

# Wahrscheinlichkeit und Statistik Zusammenfassung

Fabian Hahn, Dino Wernli

29. September 2008

## Wahrscheinlichkeitstheorie

### Grundlegende Kombinatorik

Die folgende Tabelle bezieht sich auf das Urnenmodell:

| ziehe $n$ aus $k$ | geordnet            | ungeordnet         |
|-------------------|---------------------|--------------------|
| mit Zurücklegen   | $n^k$               | $\binom{n+k-1}{k}$ |
| ohne Zurücklegen  | $\frac{n!}{(n-k)!}$ | $\binom{n}{k}$     |

### Ereignisraum $\Omega$

Menge aller möglichen **Elementarereignisse**  $\omega$  des betrachteten Zufallsexperiments.

**Beispiel:** Würfel:  $\Omega = \{1, 2, 3, 4, 5, 6\}$

### Ereignis $A$

Teilmenge des *Ereignisraums*  $\Omega$  ( $A \subseteq \Omega$ ), also eine Kollektion aus *Elementarereignissen*. Kann also auch mehrere "Ergebnisse" des Zufallsexperiments umfassen.

**Beispiel:** Gerader Würfelwurf:  $A = \{2, 4, 6\} \subseteq \Omega$

### Beobachtbare Ereignisse $\mathcal{F}$

*Ereignisse*, die man wirklich beobachten, also messen kann. Es gilt  $\mathcal{F} \subseteq 2^\Omega$ . Normalerweise, also wenn  $\Omega$  endlich oder überabzählbar ist, wählt man  $\mathcal{F} = 2^\Omega$ , also alle möglichen Ereignisse des *Ereignisraums*.

### Mengenoperationen auf Ereignissen

*Mengenoperationen auf Ereignissen* funktionieren genau so, wie man es sich auch intuitiv vorstellen würde:

- Schnittmenge  $A \cap B$ : *Ereignis*, dass  $A$  und  $B$  gleichzeitig eintreten.
- Vereinigung  $A \cup B$ : *Ereignis*, dass  $A$  oder  $B$  (oder auch beide) eintreten.
- Komplement  $\bar{A}$ : *Ereignis*, dass  $A$  nicht eintritt.

### Wahrscheinlichkeitmass $P$

Funktion, welche einem *Ereignis* einen Wert zwischen 0 und 1 zuordnet, also eine Abbildung  $P: \mathcal{F} \rightarrow [0, 1]$ .

### Rechenregeln

- $P[\Omega] = 1$ ,  $P[\emptyset] = P[\bar{\Omega}] = 0$
- $P[A \cup B] = P[A] + P[B]$  falls  $A \cap B = \emptyset$  ( $A$  und  $B$  heissen dann **disjunkt**), ansonsten verwende Inklusion-Exklusions-Prinzip:  
 $P[A \cup B] = P[A] + P[B] - P[A \cap B]$
- Falls alle  $A_i$  *paarweise disjunkt* sind, gilt:

$$P\left[\bigcup_i A_i\right] = \sum_i P[A_i] \quad (1)$$

- $P[\bar{A}] = 1 - P[A]$
- $A \subseteq B \rightarrow P[A] \leq P[B]$

### Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, P)$

Ein *Wahrscheinlichkeitsraum* charakterisiert ein Zufallsexperiment und umfasst einen *Grundraum*  $\Omega$ , die *beobachtbaren Ereignisse*  $\mathcal{F}$  und eine *Wahrscheinlichkeitsabbildung*  $P$ .

### Laplace-Raum

Ein *Laplace-Raum* ist ein endlicher *Wahrscheinlichkeitsraum*, in welchem alle *Elementarereignisse* gleich wahrscheinlich sind. Das *Wahrscheinlichkeitsmass*  $P$  in diesem Raum heisst **diskrete Gleichverteilung**. Für alle *Ereignisse*  $A \subseteq \Omega$  gilt:

$$P[A] = \frac{|A|}{|\Omega|} \quad (2)$$

### Bedingte Wahrscheinlichkeit

Die *bedingte Wahrscheinlichkeit* von  $B$  gegeben  $A$  entspricht der Wahrscheinlichkeit, dass  $B$  eintritt, wenn man schon weiss, dass  $A$  eingetreten ist. Es gilt:

$$P[B|A] = \frac{P[A \cap B]}{P[A]} \quad (3)$$

$$P[A \cap B] = P[A] \cdot P[B|A] = P[B] \cdot P[A|B] \quad (4)$$

Die **Pfadregel**, nach der Wahrscheinlichkeiten in einem **Wahrscheinlichkeitsbaum** multipliziert werden, um die Wahrscheinlichkeit eines "Blattes" zu erhalten, entspricht einer Verkettung *bedingter Wahrscheinlichkeiten*.

### Satz der totalen Wahrscheinlichkeit

Sei  $A_i$  eine *disjunkte* Zerlegung von  $\Omega$ , also  $\bigcup_{i=1}^n A_i = \Omega$  *disjunkt*. Für beliebige *Ereignisse*  $B$  gilt dann:

$$P[B] = \sum_{i=1}^n P[A_i \cap B] = \sum_{i=1}^n P[A_i] \cdot P[B|A_i] \quad (5)$$

Der Satz bedeutet gerade, dass man die *Wahrscheinlichkeit* eines Ereignisses “unten” in einem *Wahrscheinlichkeitsbaum* bekommen kann, wenn man die einzelnen Pfade addiert, die zu ihm führen.

## Satz von Bayes

Mit dem *Satz von Bayes* lassen sich *bedingte Wahrscheinlichkeiten* “umkehren”. Sei  $A_i$  eine *disjunkte* Zerlegung von  $\Omega$ , also  $\bigcup_{i=1}^n A_i = \Omega$  *disjunkt* und  $B$  ein weiteres Ereignis. Dann gilt für jedes  $k$ :

$$P[A_k|B] = \frac{P[A_k \cap B]}{P[B]} = \frac{P[A_k] \cdot P[B|A_k]}{\sum_{i=1}^n P[A_i] \cdot P[B|A_i]} \quad (6)$$

## Unabhängigkeit

Zwei *Ereignisse*  $A$  und  $B$  heissen *unabhängig*, falls gilt:

$$P[A \cap B] = P[A] \cdot P[B] \quad (7)$$

Vergleich mit (4) liefert: ( $P[A] \neq 0$ ,  $P[B] \neq 0$ )

$$A, B \text{ unabhängig} \Leftrightarrow P[B|A] = P[B] \Leftrightarrow P[A|B] = P[A] \quad (8)$$

Anschaulich bedeutet *Unabhängigkeit*, dass das Eintreten des einen Ereignisses keinen Einfluss auf die Wahrscheinlichkeit des anderen hat. Deshalb ist auch die *Kovarianz*  $\text{Cov}(X, Y)$  zweier Zufallsvariablen  $X$  und  $Y$  gleich Null, falls sie *unabhängig* sind (**Achtung:** Umkehrung gilt nicht!).

