

# Statistik

## 1. Datenerfassung - Begriffe

<b>Grundgesamtheit</b>	Die Gesamtheit der Individuen oder Objekte, die Gegenstand einer statistischen Untersuchung sind.
<b>Zufallsprinzip</b>	Sicherstellung, dass jedes Element der Grundgesamtheit bei der Erhebung einer Stichprobe ausgewählt werden kann.
<b>Stichprobe</b>	Ausgewählter Teil der Grundgesamtheit
<b>Rohdaten</b>	Die in einer Stichprobe erfassten Daten
<b>Urliste</b>	Liste, in der die Rohdaten der Stichprobe eingetragen werden
<b>Verdichtete Daten</b>	Verarbeitete Rohdaten
<b>Strichliste</b>	Verdeutlichung der Merkmalsausprägung
<b>Merkmalsklasse</b>	Zusammenfassung von unterschiedlichen Merkmalen
<b>Merkmalsausprägung</b>	Spezifische Daten der Merkmalsklasse
<b>Nominalskala</b>	Erfassung eines <b>qualitativen</b> Merkmals <b>ohne</b> eindeutige Rangfolge
<b>Ordinalskala</b>	Merkmale <b>mit</b> eindeutiger Rangfolge
<b>Metrische Skala</b>	Erfassung eines <b>quantitativen</b> Merkmals <b>mit</b> eindeutiger Rangfolge

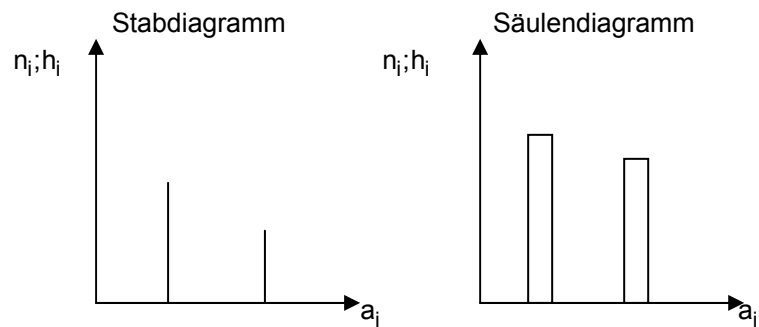
## 2. Häufigkeiten

<b>Absolute Häufigkeit <math>n_i</math></b>	Die Anzahl, mit der eine Merkmalsausprägung $a_i$ vorkommt.
<b>Gesamtheit <math>n</math></b>	Summe der absoluten Häufigkeiten $n = \sum_{i=1}^k n_i = n_1 + n_2 + \dots + n_k$
<b>Relative Häufigkeit <math>h(a_i)</math></b>	$h(a_i) = \frac{n_i}{n}$ ; $n_i$ : einzelne Beobachtungswerte $n$ : Gesamtheit der Beobachtungswerte
<b>Summe der relativen Häufigkeiten</b>	Für $k$ Merkmalsausprägungen gilt: $\sum_{i=1}^k h(a_i) = 1$

### 3. Diagramme


Stabdiagramm

Säulendiagramm



$n_i$ : absolute Häufigkeit  
 $h_i$ : relative Häufigkeit  
 $a_i$ : Merkmalsausprägung

Kreisdiagramm:



$$\alpha_i = h(a_i) \cdot 360^\circ$$

M: Mittelpunkt  
 $\alpha_i$ : Mittelpunktswinkel  
 $h(a_i)$ : relative Häufigkeit

### 4. Lagemaße

**Arithmetisches Mittel**  $\bar{x}$

Das arithmetische Mittel  $\bar{x}$  ist der Durchschnittswert aller Beobachtungswerte.

