

DESKRIPTIVE STATISTIK

<b>nominale Merkmale</b>	lassen sich nicht in natürlicher Weise anordnen
<b>ordinale Merkmale</b>	lassen sich in natürlicher Reihenfolge anordnen
<b>diskrete Merkmale</b>	Wertebereich abzählbar, aber möglicherweise unendlich
<b>stetige Merkmale</b>	Merkmale, die prinzipiell jeden beliebigen Wert (in einem Intervall) annehmen
Grundgesamtheit: $\Omega$	$h_i$ : absolute Häufigkeit einer Merkmalsausprägung $a_i$
Grösse Stichprobe: $n$	$h_1 + h_2 + \dots + h_m = n$
Objekte: $\omega_1, \omega_2, \dots, \omega_n$	$f_i$ : relative Häufigkeit, $f_i = \frac{h_i}{n}$ , ( $f_1 + f_2 + \dots + f_m = 1$ )
Merkmale: $X(\omega_i) = x_i$	Höhe eines Balkens/Stabes der PMF

KUMULATIVE HÄUFIGKEIT

$H(x) = \text{Anzahl aller Stichprobenwerte} \leq X$

empirische relative Summenhäufigkeit:  
Klasse  $\rightarrow \frac{H(x)}{n} \rightarrow$  rechter Wert Klasse

$$H(x) = \sum_{i:a_i \leq x} h_i \rightarrow \text{absolut}$$

$$F(x) = \frac{H(x)}{n} = \sum_{i:a_i \leq x} f_i \rightarrow \text{relativ}$$

ABSOLUTE HÄUFIGKEIT (RECHTECKSFLÄCHE)

Höhe Rechteck:  $h(x) = \frac{h_i}{a_i}$  (abs. Häufigkeitsdichte) und  $f(x) = \frac{f_i}{a_i}$  (rel. Häufigkeitsdichte)

$d_i$ : Klassenbreite (Breite im Intervall, Säulenbreite im Histogramm)

RELATIVE HÄUFIGKEITSDICHTEFUNKTION (PDF)

$$f(x) = \frac{h(x)}{n}, f: \mathbb{R} \rightarrow [0,1]$$

KUMULATIVE VERTEILUNGSFUNKTION (CDF)

$$F(x) = \int_{-\infty}^x f(t) dt, (\text{Integration von PDF})$$

in Klassen:

$$F(x) = \frac{F(B)}{B - A} \cdot (X - A) + F(A)$$

LAGEMASSE

arithmetisches Mittel:

$$\bar{x} = \frac{1}{n} \sum_1^m x_i = \frac{1}{n} \sum_1^m h_i \cdot a_i = \sum_1^m f_i \cdot a_i$$

Median: 0.5 – Quantil = Median/Zentralwert  $\rightarrow$  teilt in 2 gleich grosse Hälften

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

Modus  $x_{mod}$ :

- "Maximum der PMF/PDF"
- häufigster Stichprobenwert  $\rightarrow$  Wert der am meisten vorkommt

rechtsschief	$x_{mod} < x_{med} < \bar{x}$
symmetrisch	$x_{mod} = x_{med} = \bar{x}$
linksschief	$x_{mod} > x_{med} > \bar{x}$

STREUMASSE

Varianz:

$$s^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^m h_i (a_i - \bar{x})^2 = \sum_{i=1}^m a_i^2 \cdot f_i - \bar{x}^2$$

korrigierte Varianz:

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

Standardabweichung:

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

korr. Standardabweichung:

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

$\rightarrow$  ! Bei klassierten Daten Klassenmitte verwenden!

## KENNGRÖSSEN

Interquartilsabstand (IQR):  $3. \text{Quartil} - 1. \text{Quartil} = Q_3 - Q_1$

Mean absolute deviation MAD:  $1.4826 \cdot \text{median}(|x_1 - \bar{x}|, |x_2 - \bar{x}|, \dots, |x_n - \bar{x}|)$

Perzentil/Quantile  $q$ : Zahl  $R$  teilt Stichprobenwerte im Verhältnis  $q$ :  $(1 - q)$

$$R_q = \frac{1}{2} \cdot (x_{[n \cdot q]} + x_{[n \cdot q + 1]}) \quad n \cdot q = \text{ganze Zahl}$$

$$R_q = x_{[n \cdot q]} \quad n \cdot q \neq \text{ganze Zahl, mit } n \cdot q \text{ nächstgrössere Zahl}$$