Die Ereignisse  $A_i$  mit  $i \in \{1, 2, \dots, n\}$  heissen *unabhängig*, wenn für jede Teilfamilie  $T$  von  $A_i$  gilt:

$$1 \leq j_1 < \dots < j_k \leq n, \quad T = A_{j_1} \cap \dots \cap A_{j_k} \quad (9)$$

$$P[T] = \prod_{m=1}^k P[A_{j_m}]$$

**Achtung:** Paarweise Unabhängigkeit bedeutet nicht, dass alle Elemente unabhängig sind. Gegenbeispiel Würfelwurf:  $A$  = erste Zahl gerade,  $B$  = zweite Zahl gerade,  $C$  = beide gerade oder beide ungerade.

## Zufallsvariablen

### Zufallsvariable $X$

Eine *Zufallsvariable* ist eine Funktion  $X : \Omega \rightarrow \mathbb{R}$ , welche jedem *Elementarereignis* eine Zahl zuordnet, welche repräsentiert, wofür wir uns bei unserem Zufallsexperiment überhaupt interessieren.

**Beispiele:** Augenzahl bei einem Würfelwurf, Anzahl Köpfe bei  $k$ -maligem Münzwurf, Gewicht einer aus einem Sack gezogenen Kartoffel.

Eine *Zufallsvariable* mit abzählbarem Wertebereich heisst **diskret**, ansonsten ist sie (bei uns meist) **stetig**.

### Indikatorfunktion 1

Die *Indikatorfunktion* ist eine spezielle *Zufallsvariable*, welche angibt, ob ein Ereignis  $A$  eingetreten ist.

$$\mathbf{1}_A(\omega) = \begin{cases} 1 & \omega \in A \\ 0 & \omega \notin A \end{cases} \quad (10)$$

## Gewichtsfunktion $p$

Die *Gewichtsfunktion*  $p_X(t) : \mathcal{W}(X) \rightarrow [0, 1]$  ordnet jedem Wert  $t$ , den eine *Zufallsvariable*  $X$  annehmen kann, seine *Wahrscheinlichkeit* zu. Viel intuitiver aber auch erlaubt ist die Schreibweise  $P[X = t]$ , wobei  $t \in \mathcal{W}(X)$ .

Anschaulich gibt  $P[X = t]$  auf die Frage Auskunft: “Mit welcher *Wahrscheinlichkeit* nimmt  $X$  den Wert  $t$  an?”

**Achtung:** Die *Gewichtsfunktion* ist nur für *diskrete Zufallsvariablen* sinnvoll (denn bei einer *stetigen* Verteilung hat ein Einzelereignis immer die *Wahrscheinlichkeit* 0)!

## Dichtefunktion

Die *Dichtefunktion*  $f_X$  ist das Analagon zur *Gewichtsfunktion* für *stetige Zufallsvariablen*. Sie gibt die Änderung ihrer *Verteilungsfunktionen* an und charakterisiert sie so vollständig.

### Eigenschaften

$$\forall t \in \mathcal{W}(X) : f_X(t) \geq 0 \quad (11)$$

$$\forall t \notin \mathcal{W}(X) : f_X(t) = 0 \quad (12)$$

$$\int_{-\infty}^{\infty} f_X(t) dt = 1 \quad (13)$$

### Transformation

Sei  $X$  eine *Zufallsvariable* mit *Dichtefunktion*  $f_X$  und  $Y = g(X)$  bijektiv. Dann hat  $Y$  die *Dichtefunktion*:

$$f_Y(t) = \left| \frac{d}{dt} g^{-1}(t) \right| \cdot f_X(g^{-1}(t)) \quad (14)$$

Sei zum Beispiel  $Y = aX + b$ . Dann gilt:  $f_Y(t) = \frac{1}{a} \cdot f_X\left(\frac{t-b}{a}\right)$

## Verteilung $\mu$

Die *Verteilung*  $\mu_X : B \rightarrow [0, 1]$  mit  $B \subseteq \mathcal{W}(X)$  ist das Analagon zu *Gewichts-* bzw. *Dichtefunktion* für Bereiche (Teilmen-gen) der Wertemenge einer *Zufallsvariablen*  $X$ .

Anschaulich beantwortet  $\mu_X(B)$ , wie gross die *Wahrscheinlichkeit* ist, dass  $X$  einen Wert aus  $B$  annimmt.

Bei *stetigen Zufallsvariablen* ist  $B$  oft Teilintervall von  $\mathcal{W}(X)$ .

## Verteilungsfunktion $F$

Die *Verteilungsfunktion*  $F_X : \mathcal{W}(X) \rightarrow [0, 1]$  gibt über die *Wahrscheinlichkeit* Auskunft, mit welcher eine *Zufallsvariable*  $X$  höchstens einen bestimmten Wert erreicht. Intuitiver und erlaubt ist die Schreibweise  $P[X \leq t]$ , wobei  $t \in \mathcal{W}(X)$ .

### Eigenschaften

- $F_X$  ist monoton wachsend und rechtsstetig.
- Es gilt:

$$\lim_{t \rightarrow -\infty} F_X(t) = 0 \quad (15)$$

$$\lim_{t \rightarrow \infty} F_X(t) = 1 \quad (16)$$

- Wenn  $X$  *diskret*:

$$F_X(t) = \sum_{\substack{i \in \mathcal{W}(X) \\ i \leq t}} p_X(i) = \sum_{\substack{i \in \mathcal{W}(X) \\ i \leq t}} P[X = i] \quad (17)$$

- Wenn  $X$  stetig:

$$F_X(t) = \int_{-\infty}^t f_X(x) dx \quad (18)$$

- Für diskrete und stetige  $X$  gilt gleichermaßen:

$$P[a < X \leq b] = F_X(b) - F_X(a) \quad (19)$$

- Bei stetigen  $X$  darf man innerhalb von  $P[\dots]$ -Blöcken die Zeichen  $<, \leq$  sowie  $>, \geq$  frei vertauschen

## Quantil und Median

Für  $\alpha \in (0, 1)$  heisst  $q_\alpha = F_X^{-1}(\alpha)$  das  $\alpha$ -Quantil der Verteilungsfunktion  $F$ . Es bedeutet, dass die Zufallsvariable  $X$  mit Wahrscheinlichkeit  $\alpha$  Werte zwischen  $-\infty$  und dem  $\alpha$ -Quantil  $q_\alpha$  annimmt.

Das  $\frac{1}{2}$ -Quantil einer Verteilung heisst **Median**.