$$\bar{x} = \frac{1}{n} \cdot \sum_{i=1}^n x_i$$

$$\bar{x} = \frac{1}{n} \cdot (x_1 + x_2 + \dots + x_n)$$

n: Anzahl der Beobachtungswerte

$x_i$ : Beobachtungswerte

i: Laufvariable von  $i = 1$  bis zur Anzahl n der Beobachtungswerte

**Arithmetisches Mittel**  $\bar{x}$   
über relative Häufigkeit

$$\bar{x} = \sum_{i=1}^k a_i \cdot h(a_i)$$

$$\bar{x} = a_1 \cdot h(a_1) + a_2 \cdot h(a_2) + \dots + a_k \cdot h(a_k)$$

$a_i$ : Merkmalsausprägungen

$h(a_i)$ : relative Häufigkeiten

k: Anzahl der Merkmalsausprägungen

**Zentralwert z**  
**Median  $x_{med}$**

Der Zentralwert z (auch Median  $x_{med}$  genannt) ist derjenige Wert, der die geordneten Beobachtungswerte  $x_i$  in zwei Hälften teilt. Der Zentralwert steht in der Mitte der Rangwertliste.

Fall 1: n ungeradzahlig

$$z = x_{med} = x_{\frac{n+1}{2}}$$

Fall 2: n geradzahlig:

$$z = x_{med} = \frac{1}{2} \cdot \left( x_{\frac{n}{2}} + x_{\frac{n+2}{2}} \right) = \frac{1}{2} \cdot \left( x_{\frac{n}{2}} + x_{\frac{n}{2}+1} \right)$$

**Spannweite w**

Die Differenz zwischen dem größten Beobachtungswert  $x_{max}$  und dem kleinsten Beobachtungswert  $x_{min}$  einer Reihe von Beobachtungswerten  $x_i$  wird als Spannweite w bezeichnet.

$$w = x_{max} - x_{min}$$

**Modalwert  $x_{mod}$**

Der Modalwert  $x_{mod}$  ist der am häufigsten vorkommende Beobachtungswert.

**Verteilung der Lagemaße**

linksschiefe Verteilung:  $x_{mod} > x_{med} > \bar{x}$   
rechtsschiefe Verteilung:  $\bar{x} > x_{med} > x_{mod}$   
symmetrische Verteilung:  $\bar{x} \approx x_{med} \approx x_{mod}$

**5. Streumaße**

**Quartil  $Q_{1;2;3}$**   
**Quartilsabstand Q**

Werden alle Messwerte einer Stichprobe der Größe nach geordnet und in vier gleiche Bereiche eingeteilt, so werden die drei Grenzen zwischen diesen vier Bereichen als Quartile bezeichnet.

1. Quartil:  $Q_1 = x_{\frac{n+1}{4}}$

2. Quartil:  $Q_2 = x_{\frac{n+1}{2}} = x_{med}$

3. Quartil:  $Q_3 = x_{\frac{3n+3}{4}}$

Der Quartilsabstand ist die Breite, die die beiden mittleren Bereiche einnehmen.

**Quartilsabstand:  $Q = Q_3 - Q_1$**

**Mittlere Abweichung  $d_{med}$  vom Median**

$$d_{med} = \frac{1}{n} \cdot \sum_{i=1}^n |x_i - x_{med}|$$

n: Anzahl der Beobachtungswerte  
 $x_i$ : Beobachtungswerte  
 $x_{med}$ : Median

**Mittlere Abweichung e vom arithmetischen Mittel**

$$e = \frac{1}{n} \cdot \sum_{i=1}^n |x_i - \bar{x}|$$

$\bar{x}$  : arithmetisches Mittel

**Varianz v**

Die Varianz v ist ein Maß für die Streuung der Messgrößen

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

**Standardabweichung s**

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

**Varianz v für absolute Häufigkeiten**

$$v = \frac{1}{n} \cdot \sum_{i=1}^k (x_i - \bar{x})^2 \cdot n_i$$

k: Anzahl der Klassen  
 $n_i$ : absolute Häufigkeiten


**Varianz v für relative Häufigkeiten**

$$v = \sum_{i=1}^k (x_i - \bar{x})^2 \cdot h_i$$

$h_i$ : relative Häufigkeit

**Normalverteilung**

Verteilungen, die die Form einer Glockenkurve aufweisen, nennt man Normalverteilungen oder auch Gauß-Verteilungen. Die Normal- oder Gauß-Verteilung ist ein wichtiger Typ kontinuierlicher Wahrscheinlichkeitsverteilungen.



