac{(n - 1)s^2}{c_2}; \frac{(n - 1)s^2}{c_1} \right]$$

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

### Quellen

### Tabellen



## Beispiel:

$$G \sim N(\mu; \sigma);$$

$$(x_1, \dots, x_5) = (1, 1.5, 2.5, 3, 2)$$

Gesucht: KI für  $\sigma^2$  zum Konfidenzniveau  $1 - \alpha = 0,99$

①  $1 - \alpha = 0,99$

②  $\chi^2(5 - 1) : c_1 = \chi_{\frac{\alpha}{2}} = \chi_{0,005} = 0,21$

$$c_2 = \chi_{1 - \frac{\alpha}{2}} = \chi_{0,995} = 14,86$$

③  $\bar{x} = \frac{1}{5} (1 + 1,5 + 2,5 + 3 + 2) = 2$

$$\sum_{i=1}^5 x_i^2 - 5 \cdot \bar{x}^2 = 1^2 + 1,5^2 + 2,5^2 + 3^2 + 2^2 - 5 \cdot 2^2 = 2,5$$

④  $KI = \left[ \frac{2,5}{14,86}; \frac{2,5}{0,21} \right] = [0,17; 11,9]$

(Extrem groß, da  $n$  klein.)

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen


Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen

### Tabellen



### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen

Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen


### Tabellen

- ▶ Vorliegen einer **Hypothese** über die Verteilung(en) der Grundgesamtheit(en).
- ▶ Beispiele:
  - „Der Würfel ist fair.“
  - „Die Brenndauern zweier unterschiedlicher Glühbirnensorten sind gleich.“
- ▶ Hypothese soll anhand einer Stichprobe überprüft werden.
- ▶ Prinzip:
  - **Hypothese verwerfen**, wenn „signifikanter“ Widerspruch zur Stichprobe.
  - Ansonsten: **Hypothese nicht verwerfen**.
- ▶ Eine verworfene Hypothese gilt als statistisch widerlegt.
- ▶ Nicht-Verwerfung ist dagegen ein „Freispruch aus Mangel an Beweisen“.

## Zu Beachten:

Nicht-Verwerfung ist **kein** „statistischer Beweis“, dass Hypothese wahr ist!  
(„Trick“: Hypothese falsch  $\iff$  Gegenhypothese wahr!)

# Test des Erwartungswertes bei bekannter Varianz in der Grundgesamtheit



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

## Quellen

## Tabellen

### ► Zunächst:

- $G \sim N(\mu; \sigma)$  mit  $\sigma$  bekannt
- Einfache Stichprobe  $X_1, \dots, X_n$
- (Null-)Hypothese  $H_0 : \mu = \mu_0$

### ► Beispiel:

$X_1, \dots, X_{25}$  mit  $X_i =$  Füllmenge der  $i$ -ten Flasche  $\sim N(\mu; 1,5)$

**Nullhypothese**  $H_0 : \mu = 500$ , d.h.  $\mu_0 = 500$


### ► Je nach Interessenlage sind unterschiedliche **Gegenhypothesen** möglich:

- a)  $H_1 : \mu \neq \mu_0$
- b)  $H_1 : \mu < \mu_0$
- c)  $H_1 : \mu > \mu_0$

### ► Entscheidung:

- $H_0 : \mu = \mu_0$  wird abgelehnt gegenüber
  - a)  $H_1 : \mu \neq \mu_0$ , wenn  $|\bar{x} - \mu_0|$  „sehr groß“ ist
  - b)  $H_1 : \mu < \mu_0$ , wenn  $\bar{x}$  „weit kleiner“ als  $\mu_0$  ist
  - c)  $H_1 : \mu > \mu_0$ , wenn  $\bar{x}$  „weit größer“ als  $\mu_0$  ist

# Test des Erwartungswertes bei bekannter Varianz in der Grundgesamtheit



## Entscheidungskriterium aus Stichprobe:

$$v = \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n}$$

▶ Vorteil: Verteilung bekannt:  $N(0; 1)$


▶ Dann:

$H_0 : \mu = \mu_0$  wird abgelehnt gegenüber

- a)  $H_1 : \mu \neq \mu_0$ , wenn  $|v|$  „sehr groß“ ist
- b)  $H_1 : \mu < \mu_0$ , wenn  $v$  „sehr negativ“ ist
- c)  $H_1 : \mu > \mu_0$ , wenn  $v$  „sehr positiv“ ist

## Mögliche Fehlentscheidungen

- ▶ **Ablehnung von  $H_0$** , obwohl  $H_0$  richtig ist: **Fehler 1. Art**
- ▶ **Nicht-Ablehnung von  $H_0$** , obwohl  $H_0$  falsch ist: **Fehler 2. Art**




- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

## Quellen

## Tabellen

▶ **Signifikanzniveau  $\alpha$** : Maximal erlaubte Wahrscheinlichkeit für einen Fehler 1. Art.

# Test des Erwartungswertes bei bekannter Varianz in der Grundgesamtheit



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

Quellen

Tabellen

- ▶ Mithilfe von  $\alpha$  und  $V$  kann geklärt werden, was „sehr groß“ usw. heißt:

Wahrscheinlichkeit für Fehler 1. Art im Fall

a):  $|v| > x$ , obwohl  $H_0$  richtig:


$$\begin{aligned} P(|V| > x) &= P(V > x) + P(V < -x) \\ &= 2 \cdot P(V > x) \quad (\text{Symmetrie der Normalverteilung}) \\ &= 2 \cdot [1 - P(V \leq x)] = 2 \cdot [1 - \Phi(x)] \stackrel{!}{=} \alpha \\ &\iff \Phi(x) = 1 - \frac{\alpha}{2} \\ &\iff x = x_{1 - \frac{\alpha}{2}} \end{aligned}$$

$H_0$  wird demnach verworfen,

wenn  $|v| > x_{1 - \frac{\alpha}{2}}$  bzw.  $v \in B$  ist.

$B = (-\infty; -x_{1 - \frac{\alpha}{2}}) \cup (x_{1 - \frac{\alpha}{2}}; \infty)$  heißt **Verwerfungsbereich**.

- ▶ Analoge Vorgehensweise für die Fälle b) und c)



## Rezept

- 1 Ein Signifikanzniveau  $\alpha$  wird festgelegt.
- 2 Der Verwerfungsbereich

$$B = (-\infty; -x_{1-\alpha/2}) \cup (x_{1-\alpha/2}; \infty) \quad \text{im Fall a)}$$

$$B = (-\infty; -x_{1-\alpha}) \quad \text{im Fall b)}$$

$$B = (x_{1-\alpha}; \infty) \quad \text{im Fall c)}$$

wird festgelegt, wobei  $x_{1-\alpha/2}$  bzw.  $x_{1-\alpha}$  das  $(1 - \alpha/2)$ - bzw. das  $(1 - \alpha)$ -Fraktile der  $N(0,1)$ -Verteilung ist. (**Wichtig**: Der Ablehnungsbereich ist also unabhängig von der Stichprobe)

- 3 **Wichtig**: Erst jetzt werden die Daten der Stichprobe erhoben/beachtet:

Der Testfunktionswert  $v = \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n}$  wird berechnet.

- 4  $H_0$  wird genau dann verworfen, wenn  $v \in B$  gilt.

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen


Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen

### Tabellen



## Beispiel:

$X_1, \dots, X_{25}$  mit  $X_i \sim N(\mu; 1,5)$  und  $\bar{x} = 499,28$

Prüfe  $H_0 : \mu = 500$ ,  $H_1 : \mu \neq 500$  zum Signifikanzniveau  $\alpha = 0,01$

## Lösung: Einstichproben-Gaußtest, Fall a)

- 1  $\alpha = 0,01$
- 2  $N(0; 1) : x_{1-\frac{\alpha}{2}} = x_{1-0,005} = x_{0,995} = 2,576$   
 $\Rightarrow B = (-\infty; -2,576) \cup (2,576; \infty)$
- 3  $v = \frac{499,28-500}{1,5} \cdot \sqrt{25} = -2,4$
- 4  $v \notin B \Rightarrow H_0$  nicht verwerfen

Interpretation: Zum Signifikanzniveau 1 % kann der Brauerei keine Abweichung vom Sollwert  $\mu_0 = 500$  nachgewiesen werden.

