

Mitschrieb zur Vorlesung

# Stochastik für Informatiker und Bioinformatiker

Markus List

Sommersemester 2007

## Inhaltsverzeichnis

|  |           |
|--|-----------|
| <b>A. Wahrscheinlichkeitstheorie</b>                         | <b>4</b>  |
| A.1. Wahrscheinlichkeit                                      | 4         |
| A.2. Laplacesche Wahrscheinlichkeitsräume                    | 4         |
| A.3. Axiomatischer Zugang nach A.N.Kolmogoroff               | 7         |
| A.4. Bedingte W.keiten                                       | 10        |
| A.5. Unabhängigkeit  | 11        |
| A.6. Zufallsvariablen  | 12        |
| A.7. Diskrete Zufallsvariablen                               | 14        |
| A.8. Binomialverteilung                                      | 15        |
| A.9. Erzeugende Funktionen                                   | 16        |
| A.10.Poisson-Verteilung                                      | 18        |
| A.11.Geometrische Verteilung                                 | 20        |
| A.12.Zufallsvariablen mit Dichten                            | 20        |
| A.13.Gleichverteilung  | 22        |
| A.14.Exponentialverteilung                                   | 23        |
| A.15.Normalverteilung  | 23        |
| A.16.Tschebyscheffsche Ungleichung                           | 25        |
| A.17.Gesetz der großen Zahlen                                | 25        |
| A.18.Zentraler Grenzwertsatz                                 | 26        |
| A.19.Mehr zur Unabhängigkeit                                 | 28        |
| A.20.Faltung   | 30        |
| A.21.Poisson-Punktprozess                                    | 31        |
| <b>B. Statistik</b>  | <b>33</b> |
| B.1. Statistisches Modell und Stichproben                    | 33        |
| B.2. Schätzen von Parametern                                 | 34        |
| B.3. Erwartungstreue Schätzer von Erwartungswert und Varianz | 36        |
| B.4. Maximum-Likelihood-Methode und Momentmethode            | 37        |
| B.5. Konfidenzintervalle normalverteilter ZVen               | 39        |
| B.6. Testen von Hypothesen, Binomialtest                     | 43        |
| B.7. Weitere Tests   | 47        |
| B.7.1. z-Test:   | 47        |
| B.7.2. t-Test  | 49        |
| B.7.3. Chi-Quadrat-Anpassungstest                            | 50        |
| B.7.4. Chi-Quadrat-Unabhängigkeitstest:                      | 51        |
| B.7.5. Vorzeichentest:                                       | 51        |
| B.7.6. Wilcoxon-Test:  | 52        |

*Da dieser Aufschrieb während der Vorlesung entsteht, schleichen sich leicht Fehler ein. Wenn ihr welche findet dürft ihr mich gerne darauf hinweisen: Einfach eine kurze E-Mail an: [markus.list@student.uni-tuebingen.de](mailto:markus.list@student.uni-tuebingen.de)*

## A. Wahrscheinlichkeitstheorie

### A.1. Wahrscheinlichkeit

**Naiver Zugang:** Man unterscheidet bei den möglichen Ausgängen eines Experiments zwischen günstigen und ungünstigen Fällen und interpretiert die Zahl

$$W := \frac{\text{Anzahl günstiger Fälle}}{\text{Anzahl aller Fälle}} \quad (1)$$

als die Wahrscheinlichkeit (kurz W.keit oder W.) für das Ereignis, dass das Experiment günstig ausgeht. Dabei wird angenommen, dass alle möglichen Fälle „gleich wahrscheinlich“ eintreten.

**Bsp.:** Idealer unverfälschter Würfel

Jede der Zahlen von 1 bis 6 wird gleich wahrscheinlich eintreten ( $W = \frac{1}{6}$ )  
Nimmt man z.B. die geraden Zahlen als günstige Fälle, erhält man ( $W = \frac{3}{6} = \frac{1}{2}$ )

**Realer Würfel:**

1. Man glaubt der Würfel sei ideal  
**Problem:** Es stimmt vielleicht nicht (z.B. gezinkter Würfel)
2. Man würfelt z.B. 1000 mal und bestimmt die W.keiten via Formel (1)  
**Problem:** Das Resultat hängt vom konkreten Ausgang des Würfels ab (z.B. tausend mal die 6)

### A.2. Laplacesche Wahrscheinlichkeitsräume

Gegeben seien eine natürliche Zahl  $n \in \mathbb{N}$  und ein Grundraum  $\Omega = \{\omega_1, \dots, \omega_n\}$  von Elementarereignissen  $\omega_i$ .

Die Potenzmenge  $\mathcal{P}(\Omega)$  von  $\Omega$ , d.h. die Menge („Sammlung“, „Familie“) der Teilmengen von  $\Omega$ , d.h. die Mengen  $A \subset \Omega$  heißen Ereignisse in  $\Omega$ .

Es gibt also  $2^n$  Ereignisse in  $\Omega$ .

Wir definieren nun eine Abb.  $P : \mathcal{P}(\Omega) \rightarrow [0, 1]$ , („probability“) wie folgt:

- Für Elementarereignisse  $P(\{\omega_i\}) := \frac{1}{n}$
- Für Ereignisse  $P(A) := \frac{\#A}{n} := \frac{\text{Anzahl Elementarereignisse in } A}{n}$

**Interpretation:** Man betrachtet die  $\omega_i$  im Ereignis (in der Teilmenge)  $A \subset \Omega$  als die günstigen Fälle.

**Insbesondere gilt:**

- $P(\emptyset) = 0$
- $P(\Omega) = 1$

Das Tupel  $(\Omega, P)$  heißt Laplacescher Wahrscheinlichkeitsraum mit  $n$  Elementen.

**Begriffe aus der Mengenlehre:**

**Vereinigung:**  $A \cup B := \{\omega \in \Omega : \omega \in A \text{ oder } \omega \in B\}$   
 „es tritt entweder  $A$  oder auch  $B$  ein“

$$\bigcup_{n=1}^{\infty} A_n := A_1 \cup A_2 \cup A_3 \cup \dots$$

**Schnitt:**  $A \cap B := \{\omega \in A \text{ und } \omega \in B\}$   
 „es tritt sowohl  $A$  wie auch  $B$  ein“

$$\bigcap_{n=1}^{\infty} A_n := A_1 \cap A_2 \cap A_3 \cap \dots$$

**Ähnlich:**  $k \in \mathbb{N}$   
 $\bigcup_{n=1}^k A_n := A_1 \cup A_2 \cup \dots \cup A_k$   
 $\bigcap_{n=1}^k A_n := A_1 \cap A_2 \cap \dots \cap A_k$

**Weiter:** Seien  $A, B \subset \Omega$  zwei Ereignisse.

**Dann gilt:**  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$

**Insbesondere:**  $P(A \cap B) = 0$   
 $\Rightarrow P(A \cup B) = P(A) + P(B)$

**Also auch:**  $A \cap B = \emptyset$ , d.h.  $A$  und  $B$  disjunkt.  
 $\Rightarrow P(A \cup B) = P(A) + P(B)$

**Grund:** Venn-Diagramm  $\frac{\#(A \cup B)}{n} = \frac{\#A}{n} + \frac{\#B}{n} - \frac{\#(A \cap B)}{n}$




Abbildung 1: Venn-Diagramm

**Bsp.:**

- Münzwurf,  $n = 2$ ,  $\Omega = \{K, Z\}$  oder auch  $\Omega = \{0, 1\}$   
Ereignisse in  $\Omega = \{K, Z\}$ :  $\emptyset, \{K\}, \{Z\}, \{K, Z\}$

$$\begin{aligned} \text{W.keiten: } P(\emptyset) &= 0, P(\{K, Z\}) = \frac{2}{2} = 1 \\ P(\{K\}) &= P(\{Z\}) = \frac{1}{2} \end{aligned}$$

- Würfel,  $n = 6$ ,  $\Omega = \{1, 2, 3, 4, 5, 6\}$   
Anzahl der Ereignisse =  $2^6 = 64$
- Skat-Kartenspiel  $n = 32$
- Roulette  $n = 37$

**Bsp.:** Zweimaliges Würfeln

$$\begin{aligned} \Omega &= \{1, \dots, 6\} \times \{1, \dots, 6\} \text{ Kartesisches Produkt} \\ &= \{1, \dots, 6\}^2 \\ &= \{(1, 1), \dots, (1, 6), (2, 1), \dots, (2, 6), \dots, (6, 1), \dots, (6, 6)\} \end{aligned}$$

Anzahl Elementarereignisse  $n = 36$

Sei  $A$  das Ereignis, dass eine 6 und eine weitere gerade Zahl gewürfelt werden.

$$A := \{(6, 2), (6, 4), (6, 6), (2, 6), (4, 6)\}$$

$$\text{Dann gilt } P(A) = \frac{5}{36}$$

Sei  $B$  das Ereignis, dass mind. eine 6 geworfen wird, also

$$B := \{(6, 1), (6, 2), (6, 3), (6, 4), (6, 5), (6, 6), (1, 6), (2, 6), (3, 6), (4, 6), (5, 6)\}$$

Dann gilt  $P(B) = \frac{11}{36}$

Sei  $C$  das Ereignis, dass zwei gerade Zahlen geworfen werden, also

$$C := \{(2, 2), (2, 4), (2, 6), (4, 2), (4, 4), (4, 6), (6, 2), (6, 4), (6, 6)\}$$

Dann gilt  $P(B) = \frac{9}{36} = \frac{1}{4}$

**Es gilt weiter:**  $A = B \cap C$

Wir erhalten also  $P$  („mind. eine 6 oder auch 2 gerade Zahlen“)

$$= P(B \cup C) = P(B) + P(C) - \underbrace{P(B \cap C)}_{P(A)} = \frac{11}{36} + \frac{9}{36} - \frac{5}{36} = \frac{5}{12}$$

### A.3. Axiomatischer Zugang nach A.N.Kolmogoroff

Gegeben sei eine Menge  $\Omega \neq \emptyset$ . Man nennt  $\Omega$  den Grundraum oder Ereignisraum. Die Elemente von  $\Omega$  heißen Elementarereignisse. Gegeben sei weiter eine Familie  $\mathcal{F} \subset \mathcal{P}(\Omega)$  von Teilmengen von  $\Omega$  mit folgenden Eigenschaften:

1. Es gilt  $\Omega \in \mathcal{F}$
2. Mit  $A \in \mathcal{F}$  ist auch das Komplement  $A^c = \{\omega \in \Omega : \omega \notin A\} \in \mathcal{F}$
3. gilt  $A_1, A_2, \dots \in \mathcal{F}$ , so gelten auch  $\bigcup_{n=1}^{\infty} A_n \in \mathcal{F}$  und  $\bigcap_{n=1}^{\infty} A_n \in \mathcal{F}$

**Einfachstes Bsp.:**  $\mathcal{F} = \mathcal{P}(\Omega)$

**Bemerkung:** Sind 1., 2. und 3. erfüllt, so gilt auch folgende Aussage:

3.' gilt  $A_1, \dots, A_k \in \mathcal{F}$ , so gelten auch

$$\bigcup_{n=1}^k A_n \in \mathcal{F} \text{ und } \bigcap_{n=1}^k A_n \in \mathcal{F}$$

**Grund:**

- Für  $A_1, \dots, A_k \in \mathcal{F}$  und  $A_{k+1} := \Omega, A_{k+2} := \Omega, \dots$  gelten auch  $A_1, A_2, \dots \overset{\text{nach 1}}{\in} \mathcal{F}$  und

$$\bigcap_{n=1}^{\infty} A_n = \bigcap_{n=1}^k A_n$$

Also gilt auch  $\bigcap_{n=1}^k A_n \in \mathcal{F}$  nach 3.