Die Standardabweichung s beschreibt die Breite der Normalverteilung. Berücksichtigt man die tabellierten Werte der Verteilungsfunktion, gilt näherungsweise folgende Aussage:

Rund 68% aller Werte liegen im Intervall  $[\bar{x} - s; \bar{x} + s]$ ,

rund 95% aller Werte liegen im Intervall  $[\bar{x} - 2s; \bar{x} + 2s]$ ,

mehr als 99% aller Werte liegen im Intervall  $[\bar{x} - 3s; \bar{x} + 3s]$ .

## Stochastik

### Zufallsexperiment

- Alle möglichen Ergebnisse sind vorab bekannt
- Einzelne Experimentergebnisse sind zufällig
- Beliebige Wiederholbarkeit unter gleichen Startbedingungen

### Häufigkeit

Relative Häufigkeit:

Tritt ein Ereignis E bei einer Versuchsreihe mit n Versuchen genau  $n_i$ -mal auf, so wird der Quotient  $\frac{n_i}{n}$  als **relative Häufigkeit** des Ereignisses E bezeichnet.

Absolute Häufigkeit:

$n_i$  heißt die **absolute Häufigkeit** des Ereignisses E.

### Wahrscheinlichkeit für das Eintreffen eines Ereignisses P(E)

$$P(E) = \frac{g}{m}$$

g: Anzahl der **günstigen** Ereignisse

m: Anzahl der **möglichen** Ereignisse

$$0 \leq P(E) \leq 1$$

M: Ereignisraum

$$M = \{ m_1; m_2; \dots; m_n \};$$

$m_i$ : Elementarereignisse

$$\sum_{i=1}^n P(m_i) = 1$$

$P(m_i)$ : Wahrscheinlichkeit des Eintreffens eines Elementarereignisses

### Gegeneignis $\bar{E}$

$$P(\bar{E}) = 1 - P(E)$$

$$P(E) + P(\bar{E}) = 1$$

### LAPLACE-Experiment

Sind bei einem Zufallsexperiment alle Ergebnisse des Ereignisraums **gleichwahrscheinlich**, so wird dies als LAPLACE-Experiment bezeichnet.

$$P(m_1) = P(m_2) = \dots = P(m_n);$$

$$P(m_i) = \frac{1}{n}$$

### Wahrscheinlichkeit des Eintreffens eines Ereignisses

Eintreffen des Ereignisses	
gewiss	$P(E) = 1$
wahrscheinlich	$1 > P(E) > 0,5$
zweifelhaft	$P(E) = 0,5$
unwahrscheinlich	$0,5 > P(E) > 0$
unmöglich	$P(E) = 0$

## Pfadregel


Wahrscheinlichkeit, dass das Ereignis  $E_1$  **oder** das Ereignis  $E_2$  eintritt:

$$P(E_1 \vee E_2) = P(E_1) + P(E_2)$$

$$P(\bar{E}) = 1 - P(E)$$


## Baumdiagramme

einstufiges Baumdiagramm



Pfadadditionsregel:  $P(E_1; \dots; E_n) = P(E_1) + P(E_2) + \dots + P(E_n) = 1$

zweistufiges Baumdiagramm



Pfadmultiplikationsregel  $P(E_1; \dots; E_n) = P(E_1) \cdot \dots \cdot P(E_n)$

$$P(E_1; E_1) = P(E_1) \cdot P(E_1)$$


$$P(E_1; E_2) = P(E_1) \cdot P(E_2)$$

## Bedingte Wahrscheinlichkeit

Wahrscheinlichkeit für ein Ereignis nach dem Eintreffen eines vorhergegangenen Ereignisses

$P_{E_m}(E_n)$ : Wahrscheinlichkeit für das n-te Ereignis, nachdem das m-te Ereignis eingetreten ist.