### 1. Einführung

### 2. Deskriptive Statistik

### 3. W-Theorie

### 4. Induktive Statistik

Grundlagen


Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

### Quellen

### Tabellen



## Gegeben:

- ▶ Einfache Stichprobe  $X_1, \dots, X_n$  mit
- ▶  $E(X_i) = \mu$ ,  $\text{Var}(X_i) = \sigma^2$

## Hypothesenpaare:

- a)  $H_0 : \mu = \mu_0$   $H_1 : \mu \neq \mu_0$
- b)  $H_0 : \mu = \mu_0$  (oder  $\mu \geq \mu_0$ ),  $H_1 : \mu < \mu_0$
- c)  $H_0 : \mu = \mu_0$  (oder  $\mu \leq \mu_0$ ),  $H_1 : \mu > \mu_0$


## Voraussetzungen:

- 1 Normalverteilung mit  $\sigma$  unbekannt (**Einstichproben-t-Test**)  
oder
- 2 Beliebige Verteilung  
mit  $n > 30$  bzw.  $5 \leq \sum x_i \leq n - 5$  (bei  $B(1; p)$ )  
(**approximativer Gaußtest**)

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

## Quellen

## Tabellen



## Ablauf:

- 1 Festlegen des **Signifikanzniveaus**  $\alpha$
- 2 Festlegen des **Verwerfungsbereichs**  $B$ :

- Falls  $H_1 : \mu \neq \mu_0$ :  $B = (-\infty; -x_{1-\alpha/2}) \cup (x_{1-\alpha/2}; \infty)$
- Falls  $H_1 : \mu < \mu_0$ :  $B = (-\infty; -x_{1-\alpha})$
- Falls  $H_1 : \mu > \mu_0$ :  $B = (x_{1-\alpha}; \infty)$

Dabei steht  $x_{1-\alpha/2}$  bzw.  $x_{1-\alpha}$  für das jeweilige Fraktile

- der  $t(n-1)$ -Verteilung bei  $n \leq 29$  bzw.
- der  $N(0; 1)$ -Verteilung bei  $n \geq 30$ .


- 3 Berechnen des **Testfunktionswertes**:

$$v = \begin{cases} \frac{\bar{x} - \mu_0}{s} \sqrt{n} & \text{falls Grundgesamtheit } N(\mu; \sigma)\text{-verteilt, } \sigma \text{ unbekannt} \\ & \text{oder falls Verteilung der GG beliebig, } n > 30, \sigma \text{ unbekannt} \\ \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n} & \text{falls Verteilung der GG beliebig, } n > 30, \sigma \text{ bekannt} \\ \frac{\bar{x} - \mu_0}{\sqrt{\mu_0(1 - \mu_0)}} \sqrt{n} & \text{falls GG gemäß } B(1; \mu)\text{-verteilt, } n > 30 \end{cases}$$

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

## Quellen

## Tabellen



## Beispiel t-Test: Energieaufnahme von Frauen

- ▶ Empfohlene täglich Energieaufnahme für Frauen: 7724 kJ (1845 kcal)
- ▶ Nehme einfache Stichprobe von 11 Frauen und teste zum Signifikanzniveau  $\alpha = 0,05$  für
- ▶  $H_0$ : „Der Erwartungswert der täglichen Energieaufnahme für Frauen ist 7724 kJ“ ( $\mu_0$ )
- ▶ gegen  $H_1: \mu \neq \mu_0$

```
daily.intake <- c(5260, 5470, 5640, 6180, 6390, 6515, 6805, 7515, 7515, 8230, 8770)
t.test(daily.intake, alternative="two.sided", mu=7724, conf.level=0.95)
```


```
##
## One Sample t-test
##
## data:  daily.intake
## t = -2.8179, df = 10, p-value = 0.01823
## alternative hypothesis: true mean is not equal to 7724
## 95 percent confidence interval:
##  5986.348 7520.925
## sample estimates:
## mean of x
##  6753.636
```

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik

Grundlagen  
Punkt-Schätzung  
Intervall-Schätzung  
Signifikanztests

## Quellen

## Tabellen



## Beispiel t-Test: Energieaufnahme von Frauen

- ▶ Empfohlene täglich Energieaufnahme für Frauen: 7724 kJ (1845 kcal)
- ▶ Nehme einfache Stichprobe von 11 Frauen und teste zum Signifikanzniveau  $\alpha = 0,05$  für
- ▶  $H_0$ : „Der Erwartungswert der täglichen Energieaufnahme für Frauen ist 7724 kJ“ ( $\mu_0$ )
- ▶ gegen  $H_1: \mu \neq \mu_0$

```
daily.intake <- c(5260, 5470, 5640, 6180, 6390, 6515, 6805, 7515, 7515, 8230, 8770)
t.test(daily.intake, alternative="two.sided", mu=7724, conf.level=0.95)
```

```
##
## One Sample t-test
##
## data:  daily.intake
## t = -2.8179, df = 10, p-value = 0.01823
## alternative hypothesis: true mean is not equal to 7724
## 95 percent confidence interval:
##  5986.348 7520.925
## sample estimates:
## mean of x
##  6753.636
```

1. Einführung
2. Deskriptive Statistik
3. W-Theorie
4. Induktive Statistik

Grundlagen  
Punkt-Schätzung  
Intervall-Schätzung  
Signifikanztests

## Quellen

## Tabellen

### Beispiel:

$X_1, \dots, X_{2000} \sim B(1; p)$  mit

$$X_i = \begin{cases} 1, & \text{falls } i\text{-te Person Wähler einer bestimmten Partei} \\ 0, & \text{sonst} \end{cases}$$

Ergebnis der Stichprobe:  $\sum_{i=1}^{2000} x_i = 108$


Prüfe  $H_0 : p \leq 0,05$  gegen  $H_1 : p > 0,05$  zum Signifikanzniveau 2 %

### Lösung:

**approximativer Gaußtest** bei dichotomer (zweiwertiger) Verteilung; Voraussetzung 2 erfüllt:  $5 \leq 108 \leq 2000 - 5$

- 1  $\alpha = 0,02$
- 2  $N(0; 1) : x_{1-\alpha} = x_{0,98} = 2,05$  (Tabelle)  $\Rightarrow B = (2,05; \infty)$
- 3  $v = \frac{\frac{108}{2000} - 0,05}{\sqrt{0,05 \cdot (1-0,05)}} \sqrt{2000} = 0,82$
- 4  $v \notin B \Rightarrow H_0$  nicht verwerfen

**Zusatzfrage:** Entscheidung, falls  $\alpha = 0,01$ ?  $\rightarrow$  Keine Änderung!




- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

### Quellen

### Tabellen





**Beispiel:**  $G \sim N(\mu; \sigma)$

$(x_1, \dots, x_{10}) = (2100; 2130; 2150; 2170; 2210; 2070; 2230; 2150; 2230; 2200)$

Prüfe  $H_0 : \sigma = 40$ ,  $H_1 : \sigma \neq 40$  zum Signifikanzniveau  $\alpha = 0,1$

**Lösung:**  $\chi^2$ -Test für die Varianz, Hypothese Fall a);  
Voraussetzungen sind erfüllt

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

### Quellen

### Tabellen

①  $\alpha = 0,1$


②  $\chi^2(9) : x_{\frac{\alpha}{2}} = x_{0,05} = 3,33; x_{1-\frac{\alpha}{2}} = x_{0,95} = 16,92$   
(Tabelle der  $\chi^2$ -Verteilung)

$$\Rightarrow B = [0; 3,33) \cup (16,92; \infty)$$

③  $\bar{x} = \frac{1}{10} (2100 + 2130 + \dots + 2200) = 2164$

$$v = \frac{1}{40^2} [(2100 - 2164)^2 + \dots + (2200 - 2164)^2] = 16,65$$

$\Rightarrow v \notin B \Rightarrow H_0$  nicht verwerfen



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

Quellen

Tabellen


- ▶ Situation: In Grundgesamtheit G: **Zwei verbundene einfache Stichproben**, also Beobachtung **zweier Merkmale X, Y**
- ▶ Hypothese:

$H_0$  : Die beiden Merkmale X und Y sind in G **unabhängig**.  
 $H_1$  : X und Y sind in G abhängig.

## Vorgehensweise Kontingenztest:

- 1 Festlegen des **Signifikanzniveaus**  $\alpha$ .
- 2 Unterteilung der x-Achse in  $k \geq 2$  und die y-Achse in  $l \geq 2$  disjunkte, aneinander angrenzende Intervalle  $A_1, \dots, A_k$  bzw.  $B_1, \dots, B_l$
- 3 Erstellen einer Kontingenztafel mit Randhäufigkeiten:

$x \downarrow y \rightarrow$	$B_1$	$B_2$	$\dots$	$B_l$	
$A_1$	$h_{11}$	$h_{12}$	$\dots$	$h_{1l}$	$h_{1\bullet}$
$A_2$	$h_{21}$	$h_{22}$	$\dots$	$h_{2l}$	$h_{2\bullet}$
$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$	
$A_k$	$h_{k1}$	$h_{k2}$	$\dots$	$h_{kl}$	$h_{k\bullet}$
	$h_{\bullet 1}$	$h_{\bullet 2}$	$\dots$	$h_{\bullet l}$	$n$



## Vorgehensweise Kontingenztest (Fortsetzung):

- 4 Mit dem Fraktilswert  $x_{1-\alpha}$  der  $\chi^2$ -Verteilung mit  $(k - 1) \cdot (l - 1)$  Freiheitsgraden: Berechnung des **Verwerfungsbereichs**

$$B = (x_{1-\alpha}; \infty)$$

- 5 Zu jeder Kombination aus  $i = 1, \dots, k$  und  $j = 1, \dots, l$ : Berechnung der Größe

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

- 6 Berechnung des **Testfunktionswerts**  $v$ :

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

- 7 **Ablehnung** von  $H_0$  genau dann, wenn  $v \in B$ .