- Nach 1. und 2. gilt  $\emptyset \in \mathcal{F}$ , da  $\Omega^c = \emptyset$   
Für  $A_1, \dots, A_k \in \mathcal{F}$  und  $A_{k+1} := \emptyset, A_{k+2} := \emptyset, \dots$  gelten auch  $A_1, A_2, \dots \in \mathcal{F}$  und

$$\bigcup_{n=1}^k A_n = \bigcup_{n=1}^{\infty} A_n$$

Also gilt auch  $\bigcup_{n=1}^k A_n \in \mathcal{F}$  nach 3.

Gegeben sei zusätzliche eine Abb.  $P : \mathcal{F} \rightarrow [0, 1]$  mit folgenden Eigenschaften:

- $P(\emptyset) = 0$  und  $P(\Omega) = 1$
- Seien  $A_1, A_2, \dots \in \mathcal{F}$  paarweise disjunkt, d.h.  $A_i \cap A_j = \emptyset \forall i, j \in \mathbb{N}$  und  $i \neq j$ ,

$$\text{so gilt } P\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} P(A_n) := P(A_1) + P(A_2) + \dots$$

**Bemerkung:** Sind i.) und ii.) erfüllt, so gilt auch folgende Aussage:

ii'.) Sind  $A_1, \dots, A_k \in \mathcal{F}$  paarweise disjunkt, d.h.

$$A_i \cap A_j = \emptyset \forall i, j \in \{1, \dots, k\} \text{ mit } i \neq j, \text{ so gilt}$$

$$P\left(\bigcup_{n=1}^k A_n\right) = \sum_{n=1}^k P(A_n) = P(A_1) + \dots + P(A_k)$$

**Grund:** Sind  $A_1, \dots, A_k \in \mathcal{F}$  und  $A_{k+1} := \emptyset, A_{k+2} := \emptyset, \dots$

so gelten  $A_1, A_2, \dots \in \mathcal{F}$  paarweise disjunkt und  $\bigcup_{n=1}^k A_n = \bigcup_{n=1}^{\infty} A_n$ ,

und somit

$$P\left(\bigcup_{n=1}^k A_n\right) = P\left(\bigcup_{n=1}^{\infty} A_n\right) \stackrel{ii}{=} \sum_{n=1}^{\infty} P(A_n) \stackrel{i}{=} \sum_{n=1}^k P(A_n)$$

Ein solches Tripel (3-Tupel)  $(\Omega, \mathcal{F}, P)$  wird Wahrscheinlichkeitsraum genannt.

Für  $A, B \in \mathcal{F}$  gilt z.B. Folgendes:

- $A \cup B = (A \cap B) \cup (A \cap B^c) \cup (A^c \cap B)$  paarweise disjunkt




Abbildung 2: Venn-Diagramm

- $A = (A \cap B) \cup (A \cap B^c)$  disjunkt

- $B = (A \cap B) \cup (A^c \cap B)$  disjunkt

Nach 3' sind alle diese Mengen Ereignisse und nach ii.) gilt:

$$\begin{aligned} P(A \cup B) &= P(A \cap B) + P(A \cap B^c) + P(A^c \cap B) \\ &= P(A \cap B) + P(A \cap B^c) + P(A \cap B) + P(A^c \cap B) - P(A \cap B) \\ &= P(A) + P(B) - P(A \cap B) \end{aligned}$$

### Abzählbar unendliche W.räume

Gegeben seien ein Grundraum  $\Omega = \{\omega_1, \omega_2, \dots\}$  oder  $\Omega = \{\omega_0, \omega_1, \dots\}$  und W.keiten  $P(\{\omega_i\}) \in [0, 1]$  mit der Eigenschaft

$$\sum_{i=1}^{\infty} P(\{\omega_i\}) = 1, \text{ bzw. } \sum_{i=0}^{\infty} P(\{\omega_i\}) = 1$$

Für  $A \subset \Omega$  setzt man  $P(A) := \sum_{\omega \in A} P(\{\omega\})$

D.h.  $P(A)$  ist die Summe der W.keiten der Elementarereignisse in  $A$ .

Dann ist  $(\Omega, \mathcal{P}(\Omega), P)$  ein W.raum.

Wir nennen  $(\Omega, P)$  einen abzählbar unendlichen W.raum

### Endliche W.räume

Gegeben seien ein Grundraum  $\Omega = \{\omega_1, \dots, \omega_n\}$  oder  $\Omega = \{\omega_0, \dots, \omega_n\}$  und W.keiten  $P(\{\omega_i\})$  mit  $\sum_{i=1}^n P(\{\omega_i\}) = 1$ , bzw  $\sum_{i=0}^n P(\{\omega_i\}) = 1$

Für  $A \subset \Omega$  setzt man  $P(A) = \sum_{\omega \in A} P(\{\omega\})$

Dann ist  $(\Omega, \mathcal{P}(\Omega), P)$  ein W.raum.

Wir nennen  $(\Omega, P)$  einen endlichen W.raum

**Bsp.:** Ein Laplacescher W.raum mit  $n$  Elementen ist ein endlicher W.raum mit  $P(\{\omega_i\}) = \frac{1}{n}$  für jedes Elementarereignis  $\omega_i$ .

### A.4. Bedingte W.keiten

Wir betrachten einen Laplaceschen W.raum  $(\Omega, P)$  mit  $n$  Elementen und  $A, B \subset \Omega$

$P(A) = \frac{\#A}{n}$  beschreibt die W.keit dafür, dass ein beliebiges Elementarereignis von  $\Omega$  aus  $A$  ist.

Wie groß ist die W.keit dafür, dass ein solches Elementarereignis (wenn es bereits aus  $A$  ist), dann auch aus  $B$  ist?

#### Naiver Ansatz:

Mögliche Fälle  $A$

Günstige Fälle  $A \cap B$

$$\text{Also: } W = \frac{\#(A \cap B)}{\#A} = \frac{\frac{\#(A \cap B)}{n}}{\frac{\#A}{n}} = \frac{P(A \cap B)}{P(A)}$$

Dies lässt sich auf allg. W.räume erweitern:

Seien  $(\Omega, \mathcal{F}, P)$  ein W.raum,  $A, B \in \mathcal{F}$  und  $P(A) > 0$

Dann definiert man die bedingte W.keit von  $B$  unter  $A$  als

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

Für  $P(A) = 0$  setzt man  $P(B|A) := 0$

$$\text{Analog: } P(A|B) := \frac{P(A \cap B)}{P(B)}, \quad P(B) > 0$$

$$P(A|B) := 0, \quad P(B) = 0$$

**Multiplikationssatz:**

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

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

**Bayessche Regel:** Es sei  $P(B) > 0$

$$\text{Dann gilt: } P(A|B) = \frac{P(A) \cdot P(B|A)}{P(B)}$$

**Bsp.:** Würfeln  $A :=$  „Augenzahl  $\geq 3$ “,  $B :=$  „Augenzahl ungerade“

$$P(A) = \frac{4}{6} = \frac{2}{3}, P(B) = \frac{3}{6} = \frac{1}{2} \Rightarrow P(B|A) = \frac{2}{4} = \frac{1}{2}$$

$$P(A|B) = \frac{\frac{4}{6} \cdot \frac{2}{4}}{\frac{1}{2}} = \frac{2}{3}$$

**Satz von der totalen W.keit**

$$P(B) = P(A) \cdot P(B|A) + P(A^c) \cdot P(B|A^c)$$

**Allgemeiner:** Es seien  $A_n$  endlich oder abzählbar viele paarweise disjunkte Ereignisse mit  $\bigcup_n A_n = \Omega$ .

$$\text{Dann gilt: } P(B) = \underbrace{\sum_n P(A_n)}_{\text{endliche oder unendliche Summe}} \cdot P(B|A_n)$$

## A.5. Unabhängigkeit

Gegeben W.raum  $(\Omega, \mathcal{F}, P)$

**Definition:**

Zwei Ereignisse  $A, B \in \mathcal{F}$  heißen unabhängig, wenn  $P(A \cap B) = P(A) \cdot P(B)$  gilt.

**Interpretation:**

$$\text{Für } P(A) > 0 \text{ und } A, B \text{ unabh. gilt } P(B|A) = \frac{P(A \cap B)}{P(A)} = \frac{P(B) \cdot P(A)}{P(A)} = P(B)$$

d.h. die W.keit von  $B$  hängt nicht davon ab, ob  $A$  eingetroffen ist.

**Analog:** Für  $P(B) > 0$ ,  $A, B$  unabhängig gilt  $P(A|B) = P(A)$

**Bsp.:** Zweimaliges Ziehen einer Skatkarte

Seien  $A = \text{„As beim 1. Zug“}$

$B = \text{„As beim 2. Zug“}$

- mit zurücklegen:

$$P(A) = P(B) = \frac{4}{32}, P(A \cap B) = \frac{4 \cdot 4}{32^2}$$

Also:  $A, B$  sind unabhängig

- ohne zurücklegen:

$$P(A) = \frac{4}{32} = P(B), P(A \cap B) = \frac{4 \cdot 3}{32 \cdot 31}$$

Also:  $A, B$  sind nicht unabhängig.

## A.6. Zufallsvariablen

Gegeben sei ein endlicher oder abzählbar unendlicher W.raum  $(\Omega, P)$ . Wir nennen eine Abbildung  $X : \Omega \rightarrow \mathbb{R}$  eine Zufallsvariable (kurz ZV) auf  $(\Omega, P)$ .

**Notation:** Für  $a \in \mathbb{R}$  schreiben wir  $\{X = a\} = \{\omega \in \Omega : X(\omega) = a\}$ .

Es bezeichnet also

$P(X = a) := P(\{X = a\})$  die W.keit, dass  $X$  der Wert  $a \in \mathbb{R}$  zugewiesen wird.

**Bsp.:** Würfeln  $\Omega = \{1, \dots, 6\}$

$$P(A) = \frac{\#A}{n} \text{ für } A \subset \Omega$$

$X(\omega) := \omega$  für  $\omega \in \{1, \dots, 6\}$  die „Augenzahl“

$$P(X = \omega) = \frac{1}{6} \text{ für jedes } \omega \in \{1, \dots, 6\}$$

**Bsp.:** Zweimaliges Würfeln

$$\begin{aligned} \Omega &= \{1, \dots, 6\} \times \{1, \dots, 6\} \\ &= \{(1, 1), \dots, (1, 6) \dots (6, 1), \dots, (6, 6)\} \end{aligned}$$

$$P(A) = \frac{\#A}{36}, A \subset \Omega$$

$X((\omega_1, \omega_2)) := \omega_1$  Augenzahl des 1.Wurfes

$Y((\omega_1, \omega_2)) := \omega_2$  Augenzahl des 2.Wurfes

Wir setzen  $Z := X + Y$ , also  $Z((\omega_1, \omega_2)) := \omega_1 + \omega_2$  „die Summe der Augenzahlen“  
Es gilt z.B.

$$P(Z = 2) = \frac{1}{36}$$

$$P(Z = 3) = \frac{2}{36}$$

...

$$P(Z = 7) = \frac{6}{36}$$

Gegeben sei ein beliebiger W.raum  $(\Omega, \mathcal{F}, P)$

Eine Abb.  $X : \Omega \rightarrow \mathbb{R}$  ist eine Zufallsvariable,  
wenn sie folgende Eigenschaft erfüllt:

Für jede Wahl  $a \leq b$  gilt  $\{a \leq X \leq b\} := \{\omega \in \Omega : a \leq X(\omega) \text{ und } X(\omega) \leq b\} \in \mathcal{F}$

Man sagt,  $X$  ist messbar bezgl.  $\mathcal{F}$  (vgl. „Masstheorie“ in der Analysis)

Die Gesamtheit der W.keiten  $P(a \leq X \leq b)$  nennt man die Verteilung von  $X$  unter  $P$ .  
Die Verteilung von  $X$  unter  $P$  ist bereits festgelegt durch die Funktion

$$F(t) := P(X \leq t) := P(\{X \leq t\}), t \in \mathbb{R}$$

wobei  $\{X \leq t\} = \{\omega \in \Omega : X(\omega) \leq t\}$ , die sogenannte Verteilungsfunktion von  $X$  unter  $P$  ist.  $F$  ist eine monoton wachsende, rechtsseitig stetige Funktion mit Werten im Intervall  $[0, 1]$ .