Quartile:  $Q_1: R_{0.25}, Q_2 = \text{Median}: R_{0.5}, Q_3: R_{0.75} \rightarrow 1, 2, 3 \text{ Quartil}$

bei klassierten Daten mit Verteilfunktion:  $Rq = F^{-1}(q)$

Klasse suchen in der  $q$  ist

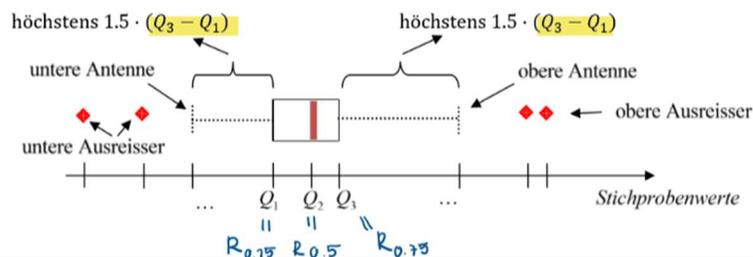
$$\frac{F(b) - F(a)}{b - a} = \frac{q - F(a)}{R_q - a}$$

$$R_q = a + \frac{(b - a)}{F(b) - F(a)} (q - F(a))$$

*Wert von nächster Klasse links nehmen*

$$F(a) = \frac{\widehat{\text{absolut}}}{n}$$

## BOXPLOT



Interquartilsabstand (IQR):  $3. \text{Quartil} - 1. \text{Quartil} = Q_3 - Q_1$

untere Antenne:  $1.5 \cdot (Q_3 - Q_1)$  von  $Q_1$  |  $Q_1 - 1.5 \cdot IQR$

obere Antenne:  $1.5 \cdot (Q_3 - Q_1)$  von  $Q_3$  |  $Q_3 + 1.5 \cdot IQR$

➔ IMPORTANT! Alles Werte!

## KORRELATION

**Pearson**-Korrelation misst Stärke/Richtung des linearen Zusammenhangs

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{s_{xy}}{s_x \cdot s_y}$$

$\bar{x} = \frac{1}{n} \sum_{i=1}^n x$ (arithm. Mittelwert)	$\overline{x^2} = \frac{1}{n} \sum_{i=1}^n x^2$
$\bar{y} = \frac{1}{n} \sum_{i=1}^n y$ (arithm. Mittelwert)	$\overline{y^2} = \frac{1}{n} \sum_{i=1}^n y^2$
$s_x = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} = \sqrt{\overline{x^2} - \bar{x}^2}$ (Standardabweichung)	$s_{x\text{korr}} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$ (korr. Standardabweichung)
$s_y = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} = \sqrt{\overline{y^2} - \bar{y}^2}$ (Standardabweichung)	$s_{y\text{korr}} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2}$ (korr. Standardabweichung)
$s_{xy} = \overline{xy} - (\bar{x} \cdot \bar{y}) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$ (Kovarianz)	$s_{xy\text{korr}} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$ (korr. Kovarianz)
$\overline{xy} = \frac{1}{n} \sum_{i=1}^n x_i \cdot y_i$	$\overline{x^2} = \frac{1}{n} \sum_{i=1}^n x_i \cdot x_i$ $\overline{y^2} = \frac{1}{n} \sum_{i=1}^n y_i \cdot y_i$

Korrelation: immer  $-1 \leq r_{xy} \leq 1$

$r_{xy} > 1$	<b>positive</b> Korrelation
$r_{xy} < -1$	<b>negative</b> Korrelation
$r_{xy} = 1$	Punkte genau auf Gerade mit <b>positiver</b> Steigung
$r_{xy} = -1$	Punkte genau auf Gerade mit <b>negativer</b> Steigung
$r_{xy} \text{ nah an } \pm 1$	Punkte streuen eng um Gerade
$r_{xy}$	kein linearer Zusammenhang

**Spearman** Rangkorrelation misst Stärke/Richtung des monotonen Zusammenhangs

$$r_{sp} = \frac{\sum_{i=1}^n \left( rg(x_i) - \frac{n+1}{2} \right) \left( rg(y_i) - \frac{n+1}{2} \right)}{\sqrt{\sum_{i=1}^n \left( rg(x_i) - \frac{n+1}{2} \right)^2} \sqrt{\sum_{i=1}^n \left( rg(y_i) - \frac{n+1}{2} \right)^2}}$$

$$r_{sp} = 1 - \frac{6 \cdot \sum_{i=1}^n d_i^2}{n \cdot (n^2 - 1)} \text{ mit } d_i = rg(x_i) - rg(y_i)$$

→ 2.te nur wenn keine Bindungen!!