**Baumdiagramm**  
1. und 2. Stufe



**Vierfeldertafel**

		$E_2$	$\bar{E}_2$
	$E_1$	$E_1 \cap E_2$	$E_1 \cap \bar{E}_2$
	$\bar{E}_1$	$\bar{E}_1 \cap E_2$	$\bar{E}_1 \cap \bar{E}_2$

**Satz von Bayes**

$$P_{E_1}(E_2) = \frac{P(E_1 \cap E_2)}{P(E_1)} \quad \text{mit } P(E_1) \neq 0$$

**Inverses Baumdiagramm**

Die Ereignisse der ersten und zweiten Stufe gegenüber dem ursprünglichen Baumdiagramm sind vertauscht.

**Hypothesentest**

Überprüfung des Wahrheitsgehalts einer Hypothese

- Nullhypothese  $H_0$ : für wahr angesehene Behauptung
- Alternativhypothese  $H_A$ : alternative Theorie zur Nullhypothese

Bei jedem Hypothesentest wird ein Zufallsexperiment in Form einer Stichprobe der Länge  $n$  durchgeführt. Die **Testgröße Z** gibt die Zahl der Treffer im Stichprobenergebnis an.

Die Grenze zwischen **Annahmebereich A** und **Ablehnungsbereich A** heißt **kritischer Wert c**.

$$A = \{1; \dots; c\};$$

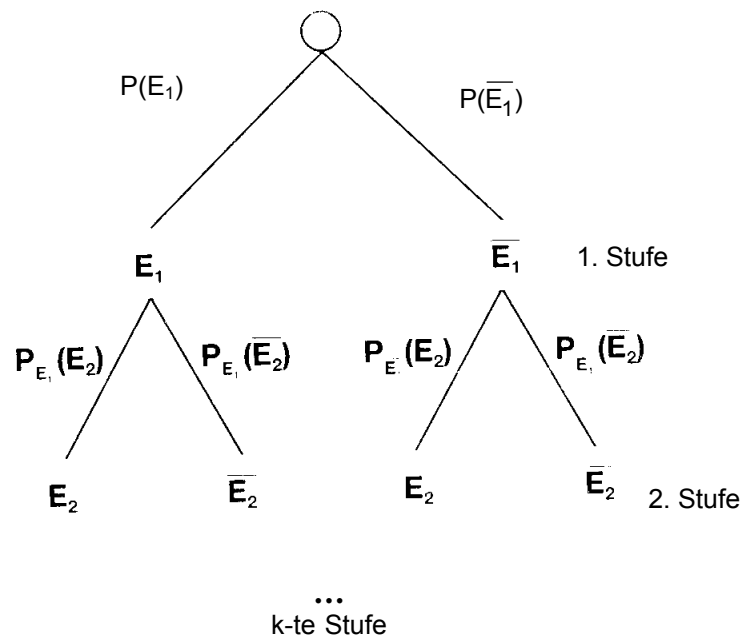
$$\bar{A} = \{c + 1; \dots; n\}$$

Der **Fehler 1. Art** ist der Fehler, eine wahre Hypothese abzulehnen.

Der **Fehler 2. Art** ist der Fehler, eine falsche Hypothese anzunehmen.

		Wahrheit	
		H <sub>0</sub>	H <sub>A</sub>
Ergebnis der Stichprobe	H <sub>0</sub>	richtig	Fehler 2.Art
	H <sub>A</sub>	Fehler 1.Art	richtig

### Binomialverteilung



Die Wahrscheinlichkeitsberechnung ist abhängig von der Gesamtzahl **n** der Einzelexperimente, der Wahrscheinlichkeit **p** des Eintreffens für ein Einzelexperiment und der Anzahl **k** der Treffer.

$$B(n; p; k) = \binom{n}{k} \cdot p^k \cdot (1-p)^{n-k}$$

$$\text{für } k \neq 0: \quad \binom{n}{k} = \frac{n}{1} \cdot \frac{n-1}{2} \cdot \frac{n-2}{3} \cdot \dots \cdot \frac{n-k+1}{k}$$

$$\text{für } k = 0: \quad \binom{n}{0} = 1$$