1. Einführung

2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Grundlagen


Punkt-Schätzung

Intervall-Schätzung

Signifikanztests

Quellen

Tabellen



## Kontingenztest: Beispiel

- ▶ 400 Erstkandidaten einer praktischen Führerscheinprüfung schneiden abhängig von der besuchten Fahrschule folgendermaßen ab:

	Fahrschule		
	A	B	C
bestanden	130	88	62
durchgefallen	70	38	12

- ▶ Zum Signifikanzniveau von 5 % soll getestet werden, ob das Bestehen der Prüfung unabhängig von der besuchten Fahrschule ist.

- 4  $\chi^2$ -Verteilung mit  $(3 - 1) \cdot (2 - 1) = 2$  Freiheitsgraden:  
 $\alpha_{1-0,05} = \alpha_{0,95} = 5,99$ :

$$B = (5,99; \infty)$$

- 5 Berechnung der  $\tilde{h}_{ij}$ :

	A	B	C
best.	140	88,2	51,8
durchg.	60	37,8	22,2

- 6 
$$v = \frac{(140 - 130)^2}{130} + \dots$$

$$+ \frac{(22,2 - 12)^2}{12}$$

$$\approx 9,077$$

- 7  $v \in B$ : Also wird  $H_0$  abgelehnt, die Prüfungsergebnisse sind abhängig von der Fahrschule.

## Testdurchführung

- 1 Signifikanzniveau  $\alpha = 5 \%$
- 2 entfällt, da Skalenniveau nominal
- 3 Kontingenztafel:

	A	B	C	$\Sigma$
best.	130	88	62	280
durchg.	70	38	12	120
$\Sigma$	200	126	74	400

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik
  - Grundlagen
  - Punkt-Schätzung
  - Intervall-Schätzung
  - Signifikanztests

- Quellen
- Tabellen



## Bücher

-  Bamberg, Günter, Franz Baur und Michael Krapp (2011). **Statistik**. 16. Aufl. München: Oldenbourg Verlag. ISBN: 3486702580.
-  Dalgaard, Peter (2002). **Introductory Statistics with R**. New York: Springer.
-  Fahrmeir, Ludwig, Rita Künstler, Iris Pigeot und Gerhard Tutz (2009). **Statistik: Der Weg zur Datenanalyse**. 7. Aufl. Berlin, Heidelberg: Springer. ISBN: 3642019382.

1. Einführung


2. Deskriptive Statistik

3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen



## Quellen zu Bildern und Daten



Anscombe, Francis (1973). „Graphs in Statistical Analysis“. In: **The American Statistician**, S. 195–199.



Bach, Axel, Reinhard Brüning, Katrin Kriefft, Hilmar Liebsch und Martin Rosenberg (2006). **Mit Zahlen lügen**. URL: [http://www.wdr.de/tv/quarks/sendungsbeitraege/2006/1017/000\\_zahlen.jsp](http://www.wdr.de/tv/quarks/sendungsbeitraege/2006/1017/000_zahlen.jsp).



Fahrmeir, Ludwig, Rita Künstler, Iris Pigeot und Gerhard Tutz (2009). **Statistik: Der Weg zur Datenanalyse**. 7. Aufl. Berlin, Heidelberg: Springer. ISBN: 3642019382.



Kramer, Walter (2011). **So lügt man mit Statistik**. Piper Verlag. ISBN: 3492264131.

1. Einführung

2. Deskriptive Statistik


3. W-Theorie

4. Induktive Statistik

Quellen

Tabellen

# Binomialverteilung $X \sim B(n; p)$ , Verteilungsfunktion $F(x) = P(X \leq x)$



$n = 2$

$\downarrow x \quad p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9801	0.9604	0.9409	0.9216	0.9025	0.8836	0.8649	0.8464	0.8281	0.8100	0.6400	0.5625	0.4900	0.3600	0.2500
1	0.9999	0.9996	0.9991	0.9984	0.9975	0.9964	0.9951	0.9936	0.9919	0.9900	0.9600	0.9375	0.9100	0.8400	0.7500

$n = 3$

$\downarrow x \quad p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9703	0.9412	0.9127	0.8847	0.8574	0.8306	0.8044	0.7787	0.7536	0.7290	0.5120	0.4219	0.3430	0.2160	0.1250
1	0.9997	0.9988	0.9974	0.9953	0.9928	0.9896	0.9860	0.9818	0.9772	0.9720	0.8960	0.8438	0.7840	0.6480	0.5000
2	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998	0.9997	0.9995	0.9993	0.9990	0.9920	0.9844	0.9730	0.9360	0.8750

$n = 4$

$\downarrow x \quad p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9606	0.9224	0.8853	0.8493	0.8145	0.7807	0.7481	0.7164	0.6857	0.6561	0.4096	0.3164	0.2401	0.1296	0.0625
1	0.9994	0.9977	0.9948	0.9909	0.9860	0.9801	0.9733	0.9656	0.9570	0.9477	0.8192	0.7383	0.6517	0.4752	0.3125
2	1.0000	1.0000	0.9999	0.9998	0.9995	0.9992	0.9987	0.9981	0.9973	0.9963	0.9728	0.9492	0.9163	0.8208	0.6875
3	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9984	0.9961	0.9919	0.9744	0.9375

$n = 5$

$\downarrow x \quad p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9510	0.9039	0.8587	0.8154	0.7738	0.7339	0.6957	0.6591	0.6240	0.5905	0.3277	0.2373	0.1681	0.0778	0.0313
1	0.9990	0.9962	0.9915	0.9852	0.9774	0.9681	0.9575	0.9456	0.9326	0.9185	0.7373	0.6328	0.5282	0.3370	0.1875
2	1.0000	0.9999	0.9997	0.9994	0.9988	0.9980	0.9969	0.9955	0.9937	0.9914	0.9421	0.8965	0.8369	0.6826	0.5000
3	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998	0.9997	0.9995	0.9933	0.9844	0.9692	0.9130	0.8125
4	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9990	0.9976	0.9898	0.9688


- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

Quellen

Tabellen

- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung

# Binomialverteilung $X \sim B(n; p)$ , Verteilungsfunktion $F(x) = P(X \leq x)$



$n = 6$

$\downarrow x \quad p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9415	0.8858	0.8330	0.7828	0.7351	0.6899	0.6470	0.6064	0.5679	0.5314	0.2621	0.1780	0.1176	0.0467	0.0156
1	0.9985	0.9943	0.9875	0.9784	0.9672	0.9541	0.9392	0.9227	0.9048	0.8857	0.6554	0.5339	0.4202	0.2333	0.1094
2	1.0000	0.9998	0.9995	0.9988	0.9978	0.9962	0.9942	0.9915	0.9882	0.9842	0.9011	0.8306	0.7443	0.5443	0.3438
3	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9997	0.9995	0.9992	0.9987	0.9830	0.9624	0.9295	0.8208	0.6563
4	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9984	0.9954	0.9891	0.9590	0.8906
5	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9993	0.9959	0.9844

$n = 7$

$\downarrow x \quad p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9321	0.8681	0.8080	0.7514	0.6983	0.6485	0.6017	0.5578	0.5168	0.4783	0.2097	0.1335	0.0824	0.0280	0.0078
1	0.9980	0.9921	0.9829	0.9706	0.9556	0.9382	0.9187	0.8974	0.8745	0.8503	0.5767	0.4449	0.3294	0.1586	0.0625
2	1.0000	0.9997	0.9991	0.9980	0.9962	0.9937	0.9903	0.9860	0.9807	0.9743	0.8520	0.7564	0.6471	0.4199	0.2266
3	1.0000	1.0000	1.0000	0.9999	0.9998	0.9996	0.9993	0.9988	0.9982	0.9973	0.9667	0.9294	0.8740	0.7102	0.5000
4	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998	0.9953	0.9871	0.9712	0.9037	0.7734
5	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9996	0.9987	0.9962	0.9812	0.9375
6	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9984	0.9922

$n = 8$

$\downarrow x \quad p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9227	0.8508	0.7837	0.7214	0.6634	0.6096	0.5596	0.5132	0.4703	0.4305	0.1678	0.1001	0.0576	0.0168	0.0039
1	0.9973	0.9897	0.9777	0.9619	0.9428	0.9208	0.8965	0.8702	0.8423	0.8131	0.5033	0.3671	0.2553	0.1064	0.0352
2	0.9999	0.9996	0.9987	0.9969	0.9942	0.9904	0.9853	0.9789	0.9711	0.9619	0.7969	0.6785	0.5518	0.3154	0.1445
3	1.0000	1.0000	0.9999	0.9998	0.9996	0.9993	0.9987	0.9978	0.9966	0.9950	0.9437	0.8862	0.8059	0.5941	0.3633
4	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9997	0.9996	0.9896	0.9727	0.9420	0.8263	0.6367
5	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9988	0.9958	0.9887	0.9502	0.8555
6	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9996	0.9987	0.9915	0.9648
7	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9993	0.9961


- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

## Quellen

## Tabellen

- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung

# Binomialverteilung $X \sim B(n; p)$ , Verteilungsfunktion $F(x) = P(X \leq x)$



$n = 9$

$\downarrow x$ $p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9135	0.8337	0.7602	0.6925	0.6302	0.5730	0.5204	0.4722	0.4279	0.3874	0.1342	0.0751	0.0404	0.0101	0.0020
1	0.9966	0.9869	0.9718	0.9522	0.9288	0.9022	0.8729	0.8417	0.8088	0.7748	0.4362	0.3003	0.1960	0.0705	0.0195
2	0.9999	0.9994	0.9980	0.9955	0.9916	0.9862	0.9791	0.9702	0.9595	0.9470	0.7382	0.6007	0.4628	0.2318	0.0898
3	1.0000	1.0000	0.9999	0.9997	0.9994	0.9987	0.9977	0.9963	0.9943	0.9917	0.9144	0.8343	0.7297	0.4826	0.2539
4	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9997	0.9995	0.9991	0.9804	0.9511	0.9012	0.7334	0.5000
5	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9969	0.9900	0.9747	0.9006	0.7461
6	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9987	0.9957	0.9750	0.9102
7	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9996	0.9962	0.9805
8	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9980

$n = 10$

$\downarrow x$ $p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.9044	0.8171	0.7374	0.6648	0.5987	0.5386	0.4840	0.4344	0.3894	0.3487	0.1074	0.0563	0.0282	0.0060	0.0010
1	0.9957	0.9838	0.9655	0.9418	0.9139	0.8824	0.8483	0.8121	0.7746	0.7361	0.3758	0.2440	0.1493	0.0464	0.0107
2	0.9999	0.9991	0.9972	0.9938	0.9885	0.9812	0.9717	0.9599	0.9460	0.9298	0.6778	0.5256	0.3828	0.1673	0.0547
3	1.0000	1.0000	0.9999	0.9996	0.9990	0.9980	0.9964	0.9942	0.9912	0.9872	0.8791	0.7759	0.6496	0.3823	0.1719
4	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9997	0.9994	0.9990	0.9984	0.9672	0.9219	0.8497	0.6331	0.3770
5	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9936	0.9803	0.9527	0.8338	0.6230
6	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9991	0.9965	0.9894	0.9452	0.8281
7	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9996	0.9984	0.9877	0.9453
8	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9983	0.9893
9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9990

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

Quellen

Tabellen

Binomialverteilung

Poissonverteilung


Standardnormalverteilung

$\chi^2$ -Verteilung

t-Verteilung

F-Verteilung

# Binomialverteilung $X \sim B(n; p)$ , Verteilungsfunktion $F(x) = P(X \leq x)$



$n = 15$

$\downarrow x \quad p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.8601	0.7386	0.6333	0.5421	0.4633	0.3953	0.3367	0.2863	0.2430	0.2059	0.0352	0.0134	0.0047	0.0005	0.0000
1	0.9904	0.9647	0.9270	0.8809	0.8290	0.7738	0.7168	0.6597	0.6035	0.5490	0.1671	0.0802	0.0353	0.0052	0.0005
2	0.9996	0.9970	0.9906	0.9797	0.9638	0.9429	0.9171	0.8870	0.8531	0.8159	0.3980	0.2361	0.1268	0.0271	0.0037
3	1.0000	0.9998	0.9992	0.9976	0.9945	0.9896	0.9825	0.9727	0.9601	0.9444	0.6482	0.4613	0.2969	0.0905	0.0176
4	1.0000	1.0000	0.9999	0.9998	0.9994	0.9986	0.9972	0.9950	0.9918	0.9873	0.8358	0.6865	0.5155	0.2173	0.0592
5	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9997	0.9993	0.9987	0.9978	0.9389	0.8516	0.7216	0.4032	0.1509
6	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9997	0.9819	0.9434	0.8689	0.6098	0.3036
7	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9958	0.9827	0.9500	0.7869	0.5000
8	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9992	0.9958	0.9848	0.9050	0.6964
9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9992	0.9963	0.9662	0.8491
10	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9993	0.9907	0.9408
11	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9981	0.9824
12	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9963
13	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9995
14	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000


- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

## Quellen

## Tabellen

- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung

# Binomialverteilung $X \sim B(n; p)$ , Verteilungsfunktion $F(x) = P(X \leq x)$



$n = 20$

$\downarrow x$ $p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.8179	0.6676	0.5438	0.4420	0.3585	0.2901	0.2342	0.1887	0.1516	0.1216	0.0115	0.0032	0.0008	0.0000	0.0000
1	0.9831	0.9401	0.8802	0.8103	0.7358	0.6605	0.5869	0.5169	0.4516	0.3917	0.0692	0.0243	0.0076	0.0005	0.0000
2	0.9990	0.9929	0.9790	0.9561	0.9245	0.8850	0.8390	0.7879	0.7334	0.6769	0.2061	0.0913	0.0355	0.0036	0.0002
3	1.0000	0.9994	0.9973	0.9926	0.9841	0.9710	0.9529	0.9294	0.9007	0.8670	0.4114	0.2252	0.1071	0.0160	0.0013
4	1.0000	1.0000	0.9997	0.9990	0.9974	0.9944	0.9893	0.9817	0.9710	0.9568	0.6296	0.4148	0.2375	0.0510	0.0059
5	1.0000	1.0000	1.0000	0.9999	0.9997	0.9991	0.9981	0.9962	0.9932	0.9887	0.8042	0.6172	0.4164	0.1256	0.0207
6	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9997	0.9994	0.9987	0.9976	0.9133	0.7858	0.6080	0.2500	0.0577
7	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9996	0.9679	0.8982	0.7723	0.4159	0.1316
8	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9900	0.9591	0.8867	0.5956	0.2517
9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9974	0.9861	0.9520	0.7553	0.4119
10	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9994	0.9961	0.9829	0.8725	0.5881
11	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9991	0.9949	0.9435	0.7483
12	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9998	0.9987	0.9790	0.8684
13	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9935	0.9423
14	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9984	0.9793
15	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997
16	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9987
17	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9998
18	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
19	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000


- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

Quellen

Tabellen

- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung

# Binomialverteilung $X \sim B(n; p)$ , Verteilungsfunktion $F(x) = P(X \leq x)$



$n = 25$

$\downarrow x \quad p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.7778	0.6035	0.4670	0.3604	0.2774	0.2129	0.1630	0.1244	0.0946	0.0718	0.0038	0.0008	0.0001	0.0000	0.0000
1	0.9742	0.9114	0.8280	0.7358	0.6424	0.5527	0.4696	0.3947	0.3286	0.2712	0.0274	0.0070	0.0016	0.0001	0.0000
2	0.9980	0.9868	0.9620	0.9235	0.8729	0.8129	0.7466	0.6768	0.6063	0.5371	0.0982	0.0321	0.0090	0.0004	0.0000
3	0.9999	0.9986	0.9938	0.9835	0.9659	0.9402	0.9064	0.8649	0.8169	0.7636	0.2340	0.0962	0.0332	0.0024	0.0001
4	1.0000	0.9999	0.9992	0.9972	0.9928	0.9850	0.9726	0.9549	0.9314	0.9020	0.4207	0.2137	0.0905	0.0095	0.0005
5	1.0000	1.0000	0.9999	0.9996	0.9988	0.9969	0.9935	0.9877	0.9790	0.9666	0.6167	0.3783	0.1935	0.0294	0.0020
6	1.0000	1.0000	1.0000	1.0000	0.9998	0.9995	0.9987	0.9972	0.9946	0.9905	0.7800	0.5611	0.3407	0.0736	0.0073
7	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9995	0.9989	0.9977	0.8909	0.7265	0.5118	0.1536	0.0216
8	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9998	0.9995	0.9532	0.8506	0.6769	0.2735	0.0539
9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9827	0.9287	0.8106	0.4246	0.1148
10	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9944	0.9703	0.9022	0.5858	0.2122
11	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9985	0.9893	0.9558	0.7323	0.3450
12	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9996	0.9966	0.9825	0.8462	0.5000
13	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9991	0.9940	0.9222	0.6550
14	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9998	0.9982	0.9656	0.7878
15	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9995	0.9868	0.8852
16	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9957	0.9461
17	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9988	0.9784
18	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9927
19	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9980
20	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9995
21	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999
22	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
23	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
24	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000


- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

Quellen

Tabellen

- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung

# Binomialverteilung $X \sim B(n; p)$ , Verteilungsfunktion $F(x) = P(X \leq x)$



$n = 50$

$\downarrow x$ $p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.6050	0.3642	0.2181	0.1299	0.0769	0.0453	0.0266	0.0155	0.0090	0.0052	0.0000	0.0000	0.0000	0.0000	0.0000
1	0.9106	0.7358	0.5553	0.4005	0.2794	0.1900	0.1265	0.0827	0.0532	0.0338	0.0002	0.0000	0.0000	0.0000	0.0000
2	0.9862	0.9216	0.8108	0.6767	0.5405	0.4162	0.3108	0.2260	0.1605	0.1117	0.0013	0.0001	0.0000	0.0000	0.0000
3	0.9984	0.9822	0.9372	0.8609	0.7604	0.6473	0.5327	0.4253	0.3303	0.2503	0.0057	0.0005	0.0000	0.0000	0.0000
4	0.9999	0.9968	0.9832	0.9510	0.8964	0.8206	0.7290	0.6290	0.5277	0.4312	0.0185	0.0021	0.0002	0.0000	0.0000
5	1.0000	0.9995	0.9963	0.9856	0.9622	0.9224	0.8650	0.7919	0.7072	0.6161	0.0480	0.0070	0.0007	0.0000	0.0000
6	1.0000	0.9999	0.9993	0.9964	0.9882	0.9711	0.9417	0.8981	0.8404	0.7702	0.1034	0.0194	0.0025	0.0000	0.0000
7	1.0000	1.0000	0.9999	0.9992	0.9968	0.9906	0.9780	0.9562	0.9232	0.8779	0.1904	0.0453	0.0073	0.0001	0.0000
8	1.0000	1.0000	1.0000	0.9999	0.9992	0.9973	0.9927	0.9833	0.9672	0.9421	0.3073	0.0916	0.0183	0.0002	0.0000
9	1.0000	1.0000	1.0000	1.0000	0.9998	0.9993	0.9978	0.9944	0.9875	0.9755	0.4437	0.1637	0.0402	0.0008	0.0000
10	1.0000	1.0000	1.0000	1.0000	1.0000	0.9998	0.9994	0.9983	0.9957	0.9906	0.5836	0.2622	0.0789	0.0022	0.0000
11	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9995	0.9987	0.9968	0.7107	0.3816	0.1390	0.0057	0.0000
12	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9996	0.9990	0.8139	0.5110	0.2229	0.0133	0.0002
13	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9997	0.8894	0.6370	0.3279	0.0280	0.0005
14	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9393	0.7481	0.4468	0.0540	0.0013
15	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9692	0.8369	0.5692	0.0955	0.0033
16	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9856	0.9017	0.6839	0.1561	0.0077
17	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9937	0.9449	0.7822	0.2369	0.0164
18	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9975	0.9713	0.8594	0.3356	0.0325
19	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9991	0.9861	0.9152	0.4465	0.0595
20	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9937	0.9522	0.5610	0.1013
21	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9974	0.9749	0.6701	0.1611
22	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9990	0.9877	0.7660	0.2399
23	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9996	0.9944	0.8438	0.3359
24	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9976	0.9022	0.4439
25	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9991	0.9427	0.5561
26	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9686	0.6641
27	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9840	0.7601
28	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9924	0.8389
29	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9966	0.8987
30	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9986	0.9405
31	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9995	0.9675
32	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9998	0.9836
33	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9923
34	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9967
35	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9987


- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

Quellen

Tabellen

- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung

# Binomialverteilung $X \sim B(n; p)$ , Verteilungsfunktion $F(x) = P(X \leq x)$



$n = 100$

$\downarrow x$ $p \rightarrow$	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09	0.1	0.2	0.25	0.3	0.4	0.5
0	0.3660	0.1326	0.0476	0.0169	0.0059	0.0021	0.0007	0.0002	0.0001	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
1	0.7358	0.4033	0.1946	0.0872	0.0371	0.0152	0.0060	0.0023	0.0009	0.0003	0.0000	0.0000	0.0000	0.0000	0.0000
2	0.9206	0.6767	0.4198	0.2321	0.1183	0.0566	0.0258	0.0113	0.0048	0.0019	0.0000	0.0000	0.0000	0.0000	0.0000
3	0.9816	0.8590	0.6472	0.4295	0.2578	0.1430	0.0744	0.0367	0.0173	0.0078	0.0000	0.0000	0.0000	0.0000	0.0000
4	0.9966	0.9492	0.8179	0.6289	0.4360	0.2768	0.1632	0.0903	0.0474	0.0237	0.0000	0.0000	0.0000	0.0000	0.0000
5	0.9995	0.9845	0.9192	0.7884	0.6160	0.4407	0.2914	0.1799	0.1045	0.0576	0.0000	0.0000	0.0000	0.0000	0.0000
6	0.9999	0.9959	0.9688	0.8936	0.7660	0.6064	0.4443	0.3032	0.1940	0.1172	0.0001	0.0000	0.0000	0.0000	0.0000
7	1.0000	0.9991	0.9894	0.9525	0.8720	0.7483	0.5988	0.4471	0.3128	0.2061	0.0003	0.0000	0.0000	0.0000	0.0000
8	1.0000	0.9998	0.9968	0.9810	0.9369	0.8537	0.7340	0.5926	0.4494	0.3209	0.0009	0.0000	0.0000	0.0000	0.0000
9	1.0000	1.0000	0.9991	0.9932	0.9718	0.9225	0.8380	0.7220	0.5875	0.4513	0.0023	0.0000	0.0000	0.0000	0.0000
10	1.0000	1.0000	0.9998	0.9978	0.9885	0.9624	0.9092	0.8243	0.7118	0.5832	0.0057	0.0001	0.0000	0.0000	0.0000
11	1.0000	1.0000	1.0000	0.9993	0.9957	0.9832	0.9531	0.8972	0.8124	0.7030	0.0126	0.0004	0.0000	0.0000	0.0000
12	1.0000	1.0000	1.0000	0.9998	0.9985	0.9931	0.9776	0.9441	0.8862	0.8018	0.0253	0.0010	0.0000	0.0000	0.0000
13	1.0000	1.0000	1.0000	1.0000	0.9995	0.9974	0.9901	0.9718	0.9355	0.8761	0.0469	0.0025	0.0001	0.0000	0.0000
14	1.0000	1.0000	1.0000	1.0000	0.9999	0.9991	0.9959	0.9867	0.9659	0.9274	0.0804	0.0054	0.0002	0.0000	0.0000
15	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9984	0.9942	0.9831	0.9601	0.1285	0.0111	0.0004	0.0000	0.0000
16	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9994	0.9976	0.9922	0.9794	0.1923	0.0211	0.0010	0.0000	0.0000
17	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9998	0.9991	0.9966	0.9900	0.2712	0.0376	0.0022	0.0000	0.0000
18	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9997	0.9986	0.9954	0.3621	0.0630	0.0045	0.0000	0.0000
19	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9995	0.9980	0.4602	0.0995	0.0089	0.0000	0.0000
20	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9998	0.9992	0.5595	0.1488	0.0165	0.0000	0.0000
21	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9997	0.6540	0.2114	0.0288	0.0000	0.0000
22	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.7389	0.2864	0.0479	0.0001	0.0000
23	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.8109	0.3711	0.0755	0.0003	0.0000
24	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.8686	0.4617	0.1136	0.0006	0.0000
25	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9125	0.5535	0.1631	0.0012	0.0000
26	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9442	0.6417	0.2244	0.0024	0.0000
27	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9658	0.7224	0.2964	0.0046	0.0000
28	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9800	0.7925	0.3768	0.0084	0.0000
29	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9888	0.8505	0.4623	0.0148	0.0000
30	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9939	0.8962	0.5491	0.0248	0.0000
31	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9969	0.9307	0.6331	0.0398	0.0001
32	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9984	0.9554	0.7107	0.0615	0.0002
33	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9993	0.9724	0.7793	0.0913	0.0004
34	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9997	0.9836	0.8371	0.1303	0.0009
35	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9906	0.8839	0.1795	0.0018

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

Quellen

Tabellen


- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung

# Poissonverteilung $X_\lambda \sim P(\lambda)$ , Verteilungsfunktionen

$$F_\lambda(x) = P(X_\lambda \leq x)$$

$\downarrow x \quad \lambda \rightarrow$	1	1.1	1.2	1.3	1.4	1.5	1.6	1.7	1.8	1.9	2	2.1	2.2	2.3	2.4
0	0.3679	0.3329	0.3012	0.2725	0.2466	0.2231	0.2019	0.1827	0.1653	0.1496	0.1353	0.1225	0.1108	0.1003	0.0907
1	0.7358	0.6990	0.6626	0.6268	0.5918	0.5578	0.5249	0.4932	0.4628	0.4337	0.4060	0.3796	0.3546	0.3309	0.3084
2	0.9197	0.9004	0.8795	0.8571	0.8335	0.8088	0.7834	0.7572	0.7306	0.7037	0.6767	0.6496	0.6227	0.5960	0.5697
3	0.9810	0.9743	0.9662	0.9569	0.9463	0.9344	0.9212	0.9068	0.8913	0.8747	0.8571	0.8386	0.8194	0.7993	0.7787
4	0.9963	0.9946	0.9923	0.9893	0.9857	0.9814	0.9763	0.9704	0.9636	0.9559	0.9473	0.9379	0.9275	0.9162	0.9041
5	0.9994	0.9990	0.9985	0.9978	0.9968	0.9955	0.9940	0.9920	0.9896	0.9868	0.9834	0.9796	0.9751	0.9700	0.9643
6	0.9999	0.9999	0.9997	0.9996	0.9994	0.9991	0.9987	0.9981	0.9974	0.9966	0.9955	0.9941	0.9925	0.9906	0.9884
7	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998	0.9997	0.9996	0.9994	0.9992	0.9989	0.9985	0.9980	0.9974	0.9967
8	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998	0.9998	0.9997	0.9995	0.9994	0.9991
9	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9999	0.9998