Kovarianz Rangliste:

$$\frac{1}{n} \sum_{i=1}^n (rg(x_i) - \overline{rg(x)})(rg(y_i) - \overline{rg(y)})$$

\*insert absolute Häufigkeits, PDF, PMF, etc. examples

### KOMBINATORIK

	Ohne Wiederholungen/ ohne zurücklegen	Mit Wiederholungen/ mit zurücklegen
<b>Auswahl <math>k = n</math> Reihenfolge wichtig!</b>	Permutation, ohne Wiederholung $z = n!$ "ABC anordnen"	Permutation mit Wiederholung $z = \frac{n!}{n_1! \cdot \dots \cdot n_s!}$ "ANNA anordnen"
<b>Auswahl <math>k</math> Reihenfolge wichtig! <math>n</math>: wird gezogen <math>k</math>: Anzahl Ziehungen</b>	geordnete Stichprobe ohne zurücklegen Es gilt $k < n$ $z = \frac{n!}{(n-k)!}$ "Nummer aus Schüssel behalten"	geordnete Stichprobe mit zurücklegen $k$ beliebig $z = n^k$ "aus Schüssel & zurücklegen"
<b>Auswahl <math>k</math> Reihenfolge unwichtig!</b>	ungeordnete Stichproben ohne zurücklegen Es gilt $k < n$ $z = \binom{n}{k} = \frac{n!}{k!(n-k)!}$ "3 aus 6" Binomialkoeffizient	ungeordnete Stichprobe mit zurücklegen $k$ beliebig $z = \binom{n+k-1}{k} = \frac{(n-1+k)!}{k!(n-1)!}$ "3 aus 6"

### ELEMENTARE WAHRSCHEINLICHKEITSRECHNUNG

$\Omega$ : Menge aller möglichen Ereignisse: Ergebnisraum

$|\Omega|$ : Mächtigkeit

Ereignis: Teilmenge  $A$  von  $\Omega$ , z.B. alle geraden Zahlen  $A = \{2,4,6, \dots\}$

Elementarereignis =  $\{\omega_i\}, \{\omega_2\}$  enthalten nur ein Ergebnis

Ereignisraum: Menge aller Teilmengen von  $\Omega$  (Potenzmenge von  $\Omega$ )  $\rightarrow 2^{|\Omega|}$

Zähldichte: PDF  $\rho: \Omega \rightarrow [0,1] \rightarrow$  mit welcher Wahrscheinlichkeit Ergebnisse auftreten

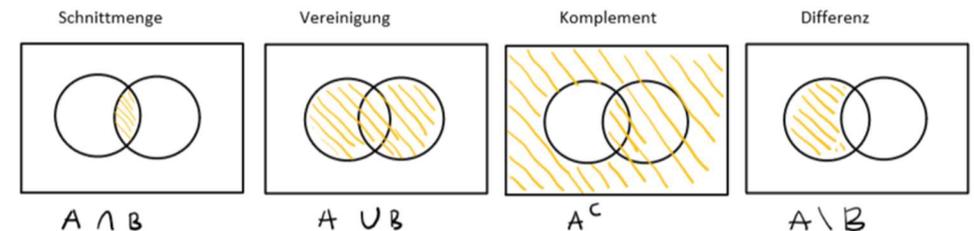
Wahrscheinlichkeitsmass  $P$  ist eine Funktion  $P: 2^\Omega \rightarrow [0,1]$  mit welcher

Wahrscheinlichkeit das Ergebnis, das durch die Menge  $M$  beschrieben wird, eintritt.

Gegenereignis von  $A = A^c$  mit  $A \cup A^c = \Omega$

Sicheres Ereignis  $A = \Omega$

Unmögliches Ereignis  $A = \{\}$  (leere Menge)



Laplace Wahrscheinlichkeit

$$P(M) = \frac{|M|}{|\Omega|} = \frac{\text{Anzahl günstige Fälle}}{\text{Anzahl mögliche Fälle}}$$

Frequentistische Wahrscheinlichkeit

$$P(A) = v_A$$

Axiome von Kolgarov

Axiom 1:	$0 \leq P(A) \leq 1$
Axiom 2: sicheres Ereignis	$P(\Omega) = 1$
Axiom 3: Vereinigung	Falls $A \cap B = \{\}$ dann gilt $P(A \cup B) = P(A) + P(B)$
Unmögliches Ereignis	$P(\{\}) = 0$
Komplementäres Ereignis	$P(\Omega \setminus A) = P(\bar{A}) = P(A^c) = 1 - P(A)$
Sigma Additivität	$P(A_1 \cup A_2 \cup \dots) = P(A_1) + P(A_2) + \dots$ falls disjunkt

diskrete Zufallsvariabel: endlich, unendlich abzählbarer Wert

stetige Zufallsvariabel: x-beliebiger Wert von Intervall

Wahrscheinlichkeitsfunktion (PDF):  $p_i = f(x_i) = P(X = x_i)$

$\sum_i p_i = 1$ , wenn alle  $p_i$  gleich sind  $\rightarrow$  diskrete Gleichverteilung

kumulative Verteilungsfunktion CDF:  $F(x) = P(X \leq x)$

Erwartungswert:  $E(x) = \mu = \sum x_i \cdot P(X = x) = \sum x_i \cdot p(x_i) = \sum x_i \cdot p_i$