## Erwartungswert $E$

Der Erwartungswert zeigt, welchen Wert eine Zufallsvariable bei vielen Wiederholungen des Zufallsexperiments durchschnittlich annehmen wird. Oft schreibt man anstatt  $E[X]$  auch  $\mu$  (**Achtung:** nicht mit Verteilung verwechseln!).

$$\text{diskret: } E[X] = \sum_{t \in \mathcal{W}(X)} t \cdot P[X = t] \quad (20)$$

$$\text{stetig: } E[X] = \int_{-\infty}^{\infty} x \cdot f_X(x) dx \quad (21)$$

## Erlaubte Transformationen

- Für  $Y = g(X)$ , diskret gilt:

$$E[Y] = \sum_{t \in \mathcal{W}(X)} g(t) \cdot P[X = t] \quad (22)$$

- Für  $Y = g(X)$ , stetig gilt:

$$E[Y] = \int_{-\infty}^{\infty} g(x) \cdot f_X(x) dx \quad (23)$$

- Für  $Z = g(X) \cdot h(Y)$  mit  $X, Y$  unabhängig gilt:

$$E[Z] = E[g(X)] \cdot E[h(Y)] \quad (24)$$

**Achtung:** Umkehrung gilt nicht!

- Für  $Y = a + \sum_{i=1}^n b_i X_i$  gilt:

$$E[Y] = a + \sum_{i=1}^n b_i \cdot E[X_i] \quad (25)$$

## Erwartungswert einer Funktion mehrerer ZV

Seien  $X_1, \dots, X_n$  Zufallsvariablen mit gemeinsamer Gewichtsfunktion  $p$  bzw. gemeinsamer Dichtefunktion  $f$  und  $Y = g(X_1, \dots, X_n)$ . Dann gilt je nach Fall:

$$E[Y] = \sum_{x_1, \dots, x_n} g(x_1, \dots, x_n) \cdot p(x_1, \dots, x_n) \quad (26)$$

$$= \int \dots \int g(x_1, \dots, x_n) \cdot f(x_1, \dots, x_n) dx_n \dots dx_1 \quad (27)$$

## Varianz $Var$

Die Varianz ist ein Mass für die Streuung einer Zufallsvariable. Sie stellt den Übergang zwischen der Zufallsvariable selbst und ihrer Standardabweichung dar. Oft schreibt man deshalb anstatt  $Var[X]$  auch  $\sigma^2$ .

$$Var[X] = E[Y^2], \text{ wobei } Y = X - E[X] \quad (28)$$

Daraus folgt:

- Falls  $E[X^2] < \infty$ :

$$Var[X] = E[X^2] - E[X]^2 \quad (29)$$

- $X$  diskret:

$$Var[X] = \sum_{t \in \mathcal{W}(X)} (t - \mu)^2 \cdot P[X = t] \quad (30)$$

- $X$  stetig:

$$Var[X] = \int_{-\infty}^{\infty} (x - \mu)^2 \cdot f_X(x) dx \quad (31)$$

- Für  $Z = a + bX$  gilt:

$$Var[Z] = b^2 \cdot Var[X] \quad (32)$$

- Für  $X_1, X_2, \dots, X_n$  unabhängig gilt:

$$Var\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n Var[X_i] \quad (33)$$

## Standardabweichung $\sigma$

Die Standardabweichung ist das Mass für die Abweichung einer Zufallsvariable von ihrem Erwartungswert.

$$\sigma = \sqrt{\sigma^2} = \sqrt{Var[X]} \quad (34)$$

## Kovarianz $Cov$

Die Kovarianz ist ein Mass für den Zusammenhang zwischen zwei Zufallsvariablen  $X$  und  $Y$  bzw. ihrer Streuung:

$$\begin{aligned} Cov(X, Y) &= E[(X - E[X])(Y - E[Y])] \\ &= E[X \cdot Y] - E[X] \cdot E[Y] \\ &= \frac{Var[X + Y] - Var[X] - Var[Y]}{2} \end{aligned} \quad (35)$$

## Eigenschaften

$$Cov(X, X) = Var[X] \quad (36)$$

$$Cov(X, Y + Z) = Cov(X, Y) + Cov(X, Z) \quad (37)$$

$$\forall a \in \mathbb{R} : Cov(X, a) = 0 \quad (38)$$

$$\forall b \in \mathbb{R} : Cov(X, bY) = b \cdot Cov(X, Y) \quad (39)$$

## Korrelation $\rho$

Wie die Kovarianz ist auch die Korrelation ein Mass für den Zusammenhang zwischen zwei Zufallsvariablen  $X$  und  $Y$ . Im Gegensatz zu dieser ist die Korrelation jedoch dimensions- und einheitenlos und eignet sich deshalb für Vergleiche verschiedener Zusammenhänge.

$$\rho = \frac{Cov(X, Y)}{\sqrt{Var[X] \cdot Var[Y]}} \quad (40)$$

## Eigenschaften

- $-1 \leq \rho(X, Y) \leq 1$
- $|\rho(X, Y)| = 1$  gilt genau dann, wenn es Konstanten  $a, b \in \mathbb{R}$ ,  $b \neq 0$  gibt sodass  $P[Y = a + bX] = 1$ .  $X$  und  $Y$  heißen dann **perfekt korreliert**.

## Diskrete Verteilungen

### Diskrete Gleichverteilung

Einfachste Verteilung, bei welcher alle  $n$  Werte  $\in \mathbb{Z}$  zwischen zwei Schranken  $a \in \mathbb{Z}$  und  $b \in \mathbb{Z}$  gleich wahrscheinlich sind.

#### Eigenschaften

$$P[X = t] = \begin{cases} \frac{1}{n} & a \leq t \leq b \\ 0 & \text{sonst} \end{cases} \quad (41)$$

$$F_X(t) = P[X \leq t] = \begin{cases} 0 & t < a \\ \frac{t-a+1}{n} & a \leq t \leq b \\ 1 & t > b \end{cases} \quad (42)$$

$$\mu_X(B) = \frac{|B|}{n} \quad (43)$$

$$\mu = E[X] = \frac{a+b}{2} \quad (44)$$

$$\sigma^2 = \text{Var}[X] = \frac{n^2 - 1}{12} \quad (45)$$

**Beispiel:** Ergebnis eines Münz- oder Würfelwurfs.

### Bernoulli-Verteilung

Eine *Bernoulli-verteilte Zufallsvariable* mit Parameter  $p$  nimmt genau die beiden Werte 0 und 1 mit den *Wahrscheinlichkeiten*  $1-p$  und  $p$  an. Also ist sie auch die *Indikatorfunktion*  $\mathbf{1}_A$  für ein *Ereignis*  $A$  mit  $P[A] = p$ .