$\downarrow x \quad \lambda \rightarrow$	2.5	2.75	3	3.25	3.5	3.75	4	4.25	4.5	4.75	5	5.25	5.5	5.75	6
0	0.0821	0.0639	0.0498	0.0388	0.0302	0.0235	0.0183	0.0143	0.0111	0.0087	0.0067	0.0052	0.0041	0.0032	0.0025
1	0.2873	0.2397	0.1991	0.1648	0.1359	0.1117	0.0916	0.0749	0.0611	0.0497	0.0404	0.0328	0.0266	0.0215	0.0174
2	0.5438	0.4815	0.4232	0.3696	0.3208	0.2771	0.2381	0.2037	0.1736	0.1473	0.1247	0.1051	0.0884	0.0741	0.0620
3	0.7576	0.7030	0.6472	0.5914	0.5366	0.4838	0.4335	0.3862	0.3423	0.3019	0.2650	0.2317	0.2017	0.1749	0.1512
4	0.8912	0.8554	0.8153	0.7717	0.7254	0.6775	0.6288	0.5801	0.5321	0.4854	0.4405	0.3978	0.3575	0.3199	0.2851
5	0.9580	0.9392	0.9161	0.8888	0.8576	0.8229	0.7851	0.7449	0.7029	0.6597	0.6160	0.5722	0.5289	0.4866	0.4457
6	0.9858	0.9776	0.9665	0.9523	0.9347	0.9137	0.8893	0.8617	0.8311	0.7978	0.7622	0.7248	0.6860	0.6464	0.6063
7	0.9958	0.9927	0.9881	0.9817	0.9733	0.9624	0.9489	0.9326	0.9134	0.8914	0.8666	0.8392	0.8095	0.7776	0.7440
8	0.9989	0.9978	0.9962	0.9937	0.9901	0.9852	0.9786	0.9702	0.9597	0.9470	0.9319	0.9144	0.8944	0.8719	0.8472
9	0.9997	0.9994	0.9989	0.9980	0.9967	0.9947	0.9919	0.9880	0.9829	0.9764	0.9682	0.9582	0.9462	0.9322	0.9161
10	0.9999	0.9999	0.9997	0.9994	0.9990	0.9983	0.9972	0.9956	0.9933	0.9903	0.9863	0.9812	0.9747	0.9669	0.9574
11	1.0000	1.0000	0.9999	0.9999	0.9997	0.9995	0.9991	0.9985	0.9976	0.9963	0.9945	0.9922	0.9890	0.9850	0.9799
12	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9997	0.9995	0.9992	0.9987	0.9980	0.9970	0.9955	0.9937	0.9912
13	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9997	0.9996	0.9993	0.9989	0.9983	0.9975	0.9964
14	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998	0.9996	0.9994	0.9991	0.9986
15	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998	0.9997	0.9995
16	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998
17	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

Quellen

Tabellen

Binomialverteilung

Poissonverteilung

Standardnormalverteilung

$\chi^2$ -Verteilung


t-Verteilung

F-Verteilung

# Poissonverteilung $X_\lambda \sim P(\lambda)$ , Verteilungsfunktionen

$$F_\lambda(x) = P(X_\lambda \leq x)$$

$\downarrow x \quad \lambda \rightarrow$	6.25	6.5	6.75	7	7.25	7.5	7.75	8	8.25	8.5	8.75	9	9.25	9.5	10
0	0.0019	0.0015	0.0012	0.0009	0.0007	0.0006	0.0004	0.0003	0.0003	0.0002	0.0002	0.0001	0.0001	0.0001	0.0000
1	0.0140	0.0113	0.0091	0.0073	0.0059	0.0047	0.0038	0.0030	0.0024	0.0019	0.0015	0.0012	0.0010	0.0008	0.0005
2	0.0517	0.0430	0.0357	0.0296	0.0245	0.0203	0.0167	0.0138	0.0113	0.0093	0.0076	0.0062	0.0051	0.0042	0.0028
3	0.1303	0.1118	0.0958	0.0818	0.0696	0.0591	0.0501	0.0424	0.0358	0.0301	0.0253	0.0212	0.0178	0.0149	0.0103
4	0.2530	0.2237	0.1970	0.1730	0.1514	0.1321	0.1149	0.0996	0.0862	0.0744	0.0640	0.0550	0.0471	0.0403	0.0293
5	0.4064	0.3690	0.3338	0.3007	0.2699	0.2414	0.2152	0.1912	0.1694	0.1496	0.1317	0.1157	0.1013	0.0885	0.0671
6	0.5662	0.5265	0.4876	0.4497	0.4132	0.3782	0.3449	0.3134	0.2838	0.2562	0.2305	0.2068	0.1849	0.1649	0.1301
7	0.7089	0.6728	0.6359	0.5987	0.5615	0.5246	0.4884	0.4530	0.4186	0.3856	0.3540	0.3239	0.2954	0.2687	0.2202
8	0.8204	0.7916	0.7611	0.7291	0.6960	0.6620	0.6274	0.5925	0.5577	0.5231	0.4890	0.4557	0.4232	0.3918	0.3328
9	0.8978	0.8774	0.8549	0.8305	0.8043	0.7764	0.7471	0.7166	0.6852	0.6530	0.6203	0.5874	0.5545	0.5218	0.4579
10	0.9462	0.9332	0.9183	0.9015	0.8828	0.8622	0.8399	0.8159	0.7903	0.7634	0.7352	0.7060	0.6760	0.6453	0.5830
11	0.9737	0.9661	0.9571	0.9467	0.9345	0.9208	0.9053	0.8881	0.8692	0.8487	0.8266	0.8030	0.7781	0.7520	0.6968
12	0.9880	0.9840	0.9790	0.9730	0.9658	0.9573	0.9475	0.9362	0.9234	0.9091	0.8932	0.8758	0.8568	0.8364	0.7916
13	0.9949	0.9929	0.9904	0.9872	0.9832	0.9784	0.9727	0.9658	0.9578	0.9486	0.9380	0.9261	0.9129	0.8981	0.8645
14	0.9979	0.9970	0.9958	0.9943	0.9923	0.9897	0.9866	0.9827	0.9781	0.9726	0.9661	0.9585	0.9499	0.9400	0.9165
15	0.9992	0.9988	0.9983	0.9976	0.9966	0.9954	0.9938	0.9918	0.9893	0.9862	0.9824	0.9780	0.9727	0.9665	0.9513
16	0.9997	0.9996	0.9994	0.9990	0.9986	0.9980	0.9973	0.9963	0.9950	0.9934	0.9914	0.9889	0.9859	0.9823	0.9730
17	0.9999	0.9998	0.9998	0.9996	0.9995	0.9992	0.9989	0.9984	0.9978	0.9970	0.9960	0.9947	0.9931	0.9911	0.9857
18	1.0000	0.9999	0.9999	0.9999	0.9998	0.9997	0.9996	0.9993	0.9991	0.9987	0.9982	0.9976	0.9968	0.9957	0.9928
19	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9998	0.9997	0.9996	0.9995	0.9992	0.9989	0.9986	0.9980	0.9965
20	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9999	0.9998	0.9997	0.9996	0.9994	0.9991	0.9984
21	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9999	0.9998	0.9997	0.9996	0.9993
22	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999	0.9999	0.9997
23	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999
24	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
25	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

Quellen


Tabellen

- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung

# Verteilungsfunktion $\Phi$ der Standardnormalverteilung

Dabei bedeutet  $\Phi(x)$  zum Beispiel:  $\Phi(2,13) = \Phi(2,1 + 0,03) = 0,9834$ . Diesen Wert findet man in der Zeile mit  $x_1 = 2,1$  und der Spalte mit  $x_2 = 0,03$ .