Varianz:  $Var(x) = E[(X - E[X])^2] = \sum_{i=1}^n (x_i - E[X])^2 p_i$

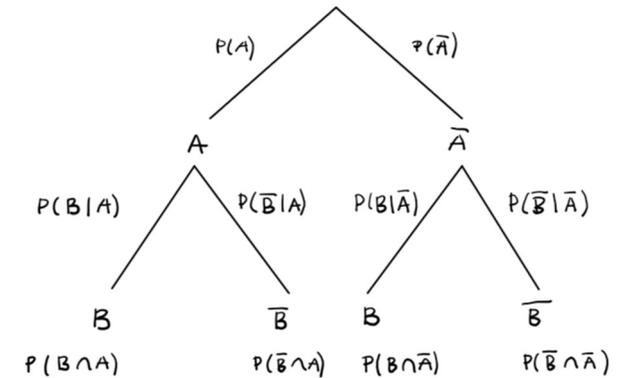
$$Var(X) = E[x^2] - (E[x])^2$$

$$Var(X) = \left( \sum_{i=1}^n x_i^2 p_i \right) - (E[x])^2$$

Ereignisraum

- Wahrscheinlichkeit am Ende des Pfades (Blatt)  $\rightarrow$  Multiplikation
- von mehreren Pfaden beschriebene Wahrscheinlichkeit  $\rightarrow$  Addition

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



bedingte Wahrscheinlichkeit  $\rightarrow$  gegeben, dass

Prävalenz	$P(k^+) \rightarrow 1 - (Pk^+) \rightarrow P(k^-)$
Sensitivität	$P(A^+ k^+) \rightarrow P(A^- P^-)$
Spezifität	$P(A^- k^-) \rightarrow P(A^+ k^-)$

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

SATZ VON BAYES

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

SATZ DER TOTALEN WAHRSCHEINLICHKEIT

$$P(A) = \sum_{i=1}^k P(A|B_i) \cdot P(B_i)$$

$$P(B_i|A) = \frac{P(B_i \cap A)}{P(A)} = \frac{(P(A|B_i) \cdot P(B_i))}{\sum_{i=1}^k P(A|B_i) \cdot P(B_i)}$$

$$P(B) = P(A) \cdot P(B|A) + P(\bar{A}) \cdot P(B|\bar{A})$$

MULTIPLIKATIONSSATZ

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

Stochastische Unabhängigkeit:

$$P(A|B) = P(A) \text{ mit } P(B) \neq 0$$

## SPEZIELLE VERTEILUNGEN – DISKRETE VERTEILUNGEN

### UNIFORMVERTEILUNG

Ergebnisraum:  $\Omega = \{a, a + 1, \dots, b - 1, b\}$  (endlich)

Erwartungswert:  $E[X] = \frac{a+b}{2}, X \sim Unif(\{a, b\})$

Varianz:  $Var[X] = \frac{(b-a+2)(b-a)}{12} = \frac{(b-a+1)^2 - 1}{12}$

### BERNOULLIVERTEILUNG

- Zufallsvariable kann 2 Werte annehmen  $P(X = 1) = p$  oder  $P(X = 0) = 1 - p$

$P = P(X = 1)$  Erfolgswahrscheinlichkeit

Ergebnisraum:  $\Omega = \{0, 1\}, X \sim Bernoulli(p)$

Erwartungswert:  $E[X] = 0 \cdot (1 - p) + 1 \cdot p = p$

$$E[X^2] = 1^2 \cdot P(X = 1) = 1 \cdot p = p$$

Varianz:  $Var[X] = E[X^2] - E[X]^2 = (0 - p)^2(1 - p) + (1 + p)^2 \cdot p = p(1 - p) = p \cdot q$

### BINOMINALVERTEILUNG

$$P(X = k) = \binom{n}{k} p^k (1 - p)^{n-k}, X \sim B(n, p)$$

Ergebnisraum:  $\Omega = \{0, 1, 2, \dots, n\}$  (endlich)

Erwartungswert:  $\mu = E[X] = E(\sum_{i=1}^n X_i) = \sum_{i=1}^n E(x_i) = \sum_{i=1}^n p = n \cdot p$

Varianz:  $\sigma^2 = V[X] = Var(\sum_{i=1}^n X_i) = \sum_{i=1}^n Var(x_i) = n \cdot p(1 - p)$

Standardabweichung:  $\sigma = S(X) = \sqrt{npq}$

Symmetrie für  $p = 0.5$  bei wachsenden  $p \neq 0.5$  immer symmetrisch falls  $n \cdot p(1 - p) > 10$ , gilt  $Bin(n, p)$  als symmetrisch