**Schreibweise:**  $X \sim \text{Be}(p)$

#### Eigenschaften

$$P[X = t] = \begin{cases} 1-p & t = 0 \\ p & t = 1 \end{cases} \quad (46)$$

$$\mu = E[X] = p \quad (47)$$

$$\sigma^2 = \text{Var}[X] = p \cdot (1-p) \quad (48)$$

### Binomialverteilung

Die *Binomialverteilung* beschreibt die Anzahl der Erfolge bei  $n$  *unabhängigen* 0-1-Experimenten mit *Erfolgswahrscheinlichkeit*  $p$ . Daraus folgt:

$$X = \sum_{i=1}^n Y_i \quad \text{mit} \quad Y_i \sim \text{Be}(p) \quad (49)$$

**Schreibweise:**  $X \sim \text{Bin}(n, p)$

## Eigenschaften

$$P[X = t] = \binom{n}{t} \cdot p^t \cdot (1-p)^{n-t} \quad (50)$$

$$\mu = E[X] = n \cdot p \quad (51)$$

$$\sigma^2 = \text{Var}[X] = n \cdot p \cdot (1-p) \quad (52)$$

**Beispiel:** Anzahl Köpfe beim 10-maligen Münzwurf

### Geometrische Verteilung

Die *geometrische Verteilung* mit Parameter  $p$  beschreibt die Wartezeit auf den ersten Erfolg bei einer Folge unabhängiger 0-1-Experimente mit *Erfolgswahrscheinlichkeit*  $p$ .

$$X = \inf \{i \in \mathbb{N} | Y_i = 1\} \quad \text{mit} \quad Y_i \sim \text{Be}(p) \quad (53)$$

**Schreibweise:**  $X \sim \text{Geom}(p)$

#### Eigenschaften

$$P[X = t] = p \cdot (1-p)^{t-1} \quad (54)$$

$$F_X(t) = P[X \leq t] = 1 - (1-p)^t \quad (55)$$

$$\mu = E[X] = \frac{1}{p} \quad (56)$$

$$\sigma^2 = \text{Var}[X] = \frac{1}{p^2} - \frac{1}{p} \quad (57)$$

Gedächtnislosigkeit / forgetfulness property:

$$P[X \geq t+s | X \geq s] = P[X \geq t] \quad (58)$$

Die *Wahrscheinlichkeit*, dass man noch einen weiteren Zeitabschnitt  $t$  warten muss, hängt nicht davon ab, wie lange man schon gewartet hat.

**Beispiel:** Wartezeit auf Kopf bei wiederholtem Münzwurf

### Negativbinomialverteilung

Die *Negativbinomialverteilung* mit Parametern  $r$  und  $p$  beschreibt die Wartezeit auf den  $r$ -ten Erfolg bei einer Folge unabhängiger 0-1-Experimente mit *Erfolgswahrscheinlichkeit*  $p$ . Daraus folgt  $\text{NB}(1, p) \equiv \text{Geom}(p)$ .

**Schreibweise:**  $X \sim \text{NB}(r, p)$

#### Eigenschaften

$$P[X = t] = \binom{t-1}{r-1} \cdot p^r \cdot (1-p)^{t-r} \quad (59)$$

$$\mu = E[X] = \frac{r}{p} \quad (60)$$

$$\sigma^2 = \text{Var}[X] = \frac{r \cdot (1-p)}{p^2} \quad (61)$$

Für  $X_1, \dots, X_r \sim \text{Geom}(p)$  *i.i.d.* gilt:

$$X_1 + X_2 + \dots + X_r \sim \text{NB}(r, p) \quad (62)$$

**Beispiel:** Wartezeit auf dritten Kopf beim wiederholtem Münzwurf

## Hypergeometrische Verteilung

Eine *hypergeometrisch* verteilte *Zufallsvariable* beschreibt die Anzahl "guter" Kugeln, wenn man aus einer Urne mit  $n$  Kugeln, davon  $r$  "gute",  $m$  Mal ohne Zurücklegen zieht.

### Eigenschaften

$$P[X = t] = \frac{\binom{r}{t} \cdot \binom{n-r}{m-t}}{\binom{n}{m}} \quad (63)$$

$$\mu = E[X] = \frac{r \cdot m}{n} \quad (64)$$

$$\sigma^2 = Var[X] = \frac{r \cdot m}{n} \cdot \left(1 - \frac{m}{n}\right) \cdot \frac{n-r}{n-1} \quad (65)$$

## Poisson-Verteilung

Die *Poisson-Verteilung* mit Parameter  $\lambda \in \mathbb{R}^+$  ist eine Approximation der *Binomialverteilung* für kleine  $p$  und grosse  $n$ , wobei  $\lambda = np$ . Die Approximation ist gut für  $np^2 \leq 0.05$  und damit ein Modell für seltene Ereignisse.

**Schreibweise:**  $X \sim P(\lambda)$

### Eigenschaften

$$P[X = t] = e^{-\lambda} \cdot \frac{\lambda^t}{t!} \quad (66)$$

$$\mu = E[X] = \lambda \quad (67)$$

$$\sigma^2 = Var[X] = \lambda \quad (68)$$

**Beispiel:** Anzahl eingehender Druckaufträge in  $n = 3600$  Sekunden mit einer Jobwahrscheinlichkeit von  $p = 1\%$  pro Sekunde, wenn pro Sekunde maximal ein Job eintreffen kann.

## Stetige Verteilungen

### Stetige Gleichverteilung

Bei der *stetigen Gleichverteilung* oder auch **uniformen Verteilung** sind alle Werte zwischen zwei Schranken  $a$  und  $b$  gleich Wahrscheinlich.

**Schreibweise:**  $X \sim \mathcal{U}(a, b)$

### Eigenschaften

$$f_X(t) = \begin{cases} \frac{1}{b-a} & a \leq t \leq b \\ 0 & \text{sonst} \end{cases} \quad (69)$$

$$F_X(t) = \begin{cases} 0 & t < a \\ \frac{t-a}{b-a} & a \leq t \leq b \\ 1 & t > b \end{cases} \quad (70)$$

$$\mu = E[X] = \frac{a+b}{2} \quad (71)$$

$$\sigma^2 = Var[X] = \frac{(b-a)^2}{12} \quad (72)$$

### Exponentialverteilung

Die *Exponentialverteilung* mit Parameter  $\lambda \in \mathbb{R}^+$  ("Ausfallrate") ist das stetige Analogon zur *geometrischen Verteilung* und beschreibt eine Lebensdauer oder eine Wartezeit.

**Schreibweise:**  $X \sim \text{Exp}(\lambda)$

### Eigenschaften

$$f_X(t) = \begin{cases} 0 & t < 0 \\ \lambda \cdot e^{-\lambda t} & t \geq 0 \end{cases} \quad (73)$$

$$F_X(t) = \begin{cases} 0 & t < 0 \\ 1 - e^{-\lambda t} & t \geq 0 \end{cases} \quad (74)$$

$$\mu = E[X] = \frac{1}{\lambda} \quad (75)$$

$$\sigma^2 = Var[X] = \frac{1}{\lambda^2} \quad (76)$$

Gedächtnislosigkeit / forgetfulness property:

$$P[X > t + s \mid X > s] = P[X \geq t] \quad (77)$$

## Normalverteilung

Die *Normalverteilung* mit *Erwartungswert*  $\mu \in \mathbb{R}$  und *Varianz*  $\sigma^2 \in \mathbb{R}^+$  modelliert Summen oder Mittelwerte vieler *i.i.d.* Zufallsvariablen (dies folgt aus dem *zentralen Grenzwertsatz*). Meistens beschreibt sie die Ergebnisse von Messungen "aus der Natur".

