

Stichproben

Merkmaltyp

Kategorisch

- Ausprägung
- endlich

metrisch

- Zahlen
- endlich / unendlich

nominal

- Kategorie
- ohne Reihenfolge

ordinal

- Reihenfolge
- Ränge

diskret

- endlich
- abzählbar

stetig

- in Intervall

Bsp. Tiere

Bsp. Feedback



Bsp. Einwohner

Bsp. Nichtdieser

Absolute Häufigkeit

$n$  = Total Stichprobe



$h(x)$  = Anzahl



Relative Häufigkeit

in %  $\Rightarrow$  0-100%  
berechnet  $\Rightarrow$  0-1


$f(x) = \frac{h(x)}{n}$



Klassierte Daten & Häufigkeit

Histogramme

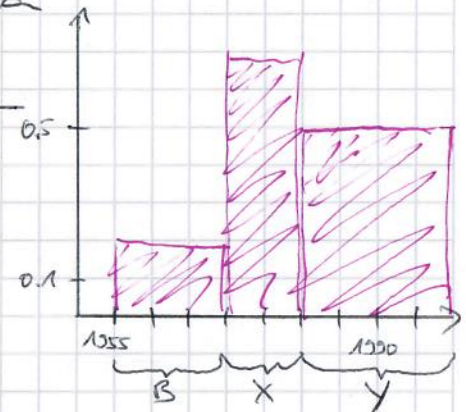
i	x	$b$	n	$h = \frac{n}{b}$
1	[0, 10[	10	2	0.2
2	[10, 20[	10	5	0.5
3	[20, 30[	10	3	0.3
4	[30, 40[	10	6	0.6
5	[40, 50[	10	4	0.4



Bsp. zwischen 30 & 40  
 $= 10 \cdot 0.6 = 6$  Personen

gleiche Klassenbreite

i	x	$b$	n	$h = \frac{n}{b}$
B	[55, 70[	15	3	0.2
X	[70, 80[	10	7	0.7
Y	[80, 100[	20	10	0.5



Bsp. Babyboomer  
 $= 15 \cdot 0.2 = 3$  Personen

variable Klassenbreite

Mittelwert = Durchschnitt

Bsp. [1, 7, 5, 4, 3]

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

$$\begin{aligned} \bar{x} &= \frac{1}{5} \cdot (1+7+5+4+3) \\ &= \frac{1}{5} \cdot 20 = \underline{4} \end{aligned}$$

Median

Lagekennwert

$$x_{\text{med}} = \begin{cases} x_{[\frac{n+1}{2}]} & \text{falls } n \text{ ungerade} \\ \frac{1}{2} (x_{[\frac{n}{2}]} + x_{[\frac{n}{2}+1]}) & \text{falls } n \text{ gerade} \end{cases}$$

Streuungskennwerte

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

$$\text{Standardabweichung} = s = \sqrt{s^2}$$

$$\text{korrigierte Varianz} = s_{\text{kor}}^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$\text{korrigierte Standardabweichung} = s_{\text{kor}} = \sqrt{s_{\text{kor}}^2}$$

Quantile

↙ nächst größerer ganzer ZS!

$$R_q = \lceil n \cdot q \rceil$$

- 1. Quartil = 0.25 Quantil
- 2. Quartil = Median
- 3. Quartil = 0.75 Quantil

Bsp. [0, 1, 3, 3, 4, 4, 5]

3. Quartil = 0.75 Quantil

$$n \cdot q = 7 \cdot 0.75 = 5.25 \Rightarrow 6$$

$$x_{(6)} = 4$$

$$\text{Interquartilsabstand} = Q_3 - Q_1$$

Pearson-Korrelationskoeffizient (auch korrigiert möglich)