### POISSONVERTEILUNG

$$P(X = x) = \frac{\lambda^x \exp(-\lambda)}{x!}, X \sim Pois(\lambda)$$

Ergebnisraum:  $\Omega = \{0, 1, 2, \dots\}$  (abzählbar, unendlich)

Erwartungswert:  $\lambda = E[X]$  für kleine  $\lambda \rightarrow$  stark rechtsschief

Varianz:  $Var[X] = \lambda$  je grosser  $\lambda \rightarrow$  Symmetrie bei  $\lambda > 10$

Standardabweichung:

### HYPERGEOMETRISCHE VERTEILUNG

$$P(X = k) = \frac{\binom{M}{k} \cdot \binom{N-M}{n-k}}{\binom{N}{n}}, X \sim H(N, M, n)$$

Ergebnisraum:  $\Omega = \{0, 1, \dots, N\}$  (endlich)

Erwartungswert:  $\mu = E[X] = n \cdot \frac{M}{N}$

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

Standardabweichung:  $\sigma = S(X) = \sqrt{n \cdot \frac{M}{N} \left(1 - \frac{M}{N}\right) \left(\frac{N-n}{N-1}\right)} = \sqrt{V(X)}$

$N$ : Objekte Total
$M$ : Merkmale Total
$N - M$ : Objekte anderer Sorte
$n$ : gezogene Objekte ohne Zurücklegen

## SPEZIELLE VERTEILUNGEN – STETIGE VERTEILUNGEN

### STETIGE WAHRSCHEINLICHKEITSFUNKTION PDF

$f(x) \geq 0$  für alle  $x \in \mathbb{R}$

$f$  ist integrierbar

$$\int_{-\infty}^{\infty} f(u) du = 1$$

CDF

$$F(x) = P(X \leq x) = \int_{-\infty}^x f(u) du$$

### KENNZAHLEN STETIGER ZUFALLSVARIABLEN

Erwartungswert:  $\mu = E[X] = \int_{-\infty}^{\infty} f(x) \cdot x dx$

Varianz:  $\sigma^2 = V(x) = \int_{-\infty}^{\infty} f(x) \cdot (x - E[X])^2 dx$

Standardabweichung:  $\sigma = \sqrt{V(x)}$

$$P(X \leq a) = F(a) = \int_{-\infty}^a f(x) dx$$

$$P(X > a) = 1 - P(X \leq a) = 1 - F(a) = 1 - \int_{-\infty}^a f(x) dx = \int_a^{\infty} f(x) dx$$

$$P(a \leq X \leq b) = P(X \leq b) - P(X \leq a) = F(b) - F(a) = \int_a^b f(x) dx$$

	diskret	stetig
Wertebereich	abzählbar	beliebig
Wahrscheinlichkeitsfunktion	$p_i = P(X = x_i)$ $\sum_{i=1}^n p_i = 1$	$f(x) \geq 0, \int_{-\infty}^{\infty} f(z) dz = 1$ stetig
kumulative Verteilfunktion $F(x) = P(x \leq \lambda)$	$F(x) = \sum p_i$	$F(x) = \int_{-\infty}^x f(z) dz$
Kennzahlen	$\mu = \sum x_i p_i$ $\sigma^2 = \sum (x_i - \mu)^2$	$\mu = \int_{-\infty}^{\infty} x f(x) dx$ $\sigma^2 = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx$

## STETIGE UNIFORMVERTEILUNG

Erwartungswert:  $E[X] = \frac{a+b}{2}, X \sim Unif([a, b])$

Varianz:  $Var(x) = \frac{(b-a)^2}{12}$

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

## DICHTEFUNKTION NORMALVERTEILUNG PDF

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2} \cdot \frac{(x-\mu)^2}{\sigma^2}\right\} \text{ für } X \in (-\infty, \infty)$$

$X \sim N(\mu, \sigma^2)$

- Dichtefunktion symmetrisch um  $X = \mu$
- nähert sich asymptotisch der 0 an

## KUMULATIVE VERTEILFUNKTION CDF

$$F(x) = P(X \leq x) = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^x \exp\left\{-\frac{1}{2} \cdot \frac{(z-\mu)^2}{\sigma^2}\right\} dz$$