**Schreibweise:**  $X \sim \mathcal{N}(\mu, \sigma^2)$

### Eigenschaften

$$f_X(t) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(t-\mu)^2}{2\sigma^2}} \quad (78)$$

$$F_X(t) = \text{tabelliert durch } \Phi(t) \quad (79)$$

$$\mu = E[X] = \mu \quad (80)$$

$$\sigma^2 = Var[X] = \sigma^2 \quad (81)$$

**Beispiel:** Gewicht von Kürbissen

### Standardnormalverteilung

$\mathcal{N}(0, 1)$  heisst *Standardnormalverteilung*. Ihre Dichte  $F_X(t) \equiv \Phi(t)$  ist tabelliert.

### Eigenschaft:

Sei  $X \sim \mathcal{N}(\mu, \sigma^2)$ ,  $Y = \frac{X-\mu}{\sigma}$ . Dann gilt  $Y \sim \mathcal{N}(0, 1)$  und:

$$P[X \leq x] = P\left[Y \leq \frac{x-\mu}{\sigma}\right] = \Phi\left(\frac{x-\mu}{\sigma}\right) \quad (82)$$

### Chiquadratverteilung

Die *Chiquadratverteilung* mit  $m$  Freiheitsgraden taucht bei bestimmten Tests auf und entsteht durch Quadrieren und Summieren von  $m$  *standardnormalverteilten Zufallsvariablen*.

**Schreibweise:**  $X \sim \chi_m^2$

### Eigenschaft:

$$\chi_m^2 \equiv \sum_{i=1}^m X_i^2 \quad \text{mit } X_i \sim \mathcal{N}(0, 1) \quad (83)$$

## t-Verteilung

Die *t-Verteilung* mit  $m$  Freiheitsgraden ist symmetrisch und tritt bei Tests auf.

**Schreibweise:**  $X \sim t_m$

### Eigenschaften

$$f_X(t) = \frac{\Gamma\left(\frac{m+1}{2}\right)}{\sqrt{m\pi} \cdot \Gamma\left(\frac{m}{2}\right)} \left(1 + \frac{x^2}{m}\right)^{-\frac{m+1}{2}} \quad (84)$$

$$\mu = E[X] = 0 \text{ für } n > 1 \quad (85)$$

$$\sigma^2 = \text{Var}[X] = \frac{n}{n-2} \text{ für } n > 2 \quad (86)$$

## Simulation

Sei  $F$  eine stetige, streng monoton wachsende und bijektive Verteilungsfunktion mit Umkehrfunktion  $F^{-1}$ . Sei  $X \sim \mathcal{U}(0, 1)$  gleichverteilt und  $Y = F^{-1}(X)$ .

Dann hat  $Y$  gerade die Verteilungsfunktion  $F$ .

**Anwendung:** PC liefert immer uniforme Zufallszahlen zwischen 0 und 1. Wir wollen aber eine andere Verteilung haben.

### Beispiel Exponentialverteilung

$$s = F(t) = 1 - e^{-\lambda t} \quad (87)$$

$$\text{Umkehrfunktion: } t = F^{-1}(s) = -\frac{\log(1-s)}{\lambda}$$

Sei nun  $x$  ein zufällig generierter Wert der Zufallsvariable  $X$  mit  $X \sim \mathcal{U}(0, 1)$ . Aufgrund obigen Formeln gilt:

$$y = F^{-1}(x) = -\frac{\log(1-x)}{\lambda} \sim \text{Exp}(\lambda) \quad (88)$$

## Gemeinsame Verteilungen

### Funktionen

Analog zum Fall für eine Zufallsvariable existieren für gemeinsame Verteilungen:

- **Gemeinsame Gewichtsfunktion**, falls alle  $X_i$  diskret:

$$p(x_1, \dots, x_n) = P[X_1 = x_1, \dots, X_n = x_n] \quad (89)$$

- **Gemeinsame Dichtefunktion**, falls alle  $X_i$  stetig:

$$f(x_1, x_2, \dots, x_n) \quad (90)$$

- **Gemeinsame Verteilungsfunktion**

$$F(x_1, \dots, x_n) = P[X_1 \leq x_1, \dots, X_n \leq x_n] \quad (91)$$

Im diskreten Fall gilt:

$$F(x_1, x_2, \dots, x_n) \quad (92)$$

$$= \sum_{\substack{t_1 \in \mathcal{W}(X_1) \\ t_1 \leq x_1}} \dots \sum_{\substack{t_n \in \mathcal{W}(X_n) \\ t_n \leq x_n}} P[X_1 = t_1, \dots, X_n = t_n] \quad (93)$$

Im stetigen Fall gilt:

$$F(x_1, x_2, \dots, x_n) \quad (94)$$

$$= \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_n} f(t_1, \dots, t_n) dt_n \dots dt_1$$

## Darstellung für $n = 2$

- Im diskreten Fall: Darstellung als Tabelle
- Im stetigen Fall: Darstellung als Flächengraph

## Randverteilungen

Möchte man ausgehend von einer gemeinsamen Verteilung bestimmte Zufallsvariablen unbetrachtet lassen und quasi "Einzelverteilungen" herausfinden, dann:

**Gewichtsfunktion:** unbetrachtete ZV wegsommieren:

$$P[X = x] = \sum_{t_1 \in \mathcal{W}(Y_1)} \dots \sum_{t_{n-1} \in \mathcal{W}(Y_{n-1})} \quad (95)$$

$$P[X = x, Y_1 = y_1, \dots, Y_{n-1} = y_{n-1}]$$

**Dichtefunktion:** unbetrachtete ZV wegintegrieren:

$$f_X(x) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f(x, y_1, \dots, y_{n-1}) dy_1 \dots dy_{n-1} \quad (96)$$

**Verteilungsfunktion:** Limes bilden:

$$F_X(x) = \lim_{y_1 \rightarrow \infty} \dots \lim_{y_{n-1} \rightarrow \infty} F(x, y_1, \dots, y_{n-1}) \quad (97)$$

## Unabhängigkeit von Zufallsvariablen

Die Zufallsvariablen  $X_1, X_2, \dots, X_n$  heißen *unabhängig*, falls:

$$F(x_1, \dots, x_n) = F_{X_1}(x_1) \dots F_{X_n}(x_n) \quad (98)$$

Dies ist je nach Fall (diskret oder stetig) äquivalent zu:

$$P[X_1 = x_1, \dots, X_n = x_n] \quad (99)$$

$$= P[X_1 = x_1] \dots P[X_n = x_n]$$

$$f(x_1, \dots, x_n) = f_{X_1}(x_1) \dots f_{X_n}(x_n) \quad (100)$$

Sind Zufallsvariablen gleich verteilt und unabhängig, so schreibt man **i.i.d.** für "independent identically distributed".