**Bsp.:** Würfeln




Abbildung 3: Verteilungsfunktion beim Würfeln

**Definition:** Zwei ZVen  $X, Y$  auf einem W.raum  $(\Omega, \mathcal{F}, P)$  heißen unabhängig, wenn

$$P(X \leq a, Y \leq b) := P(\{X \leq a\} \cap \{Y \leq b\})$$

$$= P(X \leq a) \cdot P(Y \leq b) \text{ gilt } \forall a, b \in \mathbb{R}.$$

**Bsp.:** zweimaliges Würfeln

$$\Omega = \{1, \dots, 6\} \times \{1, \dots, 6\}$$

$$P(A) = \frac{\#A}{36}$$

$X$ : Augenzahl 1. Wurf

$Y$ : Augenzahl 2. Wurf

Betrachten  $a, b \in \{1, \dots, 6\}$  (die anderen Fälle folgen einfach)

$$\{X \leq a\} \cap \{Y \leq b\} = \{(1, 1), \dots, (1, b), \dots, (a, 1), \dots, (a, b)\}$$

$$\text{Also: } P(X \leq a, Y \leq b) = \frac{a \cdot b}{36} = \frac{a}{6} \cdot \frac{b}{6}$$

$$= P(X \leq a) \cdot P(y \leq b)$$

**Somit:**  $X, Y$  sind unabhängig.

## A.7. Diskrete Zufallsvariablen

**Definition:** Eine ZV heißt diskret (verteilt), wenn sie endlich viele Werte  $x_1, \dots, x_n \in \mathbb{R}$  oder abzählbar unendlich viele Werte  $x_1, x_2, \dots \in \mathbb{R}$  annimmt.

Die Gesamtheit der Zahlenpaare  $(x_i, p_i)$ , wobei  $p_i := P(X = x_i)$  nennen wir die Verteilung von  $X$  unter  $P$  (die Verteilung im Sinne von Kap. 6 erhält man durch Aufsummieren der entsprechenden  $p_i$ ).

**Erwartungswert:** Falls die (ev. unendliche) Summe

$$E(x) := \sum_i x_i \cdot p_i$$

existiert, nennen wir  $E(x)$  den Erwartungswert.

Falls die Summe nicht existiert oder gleich unendlich ist, sagt man  $E(x)$  ex. nicht (vgl. Übung).

Falls  $E(x)$  existiert, nennen wir

$Var(x) := \sum_i (x_i - E(x))^2 \cdot p_i$  die Varianz von  $X$  unter  $P$ , und

$\sigma(X) := \sqrt{Var(x)}$  die Standardabweichung oder Streuung von  $X$ .

### Bemerkungen:

- $E(X)$  beschreibt in einem gewissen Sinne die „Mitte“ der Verteilung von  $X$ .
- Für  $Y := (X - E(X))^2$  gilt  $Var(X) = E(Y)$

$Var(X)$  beschreibt die „mittlere“ quadratische Abweichung von  $X$  zum Erwartungswert  $E(X)$ .

$$\begin{aligned} \bullet \quad Var(X) &= \sum_i (x_i^2 - 2x_i \cdot E(X) + E(X)^2) \cdot p_i \\ &= \underbrace{\sum_i x_i^2 \cdot p_i}_{E(X^2)} - 2E(X) \underbrace{\sum_i x_i \cdot p_i}_{E(X)} + E(X)^2 \underbrace{\sum_i p_i}_{=1} \\ &= E(X^2) - E(X)^2 \end{aligned}$$

Um die Verteilung von  $X$  mit Verteilungen anderer Zufallsvariablen zu vergleichen ist es sinnvoll die Standardisierte  $X^* := \frac{X - E(X)}{\sigma(X)}$ , falls  $\sigma(X) > 0$ , von  $X$  zu betrachten. Es gilt  $E(X^*) = 0, Var(X^*) = 1$

## A.8. Binomialverteilung

Wir betrachten das  $n$ -malige Werfen einer Münze (ev. gezinkt).

Grundraum  $\{0, 1\}^n = \underbrace{\{(\omega_1, \dots, \omega_n) : \omega_i \in \{0, 1\} \text{ für } i = 1, \dots, n\}}_{\text{„n-Tupel“}}$

1: „Erfolg“, 0: „Misserfolg“

Beim einmaligen Würfeln sei die W.keit für Erfolg gleich  $p$ , für Misserfolg also  $q := 1 - p \in [0, 1]$

Sei nun  $\omega = (\omega_1, \dots, \omega_n) \in \Omega$  und  $k := \omega_1 + \dots + \omega_n$  die Gesamtzahl der Erfolge.

Dann setzen wir  $P(\omega) := P(\{\omega\}) = p^k \cdot q^{n-k}$

und  $P(A) = \sum_{\omega \in A} p(\omega)$

Weiter sei  $X :=$  „Gesamtzahl der Erfolge“.

$$\text{Dann gilt } p_k = P(X = k) = \underbrace{\binom{n}{k}}_* \cdot p^k \cdot q^{n-k}$$

\* Anzahl der  $\omega = (\omega_1, \dots, \omega_n) \in \Omega$  mit  $\omega_1 + \dots + \omega_n = k$

**Definition:** Eine solche ZV  $X$  heißt binomialverteilt mit Parametern  $n \in \mathbb{N}$  und  $p \in [0, 1]$ , kurz  $B(n, p)$

### A.9. Erzeugende Funktionen

Gegeben sei ZV  $X$  mit Werten in  $\mathbb{N}_0$

und Verteilung  $p_k := P(X = k)$  für  $k \in \mathbb{N}_0$ . Für  $s \in [0, 1]$  definieren wir

$$f_X(s) := \sum_{k=0}^{\infty} p_k \cdot s^k$$

Es gilt  $f_X(s) \leq \sum_{k=0}^{\infty} p_k = 1$ , also insbesondere  $f_X(s) < \infty$

Die Abb.  $f : [0, 1] \rightarrow \mathbb{R}$  heißt erzeugende Funktion von  $X$ .

Erwartungswert und Varianz von  $X$  lassen sich mit Hilfe von  $f_X$  berechnen:

Für  $s \in [0, 1)$  gilt:

$$\begin{aligned} \bullet f'_X &= \frac{d}{ds} \left( \sum_{k=0}^{\infty} p_k s^k \right) \stackrel{\text{Analysis}}{=} \sum_{k=0}^{\infty} \frac{d}{ds} (p_k \cdot s^k) \\ &= \sum_{k=1}^{\infty} p_k \cdot k \cdot s^{k-1} \\ \bullet f''_X &= \frac{d}{ds} \left( \sum_{k=1}^{\infty} p_k \cdot k \cdot s^{k-1} \right) \stackrel{\text{Analysis}}{=} \sum_{k=1}^{\infty} \frac{d}{ds} (p_k \cdot k \cdot s^{k-1}) = \sum_{k=2}^{\infty} p_k \cdot k(k-1) \cdot s^{k-2} \end{aligned}$$

Setzt man  $s = 1$  ein, erhält man:

$$\begin{aligned} \bullet f'_X(1) &= \sum_{k=1}^{\infty} p_k \cdot k = E(X) \\ \bullet f''_X(1) &= \sum_{k=2}^{\infty} p_k \cdot k(k-1) = \sum_{k=1}^{\infty} p_k \cdot k^2 - \sum_{k=1}^{\infty} p_k \cdot k = E(X^2) - E(X) \end{aligned}$$

**Also:**

$$\begin{aligned} \text{Var}(X) &= E(X^2) - E(X)^2 \\ &= f''_X(1) + f'_X(1) - (f'_X(1))^2 \end{aligned}$$

**Bsp.:** Binomialverteilung

$X$  := Anzahl der Erfolge beim  $n$ -maligen Werfen einer ev. unfairen Münze mit Erfolgsw.keit  $p$  (Bernoulli-Experiment mit Erfolgsw.keit  $p$ )

Es gilt also  $p_k = P(X = k) = \binom{n}{k} p^k \cdot q^{n-k}$  mit  $q = 1 - p$  und  $k \in \{0, \dots, n\}$

$$\begin{aligned} f_X(s) &= \sum_{k=0}^n \binom{n}{k} p^k q^{n-k} \cdot s^k \\ &= \sum_{k=0}^n \binom{n}{k} (p \cdot s)^k \cdot q^{n-k} \\ &= (p \cdot s + q)^n \quad \text{Binomische Formel} \end{aligned}$$

$$f'_X(s) = n(p \cdot s + q)^{n-1} \cdot p$$

$$f''_X(s) = n(n-1)(p \cdot s + q)^{n-2} p^2$$

**Also:**  $E(X) = n \cdot p$

$$\begin{aligned} \text{Var}(X) &= n(n-1) \cdot p^2 + n \cdot p - n^2 \cdot p^2 \\ &= n \cdot p(-p + 1) \\ &= n \cdot p \cdot q \end{aligned}$$

**Alternative:**  $X$  binomialverteilt mit Parametern  $n, p$ .

$$\Omega := \{\omega = (\omega_1, \dots, \omega_n) : \omega_i \in \{0, 1\} \text{ für } i = 1, \dots, n\}$$

$$P(\omega) = p^k \cdot q^{n-k}, \text{ wobei } k = \omega_1 + \dots + \omega_n$$

Sei  $X_i(\omega) := \omega_i$  „Ausgang des  $i$ -ten Wurfes“

$$\text{Dann gilt } X = X_1 + \dots + X_n$$

**Definition:** Die ZVen  $X_1, \dots, X_n$  heißen unabhängig, wenn

$$P(X_1 \leq a_1, \dots, X_n \leq a_n) = P(X_1 \leq a_1) \cdot \dots \cdot P(X_n \leq a_n) \quad \forall a_1, \dots, a_n \in \mathbb{R}$$

**Bemerkung:** Nehmen  $X_1, \dots, X_n$  nur Werte in  $\mathbb{N}_0$  an, so sind sie genau dann unabhängig, wenn

$P(X_1 = a_1, \dots, X_n = a_n) = P(X_1 = a_1) \cdot \dots \cdot P(X_n = a_n) \quad \forall a_1, \dots, a_n \in \mathbb{N}_0$   
(für  $n = 2$  vergleiche Übung)

Beim  $n$ -maligen Werfen gilt:

$$P(X_i = a_i) = \begin{cases} p & \text{für } a_i = 1 \\ q & \text{für } a_i = 0 \\ 0 & \text{sonst} \end{cases}$$

berechenbar mit der Formel  $P(A) = \sum_{\omega \in A} p(\omega)$  mit  $A = \{X_i = a_i\}$

Es gilt also für  $\omega = (a_1, \dots, a_n), k = a_1 + \dots + a_n$

$$\begin{aligned} P(X_1 = a_1, \dots, X_n = a_n) &= P(\omega) \\ &= P(X_1 = a_1) \cdot \dots \cdot P(X_n = a_n) \end{aligned}$$

(mit  $a_i \in \{0, 1\}$ , alle anderen W.keiten sind Null)

Also sind  $X_1, \dots, X_n$  unabhängig.

**Satz:** Seien  $X_1, \dots, X_n$  ZVen mit existierenden Erwartungswerten und Varianzen.

- i.)  $E(x_1 + \dots + x_n) = E(x_1) + \dots + E(x_n)$
- ii.) Sind  $X_1, \dots, X_n$  unabhängig, so gilt  $Var(X_1 + \dots + X_n) = Var(X_1) + \dots + Var(X_n)$   
(vgl. Übungen für  $n = 2$  und Werte in  $\mathbb{N}_0$ ).