$x_1 \setminus x_2$	0	0.01	0.02	0.03	0.04	0.05	0.06	0.07	0.08	0.09
0	0.50000	0.50399	0.50798	0.51197	0.51595	0.51994	0.52392	0.52790	0.53188	0.53586
0.1	0.53983	0.54380	0.54776	0.55172	0.55567	0.55962	0.56356	0.56749	0.57142	0.57535
0.2	0.57926	0.58317	0.58706	0.59095	0.59483	0.59871	0.60257	0.60642	0.61026	0.61409
0.3	0.61791	0.62172	0.62552	0.62930	0.63307	0.63683	0.64058	0.64431	0.64803	0.65173
0.4	0.65542	0.65910	0.66276	0.66640	0.67003	0.67364	0.67724	0.68082	0.68439	0.68793
0.5	0.69146	0.69497	0.69847	0.70194	0.70540	0.70884	0.71226	0.71566	0.71904	0.72240
0.6	0.72575	0.72907	0.73237	0.73565	0.73891	0.74215	0.74537	0.74857	0.75175	0.75490
0.7	0.75804	0.76115	0.76424	0.76730	0.77035	0.77337	0.77637	0.77935	0.78230	0.78524
0.8	0.78814	0.79103	0.79389	0.79673	0.79955	0.80234	0.80511	0.80785	0.81057	0.81327
0.9	0.81594	0.81859	0.82121	0.82381	0.82639	0.82894	0.83147	0.83398	0.83646	0.83891
1	0.84134	0.84375	0.84614	0.84850	0.85083	0.85314	0.85543	0.85769	0.85993	0.86214
1.1	0.86433	0.86650	0.86864	0.87076	0.87286	0.87493	0.87698	0.87900	0.88100	0.88298
1.2	0.88493	0.88686	0.88877	0.89065	0.89251	0.89435	0.89617	0.89796	0.89973	0.90147
1.3	0.90320	0.90490	0.90658	0.90824	0.90988	0.91149	0.91309	0.91466	0.91621	0.91774
1.4	0.91924	0.92073	0.92220	0.92364	0.92507	0.92647	0.92785	0.92922	0.93056	0.93189
1.5	0.93319	0.93448	0.93574	0.93699	0.93822	0.93943	0.94062	0.94179	0.94295	0.94408
1.6	0.94520	0.94630	0.94738	0.94845	0.94950	0.95053	0.95154	0.95254	0.95352	0.95449
1.7	0.95543	0.95637	0.95728	0.95818	0.95907	0.95994	0.96080	0.96164	0.96246	0.96327
1.8	0.96407	0.96485	0.96562	0.96638	0.96712	0.96784	0.96856	0.96926	0.96995	0.97062
1.9	0.97128	0.97193	0.97257	0.97320	0.97381	0.97441	0.97500	0.97558	0.97615	0.97670
2	0.97725	0.97778	0.97831	0.97882	0.97932	0.97982	0.98030	0.98077	0.98124	0.98169
2.1	0.98214	0.98257	0.98300	0.98341	0.98382	0.98422	0.98461	0.98500	0.98537	0.98574
2.2	0.98610	0.98645	0.98679	0.98713	0.98745	0.98778	0.98809	0.98840	0.98870	0.98899
2.3	0.98928	0.98956	0.98983	0.99010	0.99036	0.99061	0.99086	0.99111	0.99134	0.99158
2.4	0.99180	0.99202	0.99224	0.99245	0.99266	0.99286	0.99305	0.99324	0.99343	0.99361
2.5	0.99379	0.99396	0.99413	0.99430	0.99446	0.99461	0.99477	0.99492	0.99506	0.99520
2.6	0.99534	0.99547	0.99560	0.99573	0.99585	0.99598	0.99609	0.99621	0.99632	0.99643
2.7	0.99653	0.99664	0.99674	0.99683	0.99693	0.99702	0.99711	0.99720	0.99728	0.99736
2.8	0.99744	0.99752	0.99760	0.99767	0.99774	0.99781	0.99788	0.99795	0.99801	0.99807
2.9	0.99813	0.99819	0.99825	0.99831	0.99836	0.99841	0.99846	0.99851	0.99856	0.99861
3	0.99865	0.99869	0.99874	0.99878	0.99882	0.99886	0.99889	0.99893	0.99897	0.99900
3.1	0.99903	0.99906	0.99910	0.99913	0.99916	0.99918	0.99921	0.99924	0.99926	0.99929
3.2	0.99931	0.99934	0.99936	0.99938	0.99940	0.99942	0.99944	0.99946	0.99948	0.99950
3.3	0.99952	0.99953	0.99955	0.99957	0.99958	0.99960	0.99961	0.99962	0.99964	0.99965
3.4	0.99966	0.99968	0.99969	0.99970	0.99971	0.99972	0.99973	0.99974	0.99975	0.99976



- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

## Quellen

## Tabellen

Binomialverteilung

Poissonverteilung


Standardnormalverteilung

$\chi^2$ -Verteilung

t-Verteilung

F-Verteilung

# $\alpha$ -Fraktile der $\chi^2$ -Verteilung mit n Freiheitsgraden



$\downarrow \alpha \setminus n \rightarrow$	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0.005	0.00	0.01	0.07	0.21	0.41	0.68	0.99	1.34	1.73	2.16	2.60	3.07	3.56	4.07	4.60
0.01	0.00	0.02	0.11	0.30	0.55	0.87	1.24	1.65	2.09	2.56	3.05	3.57	4.11	4.66	5.23
0.025	0.00	0.05	0.22	0.48	0.83	1.24	1.69	2.18	2.70	3.25	3.82	4.40	5.01	5.63	6.26
0.05	0.00	0.10	0.35	0.71	1.15	1.64	2.17	2.73	3.33	3.94	4.57	5.23	5.89	6.57	7.26
0.1	0.02	0.21	0.58	1.06	1.61	2.20	2.83	3.49	4.17	4.87	5.58	6.30	7.04	7.79	8.55
0.2	0.06	0.45	1.01	1.65	2.34	3.07	3.82	4.59	5.38	6.18	6.99	7.81	8.63	9.47	10.31
0.25	0.10	0.58	1.21	1.92	2.67	3.45	4.25	5.07	5.90	6.74	7.58	8.44	9.30	10.17	11.04
0.4	0.28	1.02	1.87	2.75	3.66	4.57	5.49	6.42	7.36	8.30	9.24	10.18	11.13	12.08	13.03
0.5	0.45	1.39	2.37	3.36	4.35	5.35	6.35	7.34	8.34	9.34	10.34	11.34	12.34	13.34	14.34
0.6	0.71	1.83	2.95	4.04	5.13	6.21	7.28	8.35	9.41	10.47	11.53	12.58	13.64	14.69	15.73
0.75	1.32	2.77	4.11	5.39	6.63	7.84	9.04	10.22	11.39	12.55	13.70	14.85	15.98	17.12	18.25
0.8	1.64	3.22	4.64	5.99	7.29	8.56	9.80	11.03	12.24	13.44	14.63	15.81	16.98	18.15	19.31
0.9	2.71	4.61	6.25	7.78	9.24	10.64	12.02	13.36	14.68	15.99	17.27	18.55	19.81	21.06	22.31
0.95	3.84	5.99	7.81	9.49	11.07	12.59	14.07	15.51	16.92	18.31	19.68	21.03	22.36	23.68	25.00
0.975	5.02	7.38	9.35	11.14	12.83	14.45	16.01	17.53	19.02	20.48	21.92	23.34	24.74	26.12	27.49
0.99	6.63	9.21	11.34	13.28	15.09	16.81	18.48	20.09	21.67	23.21	24.73	26.22	27.69	29.14	30.58
0.995	7.88	10.60	12.84	14.86	16.75	18.55	20.28	21.95	23.59	25.19	26.76	28.30	29.82	31.32	32.80

$\downarrow \alpha \setminus n \rightarrow$	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
0.005	5.14	5.70	6.26	6.84	7.43	8.03	8.64	9.26	9.89	10.52	11.16	11.81	12.46	13.12	13.79
0.01	5.81	6.41	7.01	7.63	8.26	8.90	9.54	10.20	10.86	11.52	12.20	12.88	13.56	14.26	14.95
0.025	6.91	7.56	8.23	8.91	9.59	10.28	10.98	11.69	12.40	13.12	13.84	14.57	15.31	16.05	16.79
0.05	7.96	8.67	9.39	10.12	10.85	11.59	12.34	13.09	13.85	14.61	15.38	16.15	16.93	17.71	18.49
0.1	9.31	10.09	10.86	11.65	12.44	13.24	14.04	14.85	15.66	16.47	17.29	18.11	18.94	19.77	20.60
0.2	11.15	12.00	12.86	13.72	14.58	15.44	16.31	17.19	18.06	18.94	19.82	20.70	21.59	22.48	23.36
0.25	11.91	12.79	13.68	14.56	15.45	16.34	17.24	18.14	19.04	19.94	20.84	21.75	22.66	23.57	24.48
0.4	13.98	14.94	15.89	16.85	17.81	18.77	19.73	20.69	21.65	22.62	23.58	24.54	25.51	26.48	27.44
0.5	15.34	16.34	17.34	18.34	19.34	20.34	21.34	22.34	23.34	24.34	25.34	26.34	27.34	28.34	29.34
0.6	16.78	17.82	18.87	19.91	20.95	21.99	23.03	24.07	25.11	26.14	27.18	28.21	29.25	30.28	31.32
0.75	19.37	20.49	21.60	22.72	23.83	24.93	26.04	27.14	28.24	29.34	30.43	31.53	32.62	33.71	34.80
0.8	20.47	21.61	22.76	23.90	25.04	26.17	27.30	28.43	29.55	30.68	31.79	32.91	34.03	35.14	36.25
0.9	23.54	24.77	25.99	27.20	28.41	29.62	30.81	32.01	33.20	34.38	35.56	36.74	37.92	39.09	40.26
0.95	26.30	27.59	28.87	30.14	31.41	32.67	33.92	35.17	36.41	37.65	38.89	40.11	41.34	42.56	43.77
0.975	28.85	30.19	31.53	32.85	34.17	35.48	36.78	38.08	39.36	40.65	41.92	43.19	44.46	45.72	46.98
0.99	32.00	33.41	34.81	36.19	37.57	38.93	40.29	41.64	42.98	44.31	45.64	46.96	48.28	49.59	50.89
0.995	34.27	35.72	37.16	38.58	40.00	41.40	42.80	44.18	45.56	46.93	48.29	49.64	50.99	52.34	53.67