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

$$s_y = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}$$

} Standardabweichungen

$$s_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$$

Kovarianz

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y}$$

Korrelationskoeffizient

Bsp.  $x = [1, 2, 3]$  &  $y = [-1, 2, 4]$

$$\bar{x} = \frac{1}{3} (1+2+3) = 2 \quad \bar{y} = \frac{1}{3} (-1+2+4) = \frac{5}{3}$$

$$s_x^2 = \frac{1}{3} [(1-2)^2 + (2-2)^2 + (3-2)^2] = \frac{2}{3} \quad s_x = \sqrt{\frac{2}{3}}$$


$$s_y^2 = \frac{1}{3} [(-1-\frac{5}{3})^2 + (2-\frac{5}{3})^2 + (4-\frac{5}{3})^2] = \frac{38}{9} \quad s_y = \sqrt{\frac{38}{9}}$$

$$s_{xy} = \frac{1}{3} [(1-2)(-1-\frac{5}{3}) + (2-2)(2-\frac{5}{3}) + (3-2)(4-\frac{5}{3})] = \frac{4}{3}$$

$$r_{xy} = \frac{s_{xy}}{s_x \cdot s_y} = \frac{2 \cdot \sqrt{57}}{19}$$

Boxplot

Bsp. [0, 1, 3, 3, 4, 4, 5]



$$Q_1 = n \cdot q = 7 \cdot 0.25 = 1.75 \Rightarrow \text{J. Wert} \Rightarrow 3$$

$$\text{Median} = 3$$

$$Q_4 = n \cdot q = 7 \cdot 0.75 = 5.25 \Rightarrow \text{6. Wert} \Rightarrow 4$$

$$\text{Interquartilsabstand} = Q_3 - Q_1 = 1$$

5 ⇒ in oberen Whisker/Antenne

0 & 1 ⇒ untere Ausreißer

Modus = Modalwert

Lagekennwert

Wert der am häufigsten vorkommt



Spearman-Rangkorrelationskoeffizient

zwischen Ränge & nicht Zahlen

Bsp.

	1	2	3	4	5	6	
$x_i$	59	35	43	23	42	27	
$y_i$	146	118	143	130	142	110	
$rg(x_i)$	6	3	5	1	4	2	$\overline{rg(x)} = 3.5$
$rg(x_i) - \overline{rg(x)}$	2.5	-0.5	1.5	-2.5	0.5	-1.5	
$rg(y_i)$	6	2	5	3	4	1	$\overline{rg(y)} = 3.5$
$rg(y_i) - \overline{rg(y)}$	2.5	-1.5	1.5	-0.5	0.5	-2.5	

$$r_{sp} = \frac{\sum (rg(x_i) - \overline{rg(x)})(rg(y_i) - \overline{rg(y)})}{\sqrt{\sum (rg(x_i) - \overline{rg(x)})^2} \cdot \sqrt{\sum (rg(y_i) - \overline{rg(y)})^2}}$$

$$= \frac{14.5}{\sqrt{12.5} \cdot \sqrt{12.5}} = 0.83$$

⇒ Fall gleiche Zahlen, dann Durchschnitt der Ränge nehmen

Kombinatorik

$n! = n(n-1)!$

Fakultät

Bsp.  $5! = 5 \cdot 4 \cdot 3 \cdot 2 \cdot 1$

$\binom{n}{k} = \frac{n!}{(n-k)! \cdot k!}$

Binomialkoeffizient

Variation (mit Reihenfolge)		Kombination (ohne Reihenfolge)	
mit W.	ohne W.	mit W.	ohne W.
$n^k$	$\frac{n!}{(n-k)!}$	$\binom{n+k-1}{k}$	$\binom{n}{k}$
Bsp. 1	Bsp. 2	Bsp. 3	Bsp. 4

} Wiederholung

Bsp. 1 ⇒ Zahlenlotterielos

6 Kugeln & 10 Ziffern ⇒  $10^6$  Möglichkeiten

Bsp. 2 ⇒ Schwimwettkampft

3 Plätze & 10 Schwimmer  $\frac{10!}{(10-3)!} = \underline{720}$  Möglichkeiten

Bsp. 3 ⇒ Teilschießen

3 Versuche & 11 Bereiche ⇒  $\binom{13}{3} = \underline{286}$  Möglichkeiten

Bsp. 4 ⇒ Lotto

6 aus 49 ohne Zurücklegen ⇒  $\frac{49!}{43! \cdot 6!} = \underline{13'983'816}$  Möglichkeiten

diskrete Wahrscheinlichkeitsmaße

Ergebnisraum  $\Omega = \{ \dots \}$  (Omega)

Zahlfunktion  $p = \dots$  (P)

Bsp. Einzelwürfel mit fairem Würfel

$\Omega = \{1, 2, 3, 4, 5, 6\}$ , Wahrscheinlichkeit für die Zahl 5  $\Rightarrow p = 1/6$