Für die Binomialverteilung gilt also:

$$E(X) = E(X_1) + \dots + E(X_n) = n \cdot p, \text{ da } E(X_i) = p$$

$$Var(X) = Var(X_1) + \dots + Var(X_n) = n \cdot p \cdot q, \text{ da } Var(X_i) = p \cdot q$$



## A.10. Poisson-Verteilung

Ein bestimmtes „Ereignis“ treffe im Laufe der Zeit beliebig oft und zu zufälligen Zeitpunkten ein. Mit  $X_I$  beschreiben wir wie oft ein solches Ereignis in einem Intervall  $I$  eintritt.

Der Erwartungswert  $E(X_I) =: \mu > 0$  sei vorgegeben (z.B. durch Messungen) Was ist die Verteilung  $p_k = P(X_I = k)$  von  $X$ ? Wie soll sie gewählt werden?

Dazu teilen wir  $I$  auf in kleinere Intervalle  $I_1, \dots, I_n$  von identischer Länge.

Mit  $X_{I_i}$ , für  $i = 1, \dots, n$ , bezeichnen wir die Anzahl der „Ereignisse“ in  $I_i$

Abbildung 4:  $X_I = 3$ Abbildung 5: Einteilung von  $I$  in Intervalle**Wir nehmen an:**

- i.) Die ZVen  $X_{I_1}, \dots, X_{I_n}$  seien unabhängig und identisch verteilt („independent, identically distributed“, kurz: iid)
- ii.) Die Intervalle  $I_1, \dots, I_n$  seien derart klein (bzw.  $n$  derart groß), dass höchstens ein „Ereignis“ pro Intervall  $I_i$  statt findet.

$X_I = X_{I_1} + \dots + X_{I_n}$  ist dann binomialverteilt und es gilt:  $\mu = E(X_I) = n \cdot E(X_i)$

**Also gilt:**  $p := P_n(X_{I_i} = 1) = \frac{\mu}{n}$  mit  $n$  Anzahl der Intervalle  $I_i$

Was passiert nun für  $n \rightarrow \infty$ ?

$$\begin{aligned} P_n(X_I = k) &= \binom{n}{k} \cdot p^k \cdot q^{n-k} \\ &= \frac{n(n-1) \cdot (n-k+1)}{k!} \cdot p^k \cdot \frac{(1-p)^n}{(1-p)^k} \\ &= \frac{1}{k!} \cdot \frac{n}{n} \cdot \frac{(n-1)}{n} \cdot \dots \cdot \frac{(n-k+1)}{n} \cdot \mu^k \cdot \frac{(1-\frac{\mu}{n})^n}{(1-\frac{\mu}{n})^k} \end{aligned}$$

**Also:**  $\lim_{n \rightarrow \infty} P_n(X_I = k) \rightarrow \frac{\mu^k}{k!} \cdot e^{-\mu}$ , da  $\lim_{n \rightarrow \infty} (1 - \frac{x}{n})^n = e^{-x}$  ist für  $x \in \mathbb{R}$

**Definition:** Eine ZV  $X$  mit Verteilung  $P(X = k) = \frac{\mu^k}{k!} \cdot e^{-\mu}$  für  $k \in \mathbb{N}_0$  heißt Poisson-verteilt mit Parameter  $\mu > 0$ . Die Verteilung von  $X$  wird kurz mit  $P_n(\mu)$  bezeichnet.

**Beachte:**  $\sum_{k=0}^{\infty} \frac{\mu^k}{k!} = e^{\mu}$  für  $\mu \in \mathbb{R}$  „Reihendarstellung der  $e$ -Funktion“.

**Übung:** Bestimmen Sie  $f_X$ ,  $E(X)$  und  $Var(X)$ .

### A.11. Geometrische Verteilung

Wir betrachten das Bernoulli-Experiment mit Erfolgsw.keit  $p > 0$  und Misserfolgsw.keit  $q = 1 - p$ . Die ZV  $X$  zähle die Misserfolge bis zum erstmaligen Erfolg. Die Verteilung von  $X$  ist also

$$P(X = k) = q^k \cdot p \text{ für } k \in \mathbb{N}_0$$

Kann das Experiment unendlich lange dauern?

$$\begin{aligned} P(X = \infty) &= 1 - P(X < \infty) \\ &= 1 - \sum_{k=0}^{\infty} P(X = k) \\ &= 1 - p \underbrace{\sum_{k=0}^{\infty} q^k}_{*} \\ &= 0 \end{aligned}$$

(\*) =  $\frac{1}{1-q} = \frac{1}{p}$  für  $q \in [0, 1)$  („geometrische Reihe“)

**Definition:** Eine ZV  $X$  mit Verteilung  $P(X = k) = p \cdot q^k$  für  $p \in [0, 1]$ ,  $q = 1 - p$ ,  $k \in \mathbb{N}_0$  heißt geometrisch verteilt mit Parameter  $p$ . Die zugehörige Verteilung wird kurz mit  $G(p)$  bezeichnet

### A.12. Zufallsvariablen mit Dichten

**Definition:** Eine Funktion  $f : \mathbb{R} \rightarrow \mathbb{R}$  heißt Dichte (W.keitsdichte, Verteilungsdichte), falls

- $f(x) \geq 0$  für jedes  $x \in \mathbb{R}$
- $f$  ist integrierbar
- $\int_{-\infty}^{\infty} f(x) dx = 1$

Ist nun  $X$  eine ZV, deren Verteilungsfunktion  $F(t) = P(X \leq t)$  für  $t \in \mathbb{R}$  gegeben ist durch

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

dann sagt man  $f$  sei eine Dichte von  $X$  oder  $X$  habe die Dichte  $f$ . Ist  $f$  stetig in  $t \in \mathbb{R}$ , so gilt  $F'(t) = f(t)$  (Hauptsatz der Differential-/Integralrechnung).

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




Abbildung 6: Verteilungsfunktion  $F(t)$

**Bemerkung zur Existenz:** Gegeben sei eine bel. Dichte  $f$ .

Es existiert eine eindeutige kleinste Familie  $\mathcal{B} \subset \mathcal{P}(\mathbb{R})$ , die sogenannte Borel- $\sigma$ -Algebra (unabhängig von  $f$ ), und eine Abbildung  $P : \mathcal{B} \rightarrow [0, 1]$ , so dass

- $\mathcal{B}$  alle Intervalle enthält.
- $(\mathbb{R}, \mathcal{B}, P)$  ein W.raum ist.
- $P((-\infty, t]) = \int_{-\infty}^t f(x)dx$  gilt  $\forall t \in \mathbb{R}$ .

Die Abbildung  $X := id_{\mathbb{R}}$  ist dann eine ZV mit Dichte  $f$ .

Es gilt  $\mathcal{B} \neq \mathcal{P}(\Omega)$ . Würde man statt dessen

$\mathcal{E} := \mathcal{P}(\mathbb{R})$  wählen, so existierte im Allgemeinen keine W.keit  $P$ , so dass obige Bedingungen erfüllt sind.

**Definition:** Sei  $X$  eine ZV mit Dichte  $f$ . Dann heißen

$E(X) := \int_{-\infty}^{\infty} x \cdot f(x)dx$  der Erwartungswert von  $X$  (falls das Integral existiert) und

$Var(X) := \int_{-\infty}^{\infty} (x - E(X))^2 f(x)dx$  die Varianz von  $X$  (falls das Integral existiert).

**Interpretation:**




Abbildung 7:  $f(x)dx \approx \int_{x-\frac{dx}{2}}^{x+\frac{dx}{2}} f(x)dx = P(|X-x| \leq \frac{dx}{2}) \approx P(X \approx x)$

### A.13. Gleichverteilung

**Definition:** Eine ZV  $X$  heißt gleichverteilt auf dem Intervall  $[a, b]$  für  $a \leq b$ , wenn

$$f(x) := \begin{cases} \frac{1}{b-a} & \text{für } x \in [a, b] \\ 0 & \text{sonst} \end{cases}$$

eine Dichte von  $X$  ist. Die Gleichverteilung auf  $[a, b]$  wird kurz mit  $U(a, b)$  bezeichnet. Es gelten

$$\begin{aligned} E(X) &= \int_{-\infty}^{\infty} x \cdot f(x) dx \\ &= \int_a^b \frac{x}{b-a} dx \\ &= \frac{1}{2 \cdot (b-a)} x^2 \Big|_a^b \\ &= \frac{b^2 - a^2}{2 \cdot (b-a)} \\ &= \frac{b+a}{2} \end{aligned}$$

$$\begin{aligned}
\text{Var}(X) &= \frac{1}{b-a} \int_a^b \left(x - \frac{b+a}{2}\right)^2 dx \\
&= \frac{1}{b-a} \int_a^b x^2 dx - 2 \cdot \underbrace{\frac{b+a}{2} \int_a^b x dx}_{\frac{(b+a)^2}{4}} + \frac{(b+a)^2}{4} = \frac{(b+a)^2}{2} \\
&= \frac{1}{b-a} \left(\frac{b^3 - a^3}{3}\right) - \frac{(a+b)^2}{4} \\
&= \frac{(b-a)^2}{12}
\end{aligned}$$

#### A.14. Exponentialverteilung

**Definition:** Eine ZV  $X$  heißt exponentialverteilt mit Parameter  $\alpha > 0$ , wenn

$$f(x) = \begin{cases} 0 & \text{für } x < 0 \\ \alpha \cdot e^{-\alpha x} & \text{für } x \geq 0 \end{cases}$$

eine Dichte von  $X$  ist. Kurz:  $\text{Exp}(\alpha)$ .

$$\text{Es gilt } F(t) = P(X \leq t) = \begin{cases} 0, & t < 0 \\ 1 - e^{-\alpha t}, & t \geq 0 \end{cases}$$

**Interpretation:** Für alle  $x, t \geq 0$  gilt

$$P(X > t + x | X > t) \stackrel{(*)}{=} P(X > x)$$

D.h.  $X$  beschreibt die Zeitdauer, bis zum Eintreten eines „Ereignisses“, wobei die Verteilung dieser Zeitdauer nicht davon abhängt, wann man zu messen beginnt.

**Bemerkung:** Umgekehrt kann gezeigt werden, dass jede ZV (mit stetiger Verteilungsfunktion), welche (\*) erfüllt, exponentiell verteilt ist mit Parameter  $\alpha := -\log P(X > 1)$ ;

#### A.15. Normalverteilung

**Definition:** Eine ZV  $X$  heißt standardnormalverteilt, wenn

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}, \quad x \in \mathbb{R} \text{ eine Dichte von } X \text{ ist.}$$

**Bemerkung:** Es kann gezeigt werden, dass

$$\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx = 1$$

Für  $\mu \in \mathbb{R}$  und  $\sigma > 0$  betrachten wir die ZV  $Y := \mu + \sigma X$ , wobei  $X$  standardnormalverteilt sei.

$$\begin{aligned} P(Y \leq t) &= P\left(X \leq \frac{t - \mu}{\sigma}\right) \\ &= \int_{-\infty}^{\frac{t - \mu}{\sigma}} \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx && \left| \text{Substitution mit } x = \frac{y - \mu}{\sigma} \right. \\ &= \int_{-\infty}^t \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y - \mu)^2}{2\sigma^2}} dy \end{aligned}$$

$$\Rightarrow Y \text{ hat eine Dichte } \varphi_{\mu, \sigma^2}(y) := \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2} \frac{(y - \mu)^2}{\sigma^2}}$$

**Definition:** Eine ZV  $Y$  mit Dichte  $\varphi_{\mu, \sigma^2}$  heißt normalverteilt mit Parameter  $\mu$  und  $\sigma^2$ . Kurzschreibweise  $\mathcal{N}(\mu, \sigma^2)$ .