## Bedingte Verteilungen

### Bedingte Gewichtsfunktion

Die *bedingte Gewichtsfunktion* einer Zufallsvariablen  $X$ , gegeben dass  $Y = y$ , ist definiert als:

$$P[X = x | Y = y] = \frac{P[X = x, Y = y]}{P[Y = y]} \quad (101)$$

$X$  und  $Y$  sind *unabhängig* genau dann, wenn  $\forall x \in \mathcal{W}(X)$  gilt:

$$P[X = x | Y = y] = P[X = x] \quad (102)$$

### Bedingte Dichtefunktion

Die *bedingte Dichtefunktion* einer Zufallsvariablen  $X$ , gegeben  $Y = y$ , ist definiert als:

$$f(x | y) = \frac{f(x, y)}{f(y)} \quad (103)$$

$X$  und  $Y$  sind *unabhängig* genau dann, wenn  $\forall x$  gilt:

$$f(x | y) = f(x) \quad (104)$$

# Grenzwertsätze

## Schwaches Gesetz der grossen Zahlen

Seien  $X_1, X_2, \dots$  *unabhängige* oder zumindest paarweise *unkorrelierte Zufallsvariablen* mit gleichem *Erwartungswert*  $\mu$  und gleicher Varianz  $\sigma^2$ . Sei  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ . Dann gilt:

$$\forall \varepsilon > 0 : \lim_{n \rightarrow \infty} P [|\bar{X}_n - \mu| > \varepsilon] = 0 \quad (105)$$

## Starkes Gesetz der grossen Zahlen

Seien  $X_1, X_2, \dots$  *i.i.d. Zufallsvariablen* mit endlichem *Erwartungswert*  $\mu$ . Sei  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ . Dann gilt:

$$P \left[ \lim_{n \rightarrow \infty} \bar{X}_n = \mu \right] = 1 \quad (106)$$

## Markow-Ungleichung

Sei  $X$  eine Zufallsvariable,  $a \in \mathbb{R}^+$  und  $h : \mathbb{R} \rightarrow \mathbb{R}^+$  eine Funktion. Dann gilt:

$$P[h(X) \geq a] \leq \frac{E[h(X)]}{a} \quad (107)$$

## Chebyshev-Ungleichung

Sei  $Y$  Zufallsvariable mit *Erwartungswert*  $\mu$  und *Varianz*  $\sigma^2$ :

$$\forall \varepsilon > 0 : P[|Y - \mu| > \varepsilon] \leq \frac{\sigma^2}{\varepsilon^2} \quad (108)$$

**Anwendung:** Sehr leicht berechenbare Schranke für jede beliebige Verteilung.

## Chernoff-Schranken

Seien  $X_1, X_2, \dots, X_n$  *i.i.d.* mit  $X_i \sim \text{Be}(p)$ . Sei  $S_n = \sum_{i=1}^n X_i \sim \text{Bin}(n, p)$  und damit  $E[S_n] = np$ .

$$\forall \varepsilon > 0 : P[S_n \geq (1 + \varepsilon)E[S_n]] \leq \left( \frac{e^\varepsilon}{(1 + \varepsilon)^{1 + \varepsilon}} \right)^{E[S_n]} \quad (109)$$

**Anwendung:** Viel einfacher zu rechnen als die *Verteilungsfunktion* der *Binomialverteilung*, liefert im Gegensatz zur *Poisson-Approximation* eine exakte Schranke.

## Zentraler Grenzwertsatz

Seien  $X_1, X_2, \dots$  *i.i.d. Zufallsvariablen* mit  $E[X_i] = \mu$  und  $\text{Var}[X_i] = \sigma^2$ . Sei  $S_n = \sum_{i=1}^n X_i$ . Dann gilt:

$$\lim_{n \rightarrow \infty} P \left[ \frac{S_n - n\mu}{\sigma\sqrt{n}} \leq t \right] = \Phi(t) \quad (110)$$

Oft wird folgende Abkürzung benutzt:

$$S_n^* = \frac{S_n - E[S_n]}{\sqrt{\text{Var}[S_n]}} = \frac{S_n - n\mu}{\sigma\sqrt{n}} \quad (111)$$

Die entstandene *Zufallsvariable*  $S_n^*$  heisst **Standardisierung** von  $S_n$ . Der *zentrale Grenzwertsatz* lässt sich so schreiben als:

$$\begin{aligned} n \text{ gross} &\Leftrightarrow S_n^* \overset{\text{approx}}{\sim} \mathcal{N}(0, 1) \\ &\Leftrightarrow P[S_n^* \leq t] \approx \Phi(t) \\ &\Leftrightarrow S_n \overset{\text{approx}}{\sim} \mathcal{N}(n\mu, n\sigma^2) \end{aligned} \quad (112)$$

Für  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$  gilt:  $\bar{X}_n \overset{\text{approx}}{\sim} \mathcal{N}\left(\mu, \frac{1}{n}\sigma^2\right)$

# Statistik

## Stichproben

In der Statistik möchte man aus beobachteten Daten Rückschlüsse auf die *Verteilungen* ziehen, welche diese Daten generiert haben.

Eine von einem *Elementarereignis*  $\omega$  erzeugte Datenmenge heisst *Stichprobe*. Ihre Daten  $x_1, x_2, \dots, x_n$  heissen **Realisierungen** und werden als Werte  $X_1(\omega), \dots, X_n(\omega)$  von *Zufallsvariablen*  $X_1, \dots, X_n$  betrachtet.

## Schätzer

Betrachtet man jede der zu charakterisierenden *Zufallsvariablen*  $X_1, \dots, X_n$  als abhängig von Parametern  $\vartheta_i$ , so reduziert sich das Ziel darauf, diese Parameter  $\vartheta_1, \dots, \vartheta_m$  zu schätzen. Ein *Schätzer*  $T_i$  ist eine *Zufallsvariable*, die in Abhängigkeit der Daten genau einen der gesuchten Parameter  $\vartheta_i$  schätzt.

## Erwartungstreue

Ein *Schätzer*  $T_i$  heisst *erwartungstreu* für  $\vartheta_i$ , falls  $E[T_i] = \vartheta_i$ . Im Mittel über alle *Realisationen* schätzt er also richtig.