Counting - Raum

$$P(M) = \frac{|M|}{|\Omega|} \quad (|M| = \text{Anzahl Elemente der Menge } M)$$

Eigenschaften:

$P(\{\emptyset\}) = 0$  unmögliches Ergebnis

$P(\Omega) = 1$  sicheres Ereignis

$P(\Omega \setminus A) = 1 - P(A)$  Komplementäres Ereignis

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

$P(A_1 \cup A_2 \cup A_3 \cup \dots) = P(A_1) + P(A_2) + \dots$

Sigma-Additivität

Zufallsvariable

Am Beispiel vom zweifachen Würfeln mit einem fairen Würfel.

Ergebnisraum  $\Omega = \{(1,1), (1,2), \dots, (6,6)\}$

$\Rightarrow 6 \cdot 6 \text{ Elemente} = 36$

Wahrscheinlichkeit für  $p(1,1) = p(5,6) = 1/36$

$P(X=2) \Rightarrow$  Summe der beiden Würfel

$$f(2) = P(X=2) = 1/36$$

$$f(2,3) = P(X=2,3) = 0$$

PDF

$$f(11) = P(X=11) = 2/36 = 1/18$$

$$f: \mathbb{R} \rightarrow [0,1], f(x) = P(X=x)$$

$$F(4) = P(X \leq 4) = P(X=4) + P(X=3) + P(X=2) = 6/36 = 1/6$$

$$F(x) = P(X \leq x) \quad \text{CDF}$$

⋮

$$P(7 \leq X \leq 10) = F(10) - F(6) = 33/36 - 15/36 = 1/2$$

$$P(X > 10) = 1 - F(10) = 1 - 33/36 = 1/12$$

$$P(X=3 \text{ oder } X=7) = f(3) + f(7) = 2/36 + 6/36 = 2/9$$

$$P(X \neq 4) = 1 - f(4) = 1 - 3/36 = 11/12$$



Kenngrößen

$\mu = E(X) = \text{Erwartungswert}$

$\sigma^2 = V(X) = \text{Varianz}$

$\sigma = S(X) = \text{Standardabweichung}$

An einem Beispiel mit einer Zufallsvariable

X	-1	0	1	2
f(x)	0.2	0.1	0.4	0.3

$\mu = 0.2 \cdot (-1) + 0.1 \cdot 0 + 0.4 \cdot 1 + 0.3 \cdot 2 = \underline{0.8}$

$\sigma^2 = 0.2(-1-0.8)^2 + 0.1(0-0.8)^2 + 0.4(1-0.8)^2 + 0.3(2-0.8)^2 = \underline{1.16}$

$\sigma = \sqrt{\sigma^2} = \sqrt{1.16} = \underline{1.077}$

Bedingte Wahrscheinlichkeiten

Wahrscheinlichkeit für B, wenn A eintritt

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

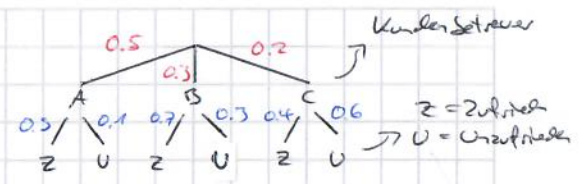
Multiplikationssatz

$\Rightarrow P(A \cap B) = P(A) \cdot P(B|A) = P(B) \cdot P(A|B)$

Satz von Bayes

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

Beispiel einer bedingten Wahrscheinlichkeit



W für A & Z  
 $\Rightarrow P(A \cap Z) = P(A) \cdot P(Z|A) = 0.5 \cdot 0.9 = \underline{0.45}$

Kundenbetreuung  
 Zufriedenheitsindex

W für U  
 $\Rightarrow P(U) = 0.5 \cdot 0.1 + 0.3 \cdot 0.3 + 0.2 \cdot 0.6 = \underline{0.26}$

W für Z & C  
 $\Rightarrow P(C|Z) = \frac{P(C \cap Z)}{P(Z)} = \frac{0.4 \cdot 0.2}{0.5 \cdot 0.9 + 0.3 \cdot 0.7 + 0.2 \cdot 0.4} = \underline{0.108}$

W für U & B  
 $\Rightarrow P(B|U) = \frac{P(B \cap U)}{P(U)} = \frac{0.3 \cdot 0.3}{0.26} = \underline{0.35}$