**Bemerkungen:**

- Die Standardnormalverteilung ist  $\mathcal{N}(0, 1)$
- Ist  $X$  normalverteilt mit Parameter  $\mu$  und  $\sigma^2$ , dann ist die Standardisierte  $X^* := \frac{X - \mu}{\sqrt{\sigma^2}}$  von  $X$  standardnormalverteilt. Es gilt also

$$P(X \leq t) = \Phi\left(\frac{t - \mu}{\sqrt{\sigma^2}}\right) \text{ mit}$$

$$\Phi(t) := \int_{-\infty}^t \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx$$

- Ist  $X$  normalverteilt mit Parametern  $\mu$  und  $\sigma^2$ , so gilt  $E(X) = \mu, \text{Var}(X) = \sigma^2$  (Übung)

**A.16. Tschebyscheffsche Ungleichung**

Sei  $Y$  eine ZV mit Dichte  $f$ , und  $\epsilon > 0$ . Es gilt

$$\begin{aligned} \epsilon^2 P(|Y| \geq \epsilon) &= \epsilon^2 (P(Y < -\epsilon) + P(Y > \epsilon)) \\ &= \int_{-\infty}^{-\epsilon} \epsilon^2 f(x) dx + \int_{\epsilon}^{\infty} \epsilon^2 f(x) dx \\ &\leq \int_{-\infty}^{-\epsilon} x^2 f(x) dx + \int_{\epsilon}^{\infty} x^2 f(x) dx \\ &= \int_{-\infty}^{\infty} x^2 f(x) dx \end{aligned}$$

$$\text{Also: } P(|Y| \geq \epsilon) \leq \frac{\int_{-\infty}^{\infty} y^2 f(y) dy}{\epsilon^2} = \frac{E(Y^2)}{\epsilon^2}$$

(\* vgl. Übung 22)

**Tschebyscheffsche Ungleichung:**

Sei  $X$  eine bel. ZV mit existierendem Erwartungswert und existierender Varianz. Dann gilt

$$P(|X - E(X)| \geq \epsilon) \leq \frac{Var(X)}{\epsilon^2} \quad \forall \epsilon > 0$$

**A.17. Gesetz der großen Zahlen**

Gegeben seien iid ZV  $X_1, X_2, \dots$  mit ex. Erwartungswerten  $\mu = E(X_i)$  und Varianzen  $\sigma^2 = Var(X_i)$ .

Wir setzen  $S_n := X_1 + \dots + X_n$  und

$$\bar{X}_n := \frac{S_n}{n} \text{ arithmetisches Mittel}$$

Es gelten:

$$E(\bar{X}_n) = \frac{n \cdot E(X_i)}{n} = \mu$$

$$Var(\bar{X}_n) = \frac{n \cdot Var(X_i)}{n^2} = \frac{\sigma^2}{n}$$

**Das (schwache) Gesetz der großen Zahlen:**

$$\lim_{n \rightarrow \infty} P(|\bar{X} - \mu| \geq \epsilon) \stackrel{*}{\leq} \lim_{n \rightarrow \infty} \frac{\sigma^2}{n \cdot \epsilon^2} = 0$$

(\*) Tschebyscheff

**Bsp.:** Sei  $Y_1, Y_2, \dots$  die endlichwertigen Ausgänge eines wiederholten Zufallsexperimentes und

$$X_i := \begin{cases} 1 & \text{für } Y_i = y \\ 0 & \text{sonst} \end{cases}$$

Dann ist  $\bar{X}_n$  die gemittelte Anzahl der Ausgänge mit  $y$ .

$$E(\bar{X}_n) = E(X_i) = P(Y_i = y)$$

$$\text{Somit } P(|\bar{X}_n - P(Y_i = y)| \geq \epsilon) \rightarrow 0$$

Das heißt, dass der axiomatische Zugang von Kolmogoroff den „empirischen Zugang beinhaltet“.

**A.18. Zentraler Grenzwertsatz**

Seien  $X_1, X_2, \dots$  unabhängige, identisch verteilte ZVen mit Erwartungswert

$$\mu := E(X_i) \in \mathbb{R} \text{ und Varianz } \sigma^2 = \text{Var}(X_i) \in (0, \infty).$$

Das Gesetz der großen Zahlen besagt dann, dass für jedes  $\epsilon > 0$  gilt:

$$\lim_{n \rightarrow \infty} P(|\bar{X}_n - \mu| > \epsilon) = 0, \text{ wobei } \bar{X} := \frac{X_1 + \dots + X_n}{n} \text{ für } n \in \mathbb{N}.$$

D.h.  $\bar{X}_n$  weicht nur „wenig“ ab vom Erwartungswert  $\mu$ , wenn  $n$  „groß“ ist.

Wie ist  $\bar{X}_n$  um  $\mu$  herum verteilt?

Genauer: wie verhält sich  $P\left(\frac{a \cdot \sigma}{\sqrt{n}} \leq \bar{X}_n - \mu \leq \frac{b \cdot \sigma}{\sqrt{n}}\right) = P\left(a \leq \frac{X_1 + \dots + X_n - n \mu}{\sqrt{n} \sigma} \leq b\right)$ ,  $a \leq b$  für große  $n$ ?

**Satz(Zentraler Grenzwertsatz)**

Unter obigen Bedingungen an  $X_1, X_2, \dots$  und mit

$$S_n := X_1 + \dots + X_n \text{ und } S_n^* := \frac{S_n - n \mu}{\sqrt{n} \sigma^2}$$

( $S_n^*$  ist die Standardisierte von  $S_n$ ), gilt

$$\lim_{n \rightarrow \infty} P(a \leq S_n^* \leq b) = \Phi(b) - \Phi(a) \quad \forall a \leq b \quad (a \in \mathbb{R} \cup \{-\infty\}, b \in \mathbb{R} \cup \{\infty\}),$$

$$\text{wobei } \Phi(t) := \int_{-\infty}^t \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{x^2}{2}} dx \text{ für } t \in \mathbb{R}$$

die Verteilungsfunktion der Standardnormalverteilung ist.

Es kann gezeigt werden, dass die Konvergenz sogar gleichmäßig ist, d.h. es gilt:

$$\lim_{n \rightarrow \infty} \sup_{a \leq b} \left| P(a \leq S_n^* \leq b) - (\Phi(b) - \Phi(a)) \right| = 0$$

**Bsp.:** Binomialverteilung

Betrachten das Bernoulli-Experiment:

$S_n := X_1 + \dots + X_n$ , wobei  $X_1, \dots, X_n$  identisch verteilt, unabhängig und mit

$$P(X_i = 1) = p \text{ und } P(X_i = 0) = q = (1 - p).$$

Dann ist  $S_n$  binomialverteilt mit Parametern  $n$  und  $p$ . Es gilt:

$$E(X_i) = p \text{ und } Var(X_i) = p \cdot q$$

Für  $a, b \in \mathbb{N}$  gilt dann:

$$P(a \leq S_n \leq b) = \sum_{k=a}^b P(S_n = k) = \sum_{k=a}^b \binom{n}{k} p^k \cdot q^{n-k}$$

$$P\left(\frac{a-n p}{\sqrt{n p q}} \leq S_n^* \leq \frac{b-n p}{\sqrt{n p q}}\right) \underset{\approx}{\approx} \Phi\left(\frac{b-n p}{\sqrt{n p q}}\right) - \Phi\left(\frac{a-n p}{\sqrt{n p q}}\right)$$

für große  $n$  (Faustregel  $n p q \geq 9$ ).

Diese Approximation lässt sich verbessern, indem man eine Diskretheitskorrektur einführt:

$$P(a \leq S_n \leq b) \approx \Phi\left(\frac{b+\frac{1}{2}-n p}{\sqrt{n p q}}\right) - \Phi\left(\frac{a-\frac{1}{2}-n p}{\sqrt{n p q}}\right)$$

$$\text{Es gilt z.B. } \underbrace{P(S_{2n} = 2n)}_{=p^{2n}} = P(2n \leq S_n \leq 2n) > 0$$

**Bemerkung:** Für  $t < 0$  gilt  $\Phi(t) = 1 - \Phi(-t)$  (vgl. Aufgabe 17).

Es reicht also, wenn  $\Phi(t)$  für  $t > 0$  tabelliert ist.

### A.19. Mehr zur Unabhängigkeit

**Erinnerung:** Zwei ZV  $X, Y$  heißen unabhängig, wenn

$$P(X \leq x, Y \leq y) = P(X \leq x) \cdot P(Y \leq y) \quad \forall x, y \in \mathbb{R}$$

**Diskrete ZVen:**

Wir nehmen an  $X$  nehme höchstens abzählbar viele (endlich viele oder abzählbar unendlich viele) Werte  $x_i$  mit  $i \in I$  ( $I = \{1, \dots, n\}$  oder  $I = \mathbb{N}$ ) an und  $Y$  nehme höchstens abzählbar viele Werte  $y_j$  mit  $j \in J$  an.

**Satz:**  $X, Y$  sind genau dann unabhängig, wenn

$$P(X = x_i, Y = y_j) = P(X = x_i) \cdot P(Y = y_j) \quad \forall i \in I, j \in J.$$

(vgl. Übung 17 für  $x_i, y_j \in \mathbb{N}$ ).

Betrachten die Matrix  $P = (p_{ij})_{i \in I, j \in J}$  mit  $p_{ij} := P(X = x_i, Y = y_j)$ , sowie die Zeilenvektoren

$$p := (p_i)_{i \in I} \text{ mit } p_i := P(X = x_i) \text{ und}$$

$$q := (q_j)_{j \in J} \text{ mit } q_j := P(Y = y_j)$$

Dann gilt  $X, Y$  sind genau dann unabhängig, wenn

$$P = p^t \cdot q = (p_i \cdot q_j), \quad i \in I, j \in J \text{ (Matrixmultiplikation)}$$

$$\begin{pmatrix} \phantom{p_i} \end{pmatrix} = \begin{pmatrix} \phantom{p_i} \end{pmatrix} \cdot \begin{pmatrix} \phantom{q_j} \end{pmatrix}$$

**Definition:** Für zwei beliebige ZVen  $X, Y$  heißt

$$F : \mathbb{R}^2 \rightarrow [0, 1], \text{ definiert durch}$$

$$F(x, y) := P(X \leq x, Y \leq y) \text{ für } x, y \in \mathbb{R},$$

die gemeinsame Verteilungsfunktion von  $(X, Y)$ .

Kennt man die gemeinsame Verteilungsfunktion von  $(X, Y)$ , so erhält man die Verteilungsfunktion  $F_1$  von  $X$  und die Verteilungsfunktion  $F_2$  von  $Y$  durch

$$\begin{aligned} F_1(x) &:= P(X \leq x) = P(X \leq x, Y \leq \infty) \\ &= F(x, \infty) := \lim_{y \rightarrow \infty} F(x, y) \end{aligned}$$

und analog  $F_2(y) = \lim_{x \rightarrow \infty} F(x, y)$

$F_1$  und  $F_2$  sind die Randverteilungen von  $(X, Y)$ .

**Es gilt:**  $X, Y$  sind genau dann unabhängig, wenn  $F(x, y) = F_1(x) \cdot F_2(y)$  gilt  $\forall x, y \in \mathbb{R}$

### ZVen mit Dichten:

Man sagt, dass zwei ZVen  $X, Y$  eine gemeinsame Dichte  $f : \mathbb{R}^2 \rightarrow [0, \infty)$  besitzen, wenn

$$F(x, y) = P(X \leq x, Y \leq y) = \int_{-\infty}^x \int_{-\infty}^y f(s, t) dt ds \text{ gilt für } x, y \in \mathbb{R}$$

**Es gilt:**

$$\begin{aligned} P(X \leq x) &= P(X \leq x, Y \leq \infty) = \int_{-\infty}^x \int_{-\infty}^{\infty} f(s, t) dt ds \\ &= \int_{-\infty}^x f_1(s) ds \end{aligned}$$

$$\text{mit } f_1(s) := \int_{-\infty}^{\infty} f(s, t) dt$$

Also ist  $f_1$  eine Dichte von  $X$  und analog ist  $f_2(t) := \int_{-\infty}^{\infty} f(s, t) ds$  eine Dichte von  $Y$ .