Standardnormalverteilung

$$\Phi u = Fu$$

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

beliebige Normalverteilung muss standardisiert werden

$$u = \frac{X - \mu}{\sigma}$$

innerhalb  $[\mu - \sigma, \mu + \sigma] = 68\%$

innerhalb  $[\mu - 2\sigma, \mu + 2\sigma] = 95\%$

innerhalb  $[\mu - 3\sigma, \mu + 3\sigma] = 99.7\%$

Diskrete und stetige Verteilungen

Stetige Verteilungen		
Uniform $X \sim Unif([a, b])$	$\begin{cases} 0 & a < 0 \\ 1 & a \leq x \leq b \\ b-a & \\ 0 & b > 0 \end{cases}$	$\mu = \frac{a+b}{2}$ $\sigma^2 = \frac{(b-a)^2}{12}$
Normal $X \sim \mathcal{N}(\mu, \sigma^2)$	$f(x) = \varphi_{\mu, \sigma}(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2} \cdot \frac{(x-\mu)^2}{\sigma^2}\right\}$	$E[x] = \mu$ $Var(x) = \sigma^2$

Summe von 2 Zufallsvariablen  $x, y$

normalverteilt:  $S \sim N(\mu_x + \mu_y, \sigma_x^2 + \sigma_y^2)$

poissonverteilt:  $S \sim Pois(\lambda_x + \lambda_y)$

binominalverteilt:  $S \sim Bin(nx, ny, p)$

$$E[S] = E[X] + E[Y]$$

$$E[aX + b] = aE[X] + b$$

$$Var[S] = Var[x] + Var[y] + 2cov(xy)$$

cov: Kovarianz

Zentraler Grenzwertsatz

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right) \rightarrow S_n \sim N(n\mu, n\sigma^2) \text{ mit } \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

Binominalverteilung:  $\mu = n \cdot p$      $\sigma^2 = npq$      $q = (1 - p)$

$$P(a \leq x \leq b) = \sum_{x=a}^b P(X = x) \approx \Phi_{\mu, \sigma^2}(b + \frac{1}{2}) - \Phi_{\mu, \sigma^2}(a - \frac{1}{2}) \quad npq > 9$$

Poissonverteilung:  $\mu = \lambda$      $\sigma^2 = \lambda$

$$P(a \leq x \leq b) = \sum_{x=a}^b P(X = x) \approx \Phi_{\mu, \sigma^2}(b + \frac{1}{2}) - \Phi_{\mu, \sigma^2}(a - \frac{1}{2}) \quad \lambda > 9$$

	diskrete Zufallsvariablen	stetige Zufallsvariablen
Dichtefunktion / PMF/PDF	$f(x) = P(X = x)$	$f(x) = F'(x) \neq P(X = x)$
Kumulative Verteilungsfunktion / CDF	$F(x) = P(X \leq x) = \sum_{u \leq x} f(u)$	$F(x) = P(X \leq x) = \int_{-\infty}^x f(u) du$
Wahrscheinlichkeiten	$P(a \leq X \leq b) = \sum_{a \leq x \leq b} f(x)$ $P(a < X \leq b) = \sum_{a < x \leq b} f(x)$ $P(a < X < b) = \sum_{a < x < b} f(x)$ $P(a < X) = 1 - F(a)$	$\left. \begin{aligned} P(a \leq X \leq b) \\ P(a < X \leq b) \\ P(a < X < b) \end{aligned} \right\} = \int_a^b f(x) dx$ $P(a < X) = 1 - F(a)$
Graphische Darstellung von $f$	Stabdiagramm	Graph
Erwartungswert	$E(X) = \sum_{x \in \mathbb{R}} f(x) \cdot x$	$E(X) = \int_{-\infty}^{\infty} f(x) \cdot x dx$
Varianz	$V(X) = \sum_{x \in \mathbb{R}} f(x) \cdot (x - E(X))^2$	$V(X) = \int_{-\infty}^{\infty} f(x) \cdot (x - E(X))^2 dx$

**Satz**

Für diskrete und stetige Zufallsvariablen  $X$  und  $Y$  gelten die folgenden Regeln:

(1) Linearität des Erwartungswertes:

$$E(X + Y) = E(X) + E(Y) \text{ und } E(\alpha X) = \alpha E(X) \text{ mit } \alpha \in \mathbb{R}.$$

(2) Verschiebungssatz für die Varianz:

$$V(X) = E(X^2) - (E(X))^2$$

(3)  $V(\alpha X + \beta) = \alpha^2 \cdot V(X)$  mit  $\alpha, \beta \in \mathbb{R}$ .