## Konsistenz

Erweitert man einen *Schätzer* so, dass er weitere *Realisierungen* derselben *Zufallsvariablen* berücksichtigt, heisst er *konsistent*, falls er für eine grössere Anzahl  $n$  immer genauer wird:

$$P \left[ \lim_{n \rightarrow \infty} T_i^{(n)} = \vartheta_i \right] = 1 \quad (113)$$

## Maximum-Likelihood-Methode

Die **Likelihood-Funktion**  $L$  gibt die *Wahrscheinlichkeit* einer Stichprobe unter einem Parameter  $\vartheta$  wieder:

$$L(x_1, \dots, x_n; \vartheta) = \begin{cases} p(x_1, \dots, x_n; \vartheta) & \text{diskreter Fall} \\ f(x_1, \dots, x_n; \vartheta) & \text{stetiger Fall} \end{cases} \quad (114)$$

Sind die *Zufallsvariablen*  $X_i$  *i.i.d.*, so gilt:

$$L(x_1, \dots, x_n; \vartheta) = \begin{cases} \prod_{i=1}^n p_X(x_i; \vartheta) & \text{diskreter Fall} \\ \prod_{i=1}^n f_X(x_i; \vartheta) & \text{stetiger Fall} \end{cases} \quad (115)$$

$\log L(x_1, \dots, x_n; \vartheta)$  heisst **log-Likelihood-Funktion**.

Der **Maximum-Likelihood-Schätzer**  $T^{\text{ML}}$  für  $\vartheta$  ist dadurch definiert, dass er die *Likelihood-Funktion*  $L$  über  $\vartheta$  maximiert. Dadurch schätzt er  $\vartheta$  genau so, dass die gegebene *Stichprobe* unter  $\vartheta$  am wahrscheinlichsten ist.

Da es sich bei  $L$  meistens um ein Produkt handelt und die *log-Funktion* streng monoton steigend ist, kann man auch  $\log L$  über  $\vartheta$  minimieren, was einfacher zu rechnen ist.

## Häufig gebrauchte ML-Schätzer

- $X_i \sim \text{Be}(p)$ :

$$T_p = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n \quad (116)$$

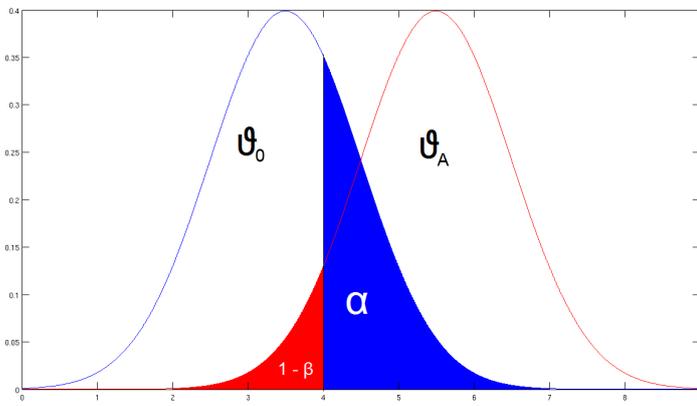


Abbildung 1: Ein Test mit Fehlern erster und zweiter Art

- $X_i \sim \mathcal{N}(\mu, \sigma^2)$ :

$$T_\mu = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n \quad (117)$$

$$T_{\sigma^2} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \quad (118)$$

$$= \left( \frac{1}{n} \sum_{i=1}^n X_i^2 \right) - (\bar{X}_n)^2$$

**Achtung:**  $T_{\sigma^2}$  ist nicht erwartungstreu:

$$E[T_{\sigma^2}] = \frac{n-1}{n} \text{Var}[X] \quad (119)$$

Deshalb benutzt man meistens die **empirische Stichprobenvarianz**  $S^2$ :

$$S^2 = T'_{\sigma^2} = \frac{n}{n-1} T_{\sigma^2} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2 \quad (120)$$

## Tests

Ausgehend von einer *Stichprobe* möchte man zwei Verteilungsparameter (bzw. Parameterbereiche) gegeneinander abwägen: Eine **Nullhypothese**  $\Theta_0$  und eine **Alternativhypothese**  $\Theta_A$ . Man wählt nun eine *Zufallsvariable*  $T$  namens **Teststatistik** abhängig von  $\vartheta$ , welche die Daten der *Stichprobe* auswertet. Dabei wollen wir die *Nullhypothese* ablehnen, wenn der realisierte Wert  $T(x_1, \dots, x_n)$  in einen **kritischen Bereich** oder **Verwerfungsbereich**  $K$  fällt.

Die Entscheidung kann auf zwei Arten falsch herauskommen:

- **Fehler 1. Art:** Die *Nullhypothese* wird abgelehnt, obwohl sie eigentlich richtig wäre. Die *Wahrscheinlichkeit* für einen *Fehler 1. Art* heisst **Signifikanzniveau**  $\alpha$ :

$$\alpha = P_{\vartheta_0}[T \in K], \quad \vartheta_0 \in \Theta_0 \quad (121)$$

- **Fehler 2. Art:** Die *Nullhypothese* wird angenommen, obwohl sie falsch wäre. Die *Wahrscheinlichkeit* für einen *Fehler 2. Art* beträgt  $1 - \beta$ , wobei  $\beta$  als die **Macht** des Tests bezeichnet wird:

$$\beta = P_{\vartheta_A}[T \in K], \quad \vartheta_A \in \Theta_A \quad (122)$$

Da es schwieriger ist, eine Hypothese zu verwerfen, wählen wir als *Nullhypothese* das Gegenteil der eigentlich gewünschten Aussage. Ausserdem wird immer ein *Signifikanzniveau*  $\alpha$  gegeben. Falls sich der *kritische Bereich* z.B. am "rechten Rand" von  $T$  befindet, berechnet sich der **kritische Wert**  $c$ , also dessen untere Grenze (exklusiv), zu:

$$P_{\vartheta_0}[T \geq c] = \alpha \quad \text{nach } c \text{ auflösen} \quad (123)$$

Bei einer zweiseitigen *Alternativhypothese* sind gegebenenfalls Symmetrien auszunutzen.

Die Wahrscheinlichkeit unter der *Nullhypothese*, den erhaltenen Wert für die *Teststatistik* zu bekommen, heisst **P-Wert**. Ist er kleiner als  $\alpha$ , so verwirft man die *Nullhypothese*.