Stochastische Unabhängigkeit

abhängig

stochastisch unabhängig wenn  $P(A \cap B) = P(A) \cdot P(B)$

Beispiel mit Würfeln, ein- und zweifaches Würfeln

$P(\text{gerade} \cap \geq 3) = \frac{|\{4, 6\}|}{|S_2|} = \frac{1}{3}$   
 $P(\text{gerade}) \cdot P(\geq 3) = \frac{1}{2} \cdot \frac{2}{3} = \frac{1}{3}$

gerade: {2, 4, 6}  
 $\geq 3$ : {3, 4, 5, 6}  
 3er W: {3, 6}

$P(\geq 3 \cap 3er W) = \frac{|\{3, 6\}|}{|S_2|} = \frac{1}{3}$   
 $P(\geq 3) \cdot P(3er W) = \frac{2}{3} \cdot \frac{1}{3} = \frac{2}{9}$

wenn X & Y unabhängig

$\Rightarrow E(X \cdot Y) = E(X) \cdot E(Y)$

$\Rightarrow V(X + Y) = V(X) + V(Y)$

Diskrete Verteilungen

diskret  $\Rightarrow$  nur ganzzahlige Werte

Hypergeometrische Verteilung:  $N =$  total Objekte  
 $M =$  bestimmte Objekte  
 $n =$  Stichprobengröße  
 $x =$  Anzahl bestimmter Objekte in Stichprobe

$$P(X=x) = \frac{\binom{M}{x} \cdot \binom{N-M}{n-x}}{\binom{N}{n}}$$

$$\mu = E(X) = n \cdot \frac{M}{N} \quad \sigma = \sigma(X) = \sqrt{\sigma^2}$$

$$\sigma^2 = V(X) = n \cdot \frac{M}{N} \left(1 - \frac{M}{N}\right) \frac{N-n}{N-1}$$

Bernoulli-Verteilung: 1 oder 0

$$P(X=1) = p \quad / \quad P(X=0) = q = 1-p$$

$$P(X=x) = \binom{n}{x} \cdot p^x \cdot q^{n-x} \quad n = \text{Anzahl Wiederholungen}$$

$$\mu = E(X) = n \cdot p \quad / \quad \sigma^2 = V(X) = n \cdot p \cdot q$$

Poisson-Verteilung: Wahrscheinlichkeit für das Eintreten von  $x$  bestimmten Anzahl gleichzeitiger Ereignisse

$$P(X=x) = \frac{\lambda^x}{x!} e^{-\lambda}, \quad \lambda > 0$$

$$\mu = E(X) = \lambda \quad / \quad \sigma^2 = V(X) = \lambda$$

Beispiel  $\Rightarrow$  120 Anrufe pro Stunde, ist ein Anruf ein Miss?

$$\text{kein Anruf} \Rightarrow P(X=0) = \frac{2^0}{0!} e^{-2} = e^{-2} = \underline{0.135}$$

$$1 \text{ Anruf} \Rightarrow P(X=1) = \frac{2^1}{1!} e^{-2} = 2e^{-2} = \underline{0.271}$$

stetige Verteilungen

stetig  $\Rightarrow$  im Intervall, auch nicht ganzzahlige Werte

Gauss-Verteilung / Normalverteilung:  $\sigma > 0$

$$\varphi_{\mu, \sigma}(x) = \frac{1}{\sqrt{2\pi} \cdot \sigma} \cdot e^{-\frac{1}{2} \left(\frac{x-\mu}{\sigma}\right)^2}$$

Wenn  $\mu = 0$  &  $\sigma = 1$

$$\Rightarrow \varphi(x) = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{1}{2}x^2} \quad (\text{Standard normalverteilung})$$

$$E(X) = \mu \quad / \quad V(X) = \sigma^2 \quad \Rightarrow \text{Tabelle 1}$$

Bsp. standard normalverteilung  $P(X \leq 0.45) = \underline{0.6736}$   
 normalverteilung  $\Rightarrow U = \frac{x-\mu}{\sigma}$

Zentraler Grenzwertsatz:

$$S_n = \sum_{i=1}^n X_i \quad n \rightarrow \infty$$

$$U_n = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \quad \lim_{n \rightarrow \infty} F_n(u) = \Phi(u) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^u e^{-\frac{t^2}{2}} dt$$