(4) Sind  $X$  und  $Y$  stochastisch unabhängig, so gilt:

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

## LINEARE REGRESSION

$$y = h(x) = d + m \cdot x$$

$d$ : Achsenabschnitt       $m$ : Steigung       $x$ : erklärende Variable

$$y_i = d + mx_i + \varepsilon_i$$

$y_i$ : Zielvariable       $d$ : Achsenabschnitt       $m$ : Steigung       $x$ : erklärende Variable

$\varepsilon_i$ : zufälliger Fehler Rest

## METHODE DER KLEINSTEN QUADRATE

$$Q(d, m) = \sum_{i=1}^n (\varepsilon_i)^2 = \sum_{i=1}^n (y_i - (d + mx_i))^2 = \underbrace{\sum_{i=1}^n (y_i - \hat{y})^2}_{\text{Summe der Residuen Quadrate}}$$

$$\hat{y} = d + mx$$

$$\varepsilon_i = y_i - \hat{y}_i \text{ (Residuen)}$$

$$m = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{S_{xy}}{S_x^2} = \frac{\text{Kovarianz}}{\text{Varianz}}$$

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

$$S_y^2 = \underbrace{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}_{\text{Totale Varianz}} = \underbrace{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}_{\text{Fehlervarianz}} + \underbrace{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2}_{\text{erklärte Varianz}} = S_\varepsilon^2 + S_{\hat{y}}^2$$

$$\text{Residuenvarianz: } S_\varepsilon^2 = \frac{1}{n} \sum_{i=1}^n (y_i - mx_i - d)^2 = S_y^2 - S_{\hat{y}}^2$$

$$\text{korrigierte Gesamtvarianz: } S_y^2 = \frac{1}{n-1} \underbrace{\sum_{i=1}^n (y_i - \bar{y})^2}_{\text{Totale Varianz}}$$

$$\text{korrigierte erklärte Varianz: } S_{\hat{y}}^2 = \frac{1}{n-1} \underbrace{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}_{\text{erklärte Varianz}}$$

$$\text{Bestimmtheitsmass: } R^2 = \frac{S_{\hat{y}}^2}{S_y^2} = \frac{S_{xy}^2}{S_x^2 \cdot S_y^2} = r_{xy}^2$$

## TRANSFORMATIONEN

muss wieder zurücktransformiert werden  $\rightarrow \log(m) \rightarrow m = e^{\dots}$

$y = q \cdot x^m$	$\log(y) = \log(q) + m \cdot \log(x)$
$y = q \cdot m^x$	$\log(y) = \log(q) + x \cdot \log(m)$
$y = q \cdot e^{mx}$	$\log(y) = \log(q) + m \cdot x$
$y = q \cdot e^{q \frac{m}{x}}$	$\ln(y) = q - m \cdot u, u = \frac{1}{x}$
$y = \frac{1}{q + m \cdot x}$	$v = q + m \cdot x, v = \frac{1}{y}$
$y = q + m \cdot \ln(x)$	$y = q + m \cdot u, u = \ln(x)$
$y = \frac{1}{q \cdot m^x}$	$\log\left(\frac{1}{y}\right) = \log(q) + \log(m) \cdot x$

# SCHLIESSENDE STATISTIK

## SCHÄTZFUNKTIONEN

$$\mu = \text{arithmetisches Mittel} = \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \rightarrow \text{Schätzung}$$

$$\sigma = \text{empirische Standardabweichung}$$

$$p = \text{relative Häufigkeit}$$

Erwartungstreue  $\rightarrow \mu \quad E(\Theta) = \theta$

Effizienz  $\rightarrow \sigma \quad \text{effizienter wenn: } V(\Theta_1) < V(\Theta_2)$

Konsistenz  $\rightarrow$  je grosser die Stichprobe, desto genauer der Schätzer

konsistent wenn:  $E(\Theta) \rightarrow \theta$  und  $V(\Theta) \rightarrow \theta$ , für  $n \rightarrow \infty$

### Schätzfunktionen für wichtige Parameter

	Schätzfunktion	Schätzwert
<b>Erwartungswert</b> Spezialfall: Anteilswert einer Bernoulli-Verteilung	$\bar{X} = \frac{1}{n} \cdot \sum_{i=1}^n X_i$	$\hat{\mu} = \bar{x} = \frac{1}{n} \cdot \sum_{i=1}^n x_i$ $\hat{p} = \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{\text{Anzahl Ien}}{n}$
<b>Varianz</b>	$S^2 = \frac{1}{n-1} \cdot \sum_{i=1}^n (X_i - \bar{X})^2$	$\hat{\sigma}^2 = s^2 = \frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \bar{x})^2$
<b>Standardabweichung</b>	$S = \sqrt{S^2}$	$\hat{\sigma} = s = \sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \bar{x})^2}$

**Satz**

- (1)  $\bar{X}$  und  $S^2$  sind erwartungstreu und konsistent.
- (2)  $S$  ist konsistent, aber nicht erwartungstreu.