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik


## Quellen

## Tabellen

- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung

# $\alpha$ -Fraktile der t-Verteilung mit n Freiheitsgraden

$\downarrow n \setminus \alpha \rightarrow$	0.6	0.75	0.8	0.9	0.95	0.975	0.99	0.995
1	0.325	1.000	1.376	3.078	6.314	12.706	31.820	63.657
2	0.289	0.816	1.061	1.886	2.920	4.303	6.965	9.925
3	0.277	0.765	0.979	1.638	2.353	3.183	4.541	5.841
4	0.271	0.741	0.941	1.533	2.132	2.776	3.747	4.604
5	0.267	0.727	0.920	1.476	2.015	2.571	3.365	4.032
6	0.265	0.718	0.906	1.440	1.943	2.447	3.143	3.707
7	0.263	0.711	0.896	1.415	1.895	2.365	2.998	3.499
8	0.262	0.706	0.889	1.397	1.860	2.306	2.897	3.355
9	0.261	0.703	0.883	1.383	1.833	2.262	2.821	3.250
10	0.260	0.700	0.879	1.372	1.812	2.228	2.764	3.169
11	0.260	0.698	0.875	1.363	1.796	2.201	2.718	3.106
12	0.259	0.696	0.873	1.356	1.782	2.179	2.681	3.054
13	0.259	0.694	0.870	1.350	1.771	2.160	2.650	3.012
14	0.258	0.692	0.868	1.345	1.761	2.145	2.624	2.977
15	0.258	0.691	0.866	1.341	1.753	2.131	2.603	2.947
16	0.258	0.690	0.865	1.337	1.746	2.120	2.583	2.921
17	0.257	0.689	0.863	1.333	1.740	2.110	2.567	2.898
18	0.257	0.688	0.862	1.330	1.734	2.101	2.552	2.878
19	0.257	0.688	0.861	1.328	1.729	2.093	2.539	2.861
20	0.257	0.687	0.860	1.325	1.725	2.086	2.528	2.845
21	0.257	0.686	0.859	1.323	1.721	2.080	2.518	2.831
22	0.256	0.686	0.858	1.321	1.717	2.074	2.508	2.819
23	0.256	0.685	0.858	1.319	1.714	2.069	2.500	2.807
24	0.256	0.685	0.857	1.318	1.711	2.064	2.492	2.797
25	0.256	0.684	0.856	1.316	1.708	2.059	2.485	2.787
26	0.256	0.684	0.856	1.315	1.706	2.055	2.479	2.779
27	0.256	0.684	0.855	1.314	1.703	2.052	2.473	2.771
28	0.256	0.683	0.855	1.312	1.701	2.048	2.467	2.763
29	0.256	0.683	0.854	1.311	1.699	2.045	2.462	2.756
30	0.256	0.683	0.854	1.310	1.697	2.042	2.457	2.750




- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

Quellen

Tabellen

- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung

# $\alpha$ -Fraktile der F-Verteilung mit den Freiheitsgraden $\nu_1$ und $\nu_2$



$\alpha = 0,95$

$\nu_1 \setminus \nu_2$	1	2	3	4	5	6	7	8	9	10	15	20	30	40	50	100
1	161.4	18.51	10.13	7.71	6.61	5.99	5.59	5.32	5.12	4.96	4.54	4.35	4.17	4.08	4.03	3.94
2	199.5	19.00	9.55	6.94	5.79	5.14	4.74	4.46	4.26	4.10	3.68	3.49	3.32	3.23	3.18	3.09
3	215.7	19.16	9.28	6.59	5.41	4.76	4.35	4.07	3.86	3.71	3.29	3.10	2.92	2.84	2.79	2.70
4	224.6	19.25	9.12	6.39	5.19	4.53	4.12	3.84	3.63	3.48	3.06	2.87	2.69	2.61	2.56	2.46
5	230.2	19.30	9.01	6.26	5.05	4.39	3.97	3.69	3.48	3.33	2.90	2.71	2.53	2.45	2.40	2.31
6	234.0	19.33	8.94	6.16	4.95	4.28	3.87	3.58	3.37	3.22	2.79	2.60	2.42	2.34	2.29	2.19
7	236.8	19.35	8.89	6.09	4.88	4.21	3.79	3.50	3.29	3.14	2.71	2.51	2.33	2.25	2.20	2.10
8	238.9	19.37	8.85	6.04	4.82	4.15	3.73	3.44	3.23	3.07	2.64	2.45	2.27	2.18	2.13	2.03
9	240.5	19.38	8.81	6.00	4.77	4.10	3.68	3.39	3.18	3.02	2.59	2.39	2.21	2.12	2.07	1.97
10	241.9	19.40	8.79	5.96	4.74	4.06	3.64	3.35	3.14	2.98	2.54	2.35	2.16	2.08	2.03	1.93
15	245.9	19.43	8.70	5.86	4.62	3.94	3.51	3.22	3.01	2.85	2.40	2.20	2.01	1.92	1.87	1.77
20	248.0	19.45	8.66	5.80	4.56	3.87	3.44	3.15	2.94	2.77	2.33	2.12	1.93	1.84	1.78	1.68
30	250.1	19.46	8.62	5.75	4.50	3.81	3.38	3.08	2.86	2.70	2.25	2.04	1.84	1.74	1.69	1.57
40	251.1	19.47	8.59	5.72	4.46	3.77	3.34	3.04	2.83	2.66	2.20	1.99	1.79	1.69	1.63	1.52
50	251.8	19.48	8.58	5.70	4.44	3.75	3.32	3.02	2.80	2.64	2.18	1.97	1.76	1.66	1.60	1.48
100	253.0	19.49	8.55	5.66	4.41	3.71	3.27	2.97	2.76	2.59	2.12	1.91	1.70	1.59	1.52	1.39

$\alpha = 0,99$

$\nu_1 \setminus \nu_2$	1	2	3	4	5	6	7	8	9	10	15	20	30	40	50	100
1	4052	98.50	34.12	21.20	16.26	13.75	12.25	11.26	10.56	10.04	8.68	8.10	7.56	7.31	7.17	6.90
2	5000	99.00	30.82	18.00	13.27	10.92	9.55	8.65	8.02	7.56	6.36	5.85	5.39	5.18	5.06	4.82
3	5403	99.17	29.46	16.69	12.06	9.78	8.45	7.59	6.99	6.55	5.42	4.94	4.51	4.31	4.20	3.98
4	5625	99.25	28.71	15.98	11.39	9.15	7.85	7.01	6.42	5.99	4.89	4.43	4.02	3.83	3.72	3.51
5	5764	99.30	28.24	15.52	10.97	8.75	7.46	6.63	6.06	5.64	4.56	4.10	3.70	3.51	3.41	3.21
6	5859	99.33	27.91	15.21	10.67	8.47	7.19	6.37	5.80	5.39	4.32	3.87	3.47	3.29	3.19	2.99
7	5928	99.36	27.67	14.98	10.46	8.26	6.99	6.18	5.61	5.20	4.14	3.70	3.30	3.12	3.02	2.82
8	5981	99.37	27.49	14.80	10.29	8.10	6.84	6.03	5.47	5.06	4.00	3.56	3.17	2.99	2.89	2.69
9	6022	99.39	27.35	14.66	10.16	7.98	6.72	5.91	5.35	4.94	3.89	3.46	3.07	2.89	2.78	2.59
10	6056	99.40	27.23	14.55	10.05	7.87	6.62	5.81	5.26	4.85	3.80	3.37	2.98	2.80	2.70	2.50
15	6157	99.43	26.87	14.20	9.72	7.56	6.31	5.52	4.96	4.56	3.52	3.09	2.70	2.52	2.42	2.22
20	6209	99.45	26.69	14.02	9.55	7.40	6.16	5.36	4.81	4.41	3.37	2.94	2.55	2.37	2.27	2.07
30	6261	99.47	26.50	13.84	9.38	7.23	5.99	5.20	4.65	4.25	3.21	2.78	2.39	2.20	2.10	1.89
40	6287	99.47	26.41	13.75	9.29	7.14	5.91	5.12	4.57	4.17	3.13	2.69	2.30	2.11	2.01	1.80
50	6303	99.48	26.35	13.69	9.24	7.09	5.86	5.07	4.52	4.12	3.08	2.64	2.25	2.06	1.95	1.74
100	6334	99.49	26.24	13.58	9.13	6.99	5.75	4.96	4.41	4.01	2.98	2.54	2.13	1.94	1.82	1.60

- 1. Einführung
- 2. Deskriptive Statistik
- 3. W-Theorie
- 4. Induktive Statistik

Quellen

Tabellen

- Binomialverteilung
- Poissonverteilung
- Standardnormalverteilung
- $\chi^2$ -Verteilung
- t-Verteilung
- F-Verteilung