Beispiel  $\Rightarrow T_i: 1$  für  $1 < t < 2$ , sonst 0

$$\mu = \underline{1.5} \quad / \quad \sigma^2 = \int_1^2 \left(t - \frac{3}{2}\right)^2 \cdot 1 dt = \left[\frac{t^3}{3} - \frac{3}{2}t^2 + \frac{9}{4}t\right]_1^2 = \underline{\frac{1}{12}}$$

$$T = 6 \cdot 1.5 = \underline{9} \quad / \quad \sigma^2 = 6 \cdot \frac{1}{12} = \underline{\frac{1}{2}}$$

$$P(T > 10) = 1 - \Phi\left(\frac{10-9}{\sqrt{\frac{1}{2}}}\right) = 1 - \Phi(1.414) = \underline{\underline{0.0787}}$$



Lineare Regression

Regressionsgerade  $g(x) = mx + d$

Steigung  $m = \frac{s_{xy}}{s_x^2}$

y-Achsenabschnitt  $d = \bar{y} - m\bar{x}$

Residuenvarianz  $S_e^2 = s_y^2 - \frac{s^2_{xy}}{s_x^2}$

Varianz  $x_i$ -Werte  $s_x^2 = (\frac{1}{n} \sum x_i^2) - \bar{x}^2$

Varianz  $y_i$ -Werte  $s_y^2 = (\frac{1}{n} \sum y_i^2) - \bar{y}^2$

Kovarianz  $s_{xy} = (\frac{1}{n} \sum x_i y_i) - \bar{x} \cdot \bar{y}$

prognostizierte Varianz  $s_{\hat{y}}^2 = s_y^2 - S_e^2$

Bestimmtheitsmass  $R^2 = \frac{s_{xy}^2}{s_x^2 \cdot s_y^2}$

= Korrelationskoeffizient  $R^2 = \frac{s_{xy}^2}{s_x^2 \cdot s_y^2} = r_{xy}^2$

Nicht Lineares Verhalten  $\Rightarrow$  Linearisieren

$y = q \cdot x^m$

$\log(y) = \log(q) + m \cdot \log(x)$

$y = q \cdot m^x$

$\log(y) = \log(q) + \log(m) \cdot x$

$y = q \cdot e^{ux}$

$\ln(y) = \ln(q) + u \cdot x$

$y = \frac{1}{q + m \cdot x}$

$V = q + m \cdot x / V = \frac{1}{y}$

$y = q + m \cdot \ln(x)$

$y = q + m \cdot U / U = \ln(x)$

Schließende Statistik

$\Rightarrow$  Blatt 7.3.3

Beispiel 95% - Vertrauensintervall:

$\alpha^2 = 118 / n$  für 95% = ?

i	1	2	3	4	5	6	7	8
$x_i$	140	162	128	136	148	147	151	128

$\bar{x} = \frac{1}{8} (140 + 162 + 128 + 136 + 148 + 147 + 151 + 128) = 138$

$e = c \cdot \frac{\sigma}{\sqrt{n}} = 1.96 \cdot \frac{10.86}{\sqrt{8}} = 7.53$

$\phi(c) = \frac{1+\alpha}{2} = \frac{1+0.95}{2} = 0.975$

Tabelle 2

$p = \phi(c) = 0.975 \Rightarrow c = 1.960$

$\mu: [\bar{x} - e; \bar{x} + e] = [130.47; 145.53]$

Beispiel (ortswahrscheinlichkeit  $\alpha = 1\%$ ):

$n = 500 / k = 25 / \mu = ? / y = 0.99$

Problem 4  $\Rightarrow n \hat{p} (1 - \hat{p}) = 500 \cdot 0.05 \cdot 0.95 = 23.75 > 9 \checkmark$

$\hat{p} = \bar{x} = \frac{25}{500} = 0.05$

$p = \phi(c) = \frac{1+\alpha}{2} = 0.995 \Rightarrow c = 2.576$

$e = c \cdot \sqrt{\frac{\bar{x} \cdot (1 - \bar{x})}{n}} = 2.576 \cdot \sqrt{\frac{0.05 \cdot 0.95}{500}} = 0.0251$

$\mu: [\bar{x} - e; \bar{x} + e] = [0.0249; 0.0751]$