## z-Test

Der *z-Test* ist ein Test für *Erwartungswert* bei bekannter *Varianz*  $\sigma^2$ . Es seien also  $X_1, \dots, X_n \sim \mathcal{N}(\vartheta, \sigma^2)$  *i.i.d.*. Wir wollen die *Nullhypothese*  $\vartheta = \vartheta_0$  testen. *Teststatistik*:

$$T = \frac{\bar{X}_n - \vartheta_0}{\frac{\sigma}{\sqrt{n}}} \sim \mathcal{N}(0, 1) \quad (124)$$

Den *kritischen Bereich*  $K$  bestimmt man abhängig von der *Alternativhypothese*  $\Theta_A$ :

- $\vartheta_A > \vartheta_0$  einseitig:  $K = (c_>, \infty)$  mit

$$c_> = (1 - \alpha)\text{-Quantil} = \Phi^{-1}(1 - \alpha) \quad (125)$$

- $\vartheta_A < \vartheta_0$  einseitig:  $K = (-\infty, c_<)$  mit

$$c_< = \alpha\text{-Quantil} = \Phi^{-1}(\alpha) \quad (126)$$

- $\vartheta_A \neq \vartheta_0$  zweiseitig:  $K = (-\infty, c_\neq) \cup (c_\neq, \infty)$

$$c_\neq = \left(1 - \frac{\alpha}{2}\right)\text{-Quantil} = \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \quad (127)$$

## t-Test

Der *t-Test* ist ein Test für *Erwartungswert* bei unbekannter *Varianz*. Es seien also  $X_1, \dots, X_n \sim \mathcal{N}(\vartheta, \sigma^2)$  und wir möchten die *Nullhypothese*  $\vartheta = \vartheta_0$  testen. *Teststatistik*:

$$T = \frac{\bar{X}_n - \vartheta_0}{\sqrt{\frac{S^2}{n}}} \sim t_{n-1} \quad (128)$$

Dabei bezeichnet  $S^2$  den *Schätzer* für die *empirische Stichprobenvarianz*. Der *kritische Bereich*  $K$  lässt sich analog zum *z-Test* mit den *Quantilen* der  $t_{n-1}$ -Verteilung bestimmen.

# Beispiele

## t-Test

### Aufgabe

Ein Waschmittelhersteller bringt 5kg-Packungen in den Umlauf. Die Konsumentenschutzorganisation kauft 25 Packungen. Es ergibt sich ein Mittel von  $\bar{X} = 4.9$  kg und eine empirische Stichprobenvarianz  $S^2 = 0.1\text{kg}^2$ . Die einzelnen Gewichte seien durch unabhängige  $\mathcal{N}(\mu, \sigma^2)$  Zufallsvariablen beschrieben.

1. Wie lauten die Hypothesen  $H_0$  und  $H_A$  ?
2. Wie ist  $(\bar{X} - 5)/(S/5)$  verteilt unter  $H_0$  ?
3. Führen Sie den t-Test auf dem 5%-Niveau durch. Wie gross ist der P-Wert? Wird die Nullhypothese verworfen?
4. Berechnen Sie das 95%-Vertrauensintervall für den in 3. beschriebenen Test.

### Lösung

1.  $H_0 : \mu = 5, H_1 : \mu < 5$
2. Verteilung:  $\sim t_{5^2-1} = t_{24}$
3. T-Statistik:  $T_1 = \frac{\bar{X} - \mu_0}{\sqrt{\frac{S^2}{n}}} = -1.581$ . P-Wert =  $P_{\mu_0}[T < c] = 0.0653$ . Gesucht ist ein  $c$ , sodass  $P_{\mu_0}[T < c] = 0.05$  bzw  $P_{\mu_0}[T > -c] = 0.95$ . Dies ergibt  $c = -1.711$ . Weil  $T_1 = -1.581 > c$  wird die Nullhypothese nicht verworfen.
4. Die Formel für das Vertrauensintervall ergibt  $I_{0.95} = [4.792, 5.008]$ . Da unser Test aber einseitig ist, wird das Intervall  $I_{0.95} = [-\infty, 5.008]$ .

## Folge von Zufallsvariablen

### Aufgabe

Seien  $X_1, \dots, X_n$  iid. Poisson-verteilte Zufallsvariablen mit Parameter  $\lambda = 2$ . Gegeben sei nun die Folge:

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

Wie gross ist der Grenzwert?

### Lösung

$$\frac{2n+1}{n^2} \sum_{i=1}^n X_i = \frac{2n+1}{n} \cdot \frac{1}{n} \sum_{i=1}^n X_i$$

Der zentrale Grenzwertsatz liefert für  $Y \sim \mathcal{N}(2, 4/n)$

$$\lim_{n \rightarrow \infty} \frac{2n+1}{n^2} \sum_{i=1}^n X_i = 2 \cdot E[Y] = 4$$

## Simulation(1)

### Aufgabe

Die Zufallsvariable  $X$  sei Pareto-verteilt und habe die Verteilungsfunktion:

$$F_X(x|x_0, a) = \begin{cases} 1 - \left(\frac{x}{x_0}\right)^{-\alpha} & \alpha > 1, x \geq x_0 \\ 0 & \text{sonst} \end{cases}$$
$$f_X(x|x_0, a) = \begin{cases} \alpha x_0^\alpha x^{-\alpha-1} & \alpha > 1, x \geq x_0 \\ 0 & \text{sonst} \end{cases}$$

Ein auf  $[0,1]$  uniform verteilter Zufallsgenerator habe nun die Werte 0.237 und 0.733 generiert. Berechne daraus 2 Realisierungen der einer Pareto-verteiltern Zufallsvariable mit  $\alpha = 2$  und  $x_0 = 2 \cdot 10^6$ .

### Lösung

Die Inverse  $F_X^{-1}$  der Verteilungsfunktion, ausgewertet an den generierten Stellen  $\in [0,1]$  ergibt die Realisierungen der Verteilung  $F_X$ .

$$\text{für } x \geq x_0 : F_X^{-1}(y) = \frac{x_0}{(1-y)^{1/\alpha}}$$

Jetzt müssen nur noch die beiden Werte eingesetzt werden.

## Simulation(2)

### Aufgabe

Die Cauchy-Verteilung hat die Dichte

$$f(x) = \frac{1}{\pi \cdot (1+x^2)} \text{ für } x \in \mathcal{R}$$

Konstruieren Sie eine Cauchy-verteile Stichprobe vom Umfang 4 aus der folgenden Exp(1)

$$x_1 = 0.417, \quad x_2 = 0.448, \quad x_3 = 0.114, \quad x_4 = 0.665$$

### Lösung

Die Verteilungsfunktion von  $X \sim \text{Exp}(1)$  ist  $F(x) = 1 - e^{-x}$ . Wenn man auf exponentialverteilte Werte die Verteilungsfunktion der Exponentialverteilung anwendet, erhält man  $[0,1]$ -uniform-verteilte Werte. Dies liefert in diesem Beispiel durch einsetzen der  $x_i$  in  $F$  die uniform verteilten  $y_i$ :

$$y_1 = 0.341, \quad y_2 = 0.361, \quad y_3 = 0.107, \quad y_4 = 0.486$$

Nun muss man nur noch die  $y_i$  in  $F^{-1}$  der Cauchy-Verteilung einsetzen für Cauchy-verteile  $z_i$ .

$$F(x) = \int_{-\infty}^x f(x)dx = \frac{1}{2} + \frac{1}{\pi} \arctan(x)$$
$$\rightarrow F^{-1}(y) = \tan\left(\pi \cdot \left(y - \frac{1}{2}\right)\right)$$

$$z_1 = -0.544, \quad z_2 = -0.465, \quad z_3 = -2.836, \quad z_4 = -0.043$$