Schätzer/ Verteilung	Kenngrossen	Schätzer für Param.
Binominal $X \sim B(n, p)$	$E[X] = np$ $Var(X) = np(1 - p)$	$\hat{p} = \bar{x}$
Poisson $X \sim Pois(\lambda)$	$E[X] = Var(X) = \lambda$	$\hat{\lambda} = \bar{x}$
Uniform $X \sim Unif([a, b])$	$\mu = \frac{a + b}{2}$ $\sigma^2 = \frac{(b - a)^2}{12}$	$\hat{a} = \bar{x} - Sd(X) \cdot \sqrt{3}$ $\hat{b} = \bar{x} + Sd(X) \cdot \sqrt{3}$ Sd: Standardabweichung
Normal $X \sim \mathcal{N}(\mu, \sigma^2)$	$E[x] = \mu$ $Var(x) = \sigma^2$	$\hat{\mu} = \hat{x}$ $\hat{\sigma} = Sd(x)$

Anpassungen von Verteilungen

Theoretische kumulative Wahrscheinlichkeitsfunktion

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

Empirische kum. Wahrscheinlichkeitsfunktion

$$\hat{F}_n = \text{Anzahl Beobachtungen}$$

Konfidenzintervall Normalverteilung

$$\left[ \bar{X}_n - \frac{\sigma}{\sqrt{n}} q_{1-\frac{\alpha}{2}}, \bar{X}_n - \frac{\sigma}{\sqrt{n}} \underbrace{q_{\frac{\alpha}{2}}}_{\text{wird aus der Tabelle bestimmt}} \right]$$

VERTRAUENSINTERVALLE

	(1) Verteilung der Grundgesamtheit	(2) Param.	(3) Schätzfunktionen	(4) zugehörige standardisierte Zufallsvariable	(5) Verteilung und benötigte Quantile	(6) Zufallsvariablen für Intervallgrenzen
1	Normalverteilung (Varianz $\sigma^2$ bekannt)	$\mu$	$\bar{X} = \frac{1}{n} \cdot \sum_{i=1}^n X_i$	$U = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}}$	<b>Standardnormalverteilung</b> (Tabelle 2) $c = u_p$ mit $p = \frac{1+\gamma}{2}$	$\theta_u = \bar{X} - c \cdot \frac{\sigma}{\sqrt{n}}$ $\theta_o = \bar{X} + c \cdot \frac{\sigma}{\sqrt{n}}$
2	Normalverteilung (Varianz $\sigma^2$ unbekannt und $n \leq 30$ ; sonst Fall 1 mit $s$ als Schätzwert für $\sigma$ )	$\mu$	$\bar{X} = \frac{1}{n} \cdot \sum_{i=1}^n X_i$ $S^2 = \frac{1}{n-1} \cdot \sum_{i=1}^n (X_i - \bar{X})^2$	$T = \frac{\bar{X} - \mu}{S/\sqrt{n}}$	<b>t-Verteilung</b> (Tabelle 4) mit $f = n - 1$ $c = t_{(p;f)}$ mit $p = \frac{1+\gamma}{2}$	$\theta_u = \bar{X} - c \cdot \frac{S}{\sqrt{n}}$ $\theta_o = \bar{X} + c \cdot \frac{S}{\sqrt{n}}$
3	Normalverteilung	$\sigma^2$	$\bar{X} = \frac{1}{n} \cdot \sum_{i=1}^n X_i$ $S^2 = \frac{1}{n-1} \cdot \sum_{i=1}^n (X_i - \bar{X})^2$	$Z = (n-1) \frac{S^2}{\sigma^2}$	<b>Chi-Quadrat-Verteilung</b> (Tabelle 3) mit $f = n - 1$ $c_1 = z_{(p_1;f)}$ mit $p_1 = \frac{1-\gamma}{2}$ $c_2 = z_{(p_2;f)}$ mit $p_2 = \frac{1+\gamma}{2}$	$\theta_u = \frac{(n-1) \cdot S^2}{c_2}$ $\theta_o = \frac{(n-1) \cdot S^2}{c_1}$
4	Bernoulli-Verteilung Anteilsschätzung (mit $n\hat{p}(1-\hat{p}) > 9$ )	$p$	$\bar{X} = \frac{1}{n} \cdot \sum_{i=1}^n X_i$ $X_i$ 0/1-wertig mit $P(X_i = 1) = p$	$U = \frac{\bar{X} - p}{\sqrt{p(1-p)/n}}$	<b>Standardnormalverteilung</b> (näherungsweise), Tabelle 2 $c = u_q$ mit $q = \frac{1+\gamma}{2}$	$\theta_u = \bar{X} - c \cdot \sqrt{\frac{\bar{X} \cdot (1-\bar{X})}{n}}$ $\theta_o = \bar{X} + c \cdot \sqrt{\frac{\bar{X} \cdot (1-\bar{X})}{n}}$
5	beliebig mit $n > 30$	$\mu, \sigma^2$	wie im Fall 1 (gegebenenfalls mit $s$ als Schätzwert für $\sigma$ ) bzw. im Fall 3			