$f_1, f_2$  sind die Randdichten von  $(X, Y)$ , bzw. von  $f$ .

Wir nehmen nun an, es gelte  $f(s, t) = f_1(s) \cdot f_2(t)$  für alle  $s, t \in \mathbb{R}$ .

Dann gilt:

$$\begin{aligned} F(x, y) &= \int_{-\infty}^x \int_{-\infty}^y f_1(s) f_2(t) dt ds \\ &= \int_{-\infty}^x f_1(s) \underbrace{\left( \int_{-\infty}^y f_2(t) dt \right)}_{=F_2(y)} ds \\ &= F_2(y) \cdot \underbrace{\int_{-\infty}^x f_1(s) ds}_{=F_1(x)} \end{aligned}$$

Man kann zeigen, dass auch die Umkehrung gilt:

**Satz:** Sind  $X$  und  $Y$  ZVen mit Dichten  $f_1$  und  $f_2$ , so sind  $X, Y$  genau dann unabhängig, wenn  $f(x, y) := f_1(x) \cdot f_2(y)$  eine gemeinsame Dichte von  $(X, Y)$  ist.

## A.20. Faltung

Es seien  $X, Y$  zwei unabhängige ZVen.  $Q_1$  sei die Verteilung von  $X$ ,  $Q_2$  sei die Verteilung von  $Y$ .

Mit der Faltung  $Q := Q_1 * Q_2$  von  $X$  und  $Y$  bezeichnet man die Verteilung der ZV  $X + Y$ .

Betrachte zwei Spezialfälle:

**1. Fall:**  $X, Y$  nehmen nur Werte in  $\mathbb{N}_0$  an.

Betrachten  $Q_1(n) := P(X = n), Q_2(n) := P(Y = n)$

Dann gilt:

$$\begin{aligned} Q(n) := P(X + Y = n) &= \sum_{k=0}^n P(X = k, Y = n - k) \\ &= \sum_{k=0}^n P(X = k) \cdot P(Y = n - k) \\ &= \sum_{k=0}^n Q_1(k) \cdot Q_2(n - k) \end{aligned}$$

**2. Fall:**  $X$  besitzt eine Dichte  $f_1$  und  $Y$  besitzt eine Dichte  $f_2$ .

Betrachten  $Q_1(x) := P(X \leq x) = \int_{-\infty}^x f_1(t) dt$

$Q_2(y) := P(Y \leq y) = \int_{-\infty}^y f_2(t) dt$

$Q(z) := P(X + Y \leq z)$

**Heuristisch:**

$$P(X \approx x, Y \leq z - x) = P(X \approx x) \cdot P(Y \leq z - x) \approx f_1(x) dx \cdot \int_{-\infty}^{z-x} f_2(s) ds$$

Durch „Aufsummieren“, bzw. „Aufintegrieren“ erhält man

$$\begin{aligned}
 P(X + Y = Z) &= \int_{-\infty}^{\infty} f_1(x) \cdot \underbrace{\int_{-\infty}^{z-x} f_2(s) \, ds}_{= \int_{-\infty}^z f_2(y-x) \, dy \text{ (*)}} \, dx \\
 &= \int_{-\infty}^z \int_{-\infty}^{\infty} f_1(x) \cdot f_2(y-x) \, dx \, dy
 \end{aligned}$$

(\*) nach Substitution  $s = y - x$

**Also:**  $g(y) = \int_{-\infty}^{\infty} f_1(x) f_2(y-x) \, dx$  ist eine Dichte von  $X + Y$ .

### A.21. Poisson-Punktprozess

Der Poisson-Punktprozess beschreibt ein in der Zeit wiederkehrendes Ereignis (z.B. Telefonanrufe, Teilchenemission beim radioaktiven Zerfall, Meteoriteneinschläge,...)




Abbildung 8: Punkt ereignisse

**Ansatz:** Die Zeitspannen  $\tau_1, \tau_2, \dots$  zwischen den Punkt ereignissen seien unabhängig und identisch exponential verteilt zum Parameter  $\alpha > 0$  (Begründung: siehe Kap. 14).

Setzen nun  $T_0 := 0$  und  $T_n := \tau_1 + \dots + \tau_n$  für  $n \in \mathbb{N}$   
 „Zeitpunkt des  $n$ -ten Punkt ereignisses“.

**Wie ist  $\tau_n$  verteilt?**

**Aufgabe 31 a):**  $f_n(x) := \begin{cases} \frac{\alpha^n \cdot x^{n-1} \cdot e^{-\alpha \cdot x}}{(n-1)!} & , x \geq 0 \\ 0 & , x < 0 \end{cases}$  ist eine Dichte von  $T_n$ .

Die Verteilung von  $T_n$  heißt Gamma-Verteilung, benannt nach der Gamma-Funktion  
 $\Gamma(n) := \int_0^{\infty} x^{n-1} \cdot e^{-x} \, dx = (n-1)!$

**Beweisschema:**

Vollständige Induktion nach  $n \in \mathbb{N}$

**Ind.verankerung**  $n = 1$  :  $T_1 = \tau_1$  ist exp. verteilt mit Parameter  $\alpha$  nach Voraussetzung.

Also ist  $f_1$  eine Dichte von  $T_1$

**Ind.schritt**

$n \rightarrow n + 1$

Ind.annahme:

$f_n$  ist eine Dichte von  $T_n$ .

Zeigen Sie, dass dann auch  $f_{n+1}$  eine Dichte von  $T_{n+1}$  ist.

**Hinweis:**

Aus der Unabhängigkeit der  $\tau_1, \dots, \tau_n + 1$  folgt auch die Unabhängigkeit von  $T_n = \tau_1 + \dots + \tau_n$  und  $\tau_{n+1}$

**Aufgabe 31 b):** Für  $t > 0$  gilt:  $P(T_n > t) = \sum_{k=0}^{n-1} \frac{(\alpha t)^k}{k!} \cdot e^{-\alpha t}$

**Beweisschema:**

Vollständige Induktion nach  $n \in \mathbb{N}$

**Ind.verankerung:**  $n = 1$  Zeigen Sie  $P(T_1 > t) = e^{-\alpha t}$

**Hinweis:**  $P(T_1 > t) = 1 - P(T_1 \leq t) = 1 - \int_{-\infty}^t f_1(x) dx = \int_t^{\infty} f_1(x) dx$

**Ind.Schritt:**  $n \rightarrow n + 1$

Ind. Annahme:  $P(T_n > t) = \sum_{k=0}^{n-1} \frac{(\alpha t)^k}{k!} \cdot e^{-\alpha t}$

Zeigen Sie, dass dann  $P(T_{n+1} > t) = \sum_{k=0}^n \frac{(\alpha t)^k}{k!} \cdot e^{-\alpha t}$

**Hinweis:**  $P(T_{n+1} > t) = \int_t^{\infty} f_{n+1}(x) dx$ , partielle Integration.

Es sei nun  $X_t :=$  „Anzahl der Punktereignisse im Intervall  $I := [0, t]$ “




Abbildung 9: Punktereignisse im Intervall

In Kapitel 10 wurde angenommen, dass eine solche ZV Poisson-verteilt ist. Wie sieht es hier aus?

Offensichtlich gilt:  $X_t = n \Leftrightarrow T_n \leq t$  und  $T_{n+1} > t$

Somit gilt  $P(X_t = n) = P(T_n \leq t < T_{n+1})$

außerdem  $P(t < T_{n+1}) = P(T_n \leq t < T_{n+1}) + \underbrace{P(t < T_n, t < T_{n+1})}_{=P(t < T_n), \text{ da } T_n < T_{n+1}}$

**Also:**

$$\begin{aligned} P(X_t = n) &= P(T_{n+1} > t) - P(T_n > t) \\ &= \sum_{k=0}^n \frac{(\alpha t)^k}{k!} \cdot e^{-\alpha t} - \sum_{k=0}^{n-1} \frac{(\alpha t)^k}{k!} \cdot e^{-\alpha t} \\ &= \frac{(\alpha t)^n}{n!} \cdot e^{-\alpha t} \end{aligned}$$

D.h.  $X_t$  ist Poisson-verteilt mit Parameter  $\alpha \cdot t$  und es gilt:

$$E(X_t) = \text{Var}(X_t) = \alpha \cdot t$$

Insbesondere ist  $\alpha = E(X_1)$  die erwartete Anzahl Punktereignisse pro Zeiteinheit.

## B. Statistik

Die Statistik ist ein Konzept, bei dem man von einer sehr großen Grundgesamtheit ausgeht, die nicht komplett zugänglich ist, und deren Struktur man durch Daten (Stichprobe) aufklären will. Dabei geht man davon aus, dass die Grundgesamtheit groß genug ist, so dass sie von der Stichprobe nicht beeinflusst wird.

Die Statistik baut auf der W.theorie auf. Während die W.keitstheorie ohne Daten auskommt, sind diese gerade ein wesentliches Merkmal der Statistik.

### B.1. Statistisches Modell und Stichproben

Die Grundgesamtheit wird in Form einer ZV beschrieben. In der parametrischen Statistik wird angenommen, dass die Verteilung  $P_\vartheta$  dieser ZV durch einen Parameter  $\vartheta$  einer Parametermenge  $\Theta$  charakterisiert ist. Ein statistisches Modell ist also von der Form  $\{P_\vartheta : \vartheta \in \Theta\}$ .

Nun werden Daten  $\underline{x} := (x_1, \dots, x_n)$  erhoben (Stichprobe vom Umfang  $n \in \mathbb{N}$ ). Man nimmt an, dass  $x_1, \dots, x_n$  Realisierungen von (meistens) ZVen  $X_1, \dots, X_n$  sind, wobei diese auf einem Wahrscheinlichkeitsraum  $(\Omega, \mathcal{F}, P_\vartheta)$  für ein geeignetes  $\vartheta \in \Theta$  definiert sein soll.

Aus der Stichprobe  $\underline{x}$  berechnet man sogenannte Kennzahlen, die charakteristisch sein sollen für die Grundgesamtheit.

Stichprobenmittelwert:

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

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

Diese Kennzahlen sind Realisierungen (d.h. Auswertungen in einem  $\omega \in \Omega$ ) der ZVen

$$\bar{X} := \frac{1}{n} \sum_{i=1}^n X_i, S^2 := \frac{1}{(n-1)} \sum_{i=1}^n (X_i - \bar{X})^2$$

**Beachte:**  $\bar{x}_i, s^2$  sind auf konkreten Daten beruhende Zahlen.  $\bar{X}, S$  sind auf dem statistischen Modell beruhende ZVen.

Offenbar gilt:  $E(\bar{X}) = E(x_i)$   
 $Var(\bar{X}) = \frac{1}{n} Var(x_i)$ , „Mitteln verringert die Varianz“

Wir fassen  $X_1, \dots, X_n$  zu einem Zufallsvektor  $\underline{X} := (X_1, \dots, X_n)$  zusammen, welcher auch Stichprobe vom Umfang  $n \in \mathbb{N}$  genannt wird.

## B.2. Schätzen von Parametern

Gegeben sei ein statistisches Modell  $\mathcal{P} = \{P_\vartheta : \vartheta \in \Theta\}$ , welches die Grundgesamtheit (approximativ) beschreibt. Mit Hilfe von Daten  $x_1, \dots, x_n$  soll der Parameter  $\vartheta$  oder irgend eine andere Kennzahl  $q = q(\vartheta)$  geschätzt werden.

**Definition:** Gegeben sei eine Abbildung  $T : \mathbb{R}^n \rightarrow \mathbb{R}$ .  
 Dann heißt die ZV  $U_n := T(\underline{X}) := T \circ \underline{X}, \Omega \rightarrow \mathbb{R}$  ein Schätzer für  $q$ .

Die Zahl  $T(\underline{x})$  heißt dann Schätzwert für  $q$ .

Was sind „gute“ Schätzer?

**Definition:**

- i.) Schätzer  $U_n$  heißt erwartungstreu für  $q$ , wenn  $E(U_n) = q$  gilt
- ii.) Eine Folge  $(U_n)_{n \in \mathbb{N}}$  von Schätzern heißt konsistent,  
 wenn  $\lim_{n \rightarrow \infty} P(|U_n - q| > \epsilon) = 0$  für jedes  $\epsilon > 0$

**Bsp.:** Münzwurf

$p := P[\text{Kopf}] \in [0, 1]$  unbekannt

Wie schätzt man  $p$ ?

ZV  $X$  mit  $X = \begin{cases} 1 & \text{falls Kopf} \\ 0 & \text{sonst} \end{cases}$

$X$  binomialverteilt mit  $(1, p)$

Statistisches Modell:

$$\mathcal{P} = \{Bin(1, p) : p \in [0, 1]\}$$

Allgemeiner:

$X_1, \dots, X_n =$  Ergebnisse von  $n$  unabhängigen Münzwürfen. (Zufallsvariablen)

Kanonischer Schätzer für  $p$ :

$$T(x_1, \dots, x_n) = \frac{\# \text{ Einsen}}{\# \text{ Würfe}} = \frac{x_1 + \dots + x_n}{n}$$

$$T(0, 1, 1, 1, 0, 1, 0) = \frac{4}{7}$$

$T : \mathbb{R}^n \rightarrow \mathbb{R}$  mit  $\mathbb{R}^n$  Menge der möglichen Daten

$$U_n := T(X_1, \dots, X_n) = \frac{X_1 + \dots + X_n}{n} = \bar{X}$$

$U_n : \Omega \rightarrow \mathbb{R}$  der Schätzer als Zufallsvariable

$U_n$  ist erwartungstreu Schätzer von  $p$ :

$$E[U_n] = E\left[\frac{X_1 + \dots + X_n}{n}\right] = \frac{1}{n} \left( \underbrace{E[X_1]}_{0 \cdot P[X_1=0] + 1 \cdot P[X_1=1]} + \dots + E[X_n] \right) = \frac{n \cdot p}{n} = p$$

$(U_n)_n$  ist konsistenter Schätzer von  $p$ :

$$0, 1, 1, 1, 0, 1, 0, 1, 1, \dots \mid (X_n)_n$$

$0, \frac{1}{2}, \frac{2}{3}, \frac{3}{4}, \frac{3}{5}, \frac{4}{6}, \dots \mid (U_n)_n$  sollte gegen  $p$  konvergieren im Sinne der Konvergenz des schwachen Gesetzes der großen Zahlen.

Schwaches Gesetz der großen Zahlen:  $\forall \epsilon > 0 \ P[|U_n - p| \geq \epsilon] \rightarrow 0$  für  $n \rightarrow \infty$ .

Konvergenzgeschwindigkeit ist approximativ berechenbar:

$$\begin{aligned} P\left[ \left| \frac{X_1 + \dots + X_n}{n} - p \right| \geq \epsilon \right] &= P\left[ \left| (X_1 + \dots + X_n) - \underbrace{np}_{E[X_1 + \dots + X_n]} \right| \geq n \epsilon \right] \\ &= P\left[ \left| \frac{(X_1 + \dots + X_n) - np}{\underbrace{\sqrt{\text{Var}(X_1 + \dots + X_n)}}_{\approx \text{standardnormalverteilt}}} \right| \geq \frac{n \epsilon}{\sqrt{\text{Var}(X_1 + \dots + X_n)}} \right] = P\left[ \left| \frac{X_1 + \dots + X_n - np}{\sqrt{n p(1-p)}} \right| \geq \frac{n \epsilon}{\sqrt{n p(1-p)}} \right] \\ &\stackrel{\text{ZGWS}}{\approx} 2(1 - \Phi(z)) = 2(1 - \Phi\left(\frac{\epsilon \sqrt{n}}{\sqrt{p(1-p)}}\right)) \end{aligned}$$

### B.3. Erwartungstreue Schätzer von Erwartungswert und Varianz

Im letzten Kapitel haben wir gesehen:

Falls  $X_1, \dots, X_n \sim \text{Bin}(1, p)$  unabhängig, so ist  $\bar{X}$  ein erwartungstreuer Schätzer für  $p = E[X_1]$

Nach der gleichen Rechnung ergibt sich:

$\bar{X}$  schätzt  $E[X_1]$  erwartungstreu, egal welche Verteilung  $X_1, \dots, X_n$  wir haben (unter der Annahme, dass alle  $X_i$  die gleiche Verteilung haben).

**Behauptung:**

$S^2 := \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$  schätzt  $\sigma^2 := \text{Var}(X_1)$  erwartungstreu.

**Beweis:**

$$Y_i = X_i - E[X_i]$$

$$E\left[\sum_{i=1}^n (X_i - \bar{X})^2\right] = E\left[\sum_{i=1}^n (Y_i - \bar{Y})^2\right]$$

$$\begin{aligned} E\left[\sum_{i=1}^n Y_i^2 - 2\bar{Y}Y_i + \bar{Y}^2\right] &= \sum_{i=1}^n (E[Y_i^2] - 2E[Y_i] \frac{1}{n} \sum_{j=1}^n Y_j + E[\bar{Y}^2]) \\ &= \sum_{i=1}^n \sigma^2 - \frac{2}{n} (E[Y_i^2] + \sum_{j=1, i \neq j}^n E[Y_i Y_j] + \frac{\sigma^2}{n}) \\ &= \sum_{i=1}^n (\sigma^2 - \frac{2}{n} \sigma^2 + \frac{\sigma^2}{n}) \\ &= \sum_{i=1}^n (1 - \frac{1}{n}) \\ &= \sigma^2 n \left(\frac{n-1}{n}\right) = (n-1)\sigma^2 \end{aligned}$$

Also  $E[S^2] = \sigma^2$

Wie kann man Schätzer konstruieren?

## B.4. Maximum-Likelihood-Methode und Momentmethode

### Maximum-Likelihood-Methode

**Idee:** Wähle ein  $\vartheta \in \Theta$ , für das die Wahrscheinlichkeit, genau das zu beobachten, was tatsächlich beobachtet wurde, maximal ist.

**1. Fall:** Alle  $P_\vartheta, \vartheta \in \Theta$  diskret. Wähle ein  $\vartheta$ , mit  $L(\vartheta) := P_\vartheta(x_1) \cdot P_\vartheta(x_2) \dots P_\vartheta(x_n)$  maximal.  $L$  heißt Likelihood-Funktion.

**Bsp.:** Münzwurf

$x_1, \dots, x_n \in \{0, 1\}$  beobachtet, (z.B. 0, 1, 1, 1, 0, 1, 0, 0)

Parameter  $\underbrace{p}_{=\vartheta} \in \underbrace{[0, 1]}_{=\Theta}$  unbekannt.

$L(p) = p^x(1-p)^{n-x}$  mit  $x = \# 1$  in  $(x_1, \dots, x_n) = x_1 + \dots + x_n$

(Hier  $L(\vartheta) = p^4(1-p)^5$ ). Maximiere  $L$ .

**Trick:** Oft einfacher statt  $L$ ,  $\log L$  zu maximieren. (beachte  $\log$  streng monoton)  $\mathcal{L}$  heißt Log-Likelihood-Funktion.

$$\mathcal{L}(p) = \log L(p) = x \log p + (n-x) \log(1-p)$$

$$\mathcal{L}'(p) = \frac{x}{p} - \frac{n-x}{1-p} \stackrel{!}{=} 0 \text{ „soll Null sein“}$$

$$\frac{x}{p} \stackrel{!}{=} \frac{n-x}{1-p}, (1-p)x \stackrel{!}{=} (n-x)p, p = \frac{x}{n} = \bar{x}$$

( $\bar{x} = \frac{4}{9}$  = ML-Schätzer für  $p$ ).

Der ML-Schätzer  $\hat{p}$  für  $p$  ist  $\bar{X}$

**2. Fall** Alle  $P_\vartheta$  haben eine Dichte  $f_\vartheta : \mathbb{R} \rightarrow [0, \infty)$

**Bsp.:**  $x_1 = 1.3, x_2 = 2.4, x_3 = 0.9$  mit  $X_1, X_2, X_3 \sim Exp(\alpha)$  Lebensdauer

In diesem Fall maximiere  $L(\vartheta) := f_\vartheta(x_1) \cdot \dots \cdot f_\vartheta(x_n)$

Statistisches Modell:  $\mathcal{P} = \{Exp(\alpha) : \alpha > 0\}$

$$\begin{aligned} L(\alpha) &= \alpha \cdot e^{-\alpha x_1} \cdot \dots \cdot \alpha e^{-\alpha x_n} \\ &= \alpha^n \cdot e^{-\alpha x} \text{ mit } x = x_1 + \dots + x_n \end{aligned}$$

$$\mathcal{L}(\alpha) = \log L(\alpha) = n \log \alpha - \alpha x$$

$$\mathcal{L}'(\alpha) = \frac{n}{\alpha} - x \stackrel{!}{=} 0$$

$$\alpha \stackrel{!}{=} \frac{n}{x} = \frac{1}{\bar{x}}, \hat{\alpha} = \frac{1}{\bar{x}} \text{ ist ML-Schätzer für } \alpha.$$

$$\hat{\alpha} = \frac{3}{4,6}$$

### Momentmethode

Wähle ein  $\vartheta \in \Theta$  aus, für das der „empirische Mittelwert  $\bar{X}$ “ gleich dem theoretischen Mittelwert, d.h. dem Erwartungswert  $E[X_1]$  ist.

**Bsp.:**  $X_1, \dots, X_n \sim \text{Exp}(\alpha)$  unabh. wie oben, so soll  $\bar{X} \stackrel{!}{=} E[X_1] = \frac{1}{\alpha}$   
Also  $\alpha = \frac{1}{\bar{X}}$

$\hat{\alpha} = \frac{1}{\bar{x}}$  im Beispiel  $\hat{\alpha} = \frac{3}{4,6}$ , d.h. ML-Methode und Momentmethode liefern hier den selben Schätzer.

### Rückblick:

Gegeben seien iid ZVen  $X_1, \dots, X_n \Omega \rightarrow \mathbb{R}$  mit Verteilung  $P_\vartheta, \vartheta \in \Theta$ .

Betrachten Stichprobe  $(x_1, \dots, x_n) = (X_1(\omega), \dots, X_n(\omega)), \omega \in \Omega$ , vom Umfang  $n$ .

Likelihood-Funktion  $L : \Theta \rightarrow [0, \infty)$

- i.)  $L(\vartheta) = P_\vartheta(x_1) \cdot \dots \cdot P_\vartheta(x_n)$  im diskreten Fall
- ii.)  $L(\vartheta) = f_\vartheta(x_1) \cdot \dots \cdot f_\vartheta(x_n)$  falls  $f_\vartheta$  eine Dichte der  $X_i$  ist.

Dann ist  $\hat{\vartheta}$  so gewählt, dass

$L(\hat{\vartheta}) = \max_{\vartheta \in \Theta} L(\vartheta)$  gilt, der Maximum-Likelihood-Schätzer für  $\vartheta$ .

**Beachte:**  $\hat{\vartheta}$  hängt von der Stichprobe  $(x_1, \dots, x_n)$  respektive von  $\omega \in \Omega$  ab, ist also eine ZV.

### Schätzer der Momentenmethode:

$\hat{\vartheta}$  sei so gewählt, dass  $\bar{x} = \bar{x}(\omega) == E_{\vartheta}(X_1)$  gilt.

Bei der Exponentialverteilung (vgl. oben) und der geometrischen Verteilung (vgl. Übung) stimmen die beiden Schätzer überein. Dies gilt im Allgemeinen jedoch nicht.

**Bsp.:** Betrachten ZV  $X_1$  mit Dichte  $f_\vartheta(x) = \begin{cases} 0 & , x < 0 \\ \vartheta x e^{-\frac{\vartheta}{2} x^2} & , x \geq 0 \end{cases}$  für  $\vartheta > 0$ .

- $f_\vartheta$  ist eine Dichte:

$$\int_0^{\infty} \vartheta x e^{-\frac{\vartheta}{2} x^2} dx = \left[ -e^{-\frac{\vartheta}{2} x^2} \right]_0^{\infty} = -0 + 1 = 1$$

- Erwartungswert:

$$E_\vartheta[X_1] = \int_0^{\infty} \vartheta x^2 e^{-\frac{\vartheta}{2} x^2} dx = \frac{1}{2} \int_{-\infty}^{\infty} \vartheta x^2 e^{-\frac{\vartheta}{2} x^2} dx$$

$$\text{mit } \sigma := \frac{1}{\sqrt{\vartheta}}$$

$$E_\vartheta[X_1] = \frac{\sqrt{2\pi\sigma^2}}{\sigma^2 \cdot 2} \underbrace{\int_{-\infty}^{\infty} x^2 \frac{e^{-\frac{x^2}{2\sigma^2}}}{\sqrt{2\pi\sigma^2}} dx}_{= \text{Var}(Y) = \sigma^2 \text{ für } Y \stackrel{d}{=} \mathcal{N}(0, \sigma^2)}$$

- Momenten-Methode:  $\bar{X} \stackrel{!}{=} E_{\hat{\vartheta}}[X_1] = \sqrt{\frac{\pi}{2\hat{\vartheta}}}$

$$\text{Also: } \hat{\vartheta} = \frac{\pi}{2\bar{X}^2} \stackrel{n=1}{=} \frac{\pi}{2X_1^2}$$

ML-Schätzer für  $n = 1$ :

Log-Likelihood-Funktion  $\log L(\vartheta) = \log f_\vartheta$

$$\log L(\hat{\vartheta})' = (\log \hat{\vartheta} + \log X_1 - \frac{\hat{\vartheta}}{2} X_1^2)' = \frac{1}{\hat{\vartheta}} - \frac{X_1^2}{2} \stackrel{!}{=} 0$$

$$\text{Also: } \hat{\vartheta} = \frac{2}{X_1^2} \neq \frac{n}{2x_1^2}$$

## B.5. Konfidenzintervalle normalverteilter ZVen

Seien  $\underline{X} = (X_1, \dots, X_n)$  eine Stichprobe zum statistischen Modell  $\mathcal{P} = \{P_\vartheta, \vartheta \in \Theta\}$

Oft will man  $\vartheta$  gar nicht konkret schätzen, sondern ein Intervall angeben, in welchem  $\vartheta$  mit hoher W.keit liegt.

**Definition:** Gegeben sei eine Konfidenzzahl (Vertrauenszahl)  $\gamma \in (0, 1)$ .

Ein Intervall  $[U_n, O_n]$  heißt  $\gamma$ -Konfidenzintervall für  $\vartheta$ , wenn  $U_n, O_n$  zwei Schätzer sind, so dass  $P_\vartheta(U_n \leq \vartheta \leq O_n) \geq \gamma$  gilt  $\forall \vartheta \in \Theta$ .

(Wenn die Verteilung  $P_\vartheta$  die „richtige“ ist, dann liegt  $\vartheta$  mit „hoher“ W.keit im Intervall  $[U_n, O_n]$ ).

Für den Rest des Kapitels sollen die  $X_i$  normalverteilt sein.

Wir betrachten zunächst den Fall, in dem die Varianz  $\sigma^2 > 0$  vorgegeben ist. (Bsp.weise bei Produktionsprozessen mit variabler Einstellung und bekannter und konstanter Toleranz).

Das statistische Modell ist also  $\mathcal{P} = \{\mathcal{N}(\mu, \sigma^2) : \mu \in \mathbb{R}\}$

Zu gegebenem  $\gamma$  bestimmt man das  $\frac{1+\gamma}{2}$ -Quantil, d.h. die Zahl  $z$  für die gilt:

$$\Phi(z) = \frac{1+\gamma}{2}, \text{ wobei } \Phi(z) := \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}} dx$$

Man setzt  $U_n := \bar{X} - z \frac{\sigma}{\sqrt{n}}, O_n := \bar{X} + z \frac{\sigma}{\sqrt{n}}$ .

Dann gilt:  $P_\mu(U_n \leq \mu \leq O_n) = P_\mu(|\bar{X} - \mu| \leq z \frac{\sigma}{\sqrt{n}}) = P_\mu\left(\underbrace{\sqrt{n} \frac{|\bar{X} - \mu|}{\sigma}}_{\text{Standardisierte von } \bar{X}} \leq z\right) =$

$$\Phi(z) - \Phi(-z) = 2\Phi(z) - 1 = \gamma$$

**Also:**  $[U_n, O_n]$  ist ein  $\gamma$ -Konfidenz-intervall für den Erwartungswert  $\mu$ .

Betrachten nun den Fall, bei dem  $\sigma^2$  nicht bekannt ist.

**Definition:** Seien  $Y_1, \dots, Y_n$  unabhängige,  $\mathcal{N}(0, 1)$ -verteilte ZVen. Dann heißt die Verteilung von  $Y := Y_1^2 + \dots + Y_n^2$  die Chi-Quadrat-Verteilung mit  $n$  Freiheitsgraden. (Notation:  $\chi_n^2$ )

Durch vollständige Induktion nach  $n$  kann gezeigt werden, dass  $Y$  eine Dichte  $g_n$  besitzt, gegeben durch

$$g_n(x) := \begin{cases} \frac{x^{\frac{n}{2}-1} e^{-\frac{x}{2}}}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} & , x \geq 0 \\ 0 & , x < 0 \end{cases},$$

wobei  $\Gamma(\frac{n}{2}) = \int_0^\infty x^{\frac{n}{2}-1} e^{-x} dx$  die Gamma-Funktion ist.

Für  $m := \frac{n}{2}, \alpha := \frac{1}{2}$  gilt:

$$g_n(x) = \frac{\alpha^m x^{m-1} e^{-\alpha x}}{\Gamma(m)}, x \geq 0$$

$g_n$  ist also die Dichte einer „erweiterten“ Gamma-Verteilung (vgl. Kap. 21).

**Definition:** Seien  $Y \stackrel{d}{=} \chi_n^2$  und  $z \stackrel{d}{=} \mathcal{N}(0, 1)$  unabhängig. Dann heißt die Verteilung von

$T := \sqrt{n} \frac{z}{\sqrt{Y}}$  die Students-t-Verteilung mit  $n$  Freiheitsgraden (Notation:  $t_n$ ).

Man kann zeigen, dass  $f_n(x) := \frac{\Gamma(\frac{n+1}{2})}{\sqrt{n\pi}\Gamma(\frac{n}{2})} (1 + \frac{x^2}{n})^{-\frac{n+1}{2}}, x \in \mathbb{R}$ , eine Dichte von  $T$  ist.

**Beachte:** Da  $f_n(-x) = f_n(x)$  ist für alle  $x \in \mathbb{R}$  gilt auch

$$P(|T| \leq t) \leq F_n(t) - F_n(-t) = 2F_n(t) - 1, t \geq 0,$$

$$\text{wobei } F_n(t) = \int_{-\infty}^t f_n(x) dx$$

Wir erzeugen die Varianz  $\sigma^2$  nun durch ihren erwartungstreuen Schätzer

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

$$\text{und setzen nun } U_n := \bar{X} - t \frac{S}{\sqrt{n}}, O_n := \bar{X} + t \frac{S}{\sqrt{n}},$$

wobei  $t$  das  $\frac{1+\gamma}{2}$ -Quantil mit  $n-1$  Freiheitsgraden der  $t$ -Verteilung sein soll. Es muss also gelten  $F_n(t) = \frac{1+\gamma}{2}$  wobei  $F_{n-1}$  die Verteilungsfunktion der  $t$ -Verteilung mit  $n-1$  Freiheitsgraden ist.

Es gilt Folgendes:

Die Standardisierte  $Z := \frac{\bar{X} - \mu}{\sigma} \sqrt{n}$  von  $\bar{X}$  ist  $\mathcal{N}(0, 1)$ .

Man kann zeigen, dass

$$Y := \frac{n-1}{\sigma^2} s^2$$

$\chi_{n-1}^2$ -verteilt und unabhängig ist von  $Z$ .

**Also:**  $T := \sqrt{n-1} \frac{z}{\sqrt{y}} = \frac{\sqrt{n}}{s} (\bar{X} - \mu)$  ist  $t$ -verteilt mit  $n-1$  Freiheitsgraden (nach Definition). Es gilt dann:

$$P(U_n \leq \mu \leq O_n) = P(|\bar{X} - \mu| \leq t \frac{S}{\sqrt{n}}) = P(|T| \leq t) = F_{n-1}(t) - F_{n-1}(-t) = \gamma$$

**Also:**  $[U_n, O_n]$  ist ein  $\gamma$ -Konfidenzintervall für den Mittelwert  $\mu$ .

## B.6. Testen von Hypothesen, Binomialtest

Durch  $n$ -maliges Werfen einer Münze soll getestet werden, ob die Münze fair ist (d.h. ob  $P(\text{Kopf}) = P(\text{Zahl})$ ).

$$\begin{array}{ll} \text{Nullhypothese} & H_0 : P \stackrel{d}{=} B(1, \frac{1}{2}) \\ \text{Alternativhypothese} & H_A : P \in \{B(1, p) : p \neq \frac{1}{2}\} \end{array}$$

### Allgemeiner Ansatz:

Gegeben sei ein statistisches Modell  $\mathcal{P} = \{P_\vartheta : \vartheta \in \Theta\}$

Weiter sei  $\Theta$  aufgeteilt in  $\Theta_{H_0} \subset \Theta$  und  $\Theta_{H_A} := \Theta \setminus \Theta_{H_0}$   
 $\Theta_{H_0} = \Theta_{H_0}^c \subset \Theta$

$$\begin{array}{ll} \text{Nullhypothese} & H_0 : P \in \{P_\vartheta : \vartheta \in \Theta_{H_0}\} \\ \text{Alternativhypothese} & H_A : P \in \{P_\vartheta : \vartheta \in \Theta_{H_A}\} \end{array}$$

Wie soll entschieden werden, ob die Nullhypothese verworfen werden kann/darf?

Es sei  $X_i = 1$  bei „Kopf“ und  $X_i = 0$  bei „Zahl“ des  $i$ -ten Wurfes für  $i = 1, \dots, n$ .

Weiter sei  $T(\underline{x}) := \sum_{i=1}^n x_i$  für  $\underline{x} = (x_1, \dots, x_n) \in \{0, 1\}^n$

Dann ist  $T(\underline{X}) = T_0(X_1, \dots, X_n)$  die Anzahl der „Kopf-Würfe“.




Abbildung 10: Es gilt  $T(\underline{X}) \stackrel{d}{=} B(n, p)$  mit  $p = P(x_i = 1)$

$$E(T(\underline{X})) = \frac{n}{2} \text{ für } p = \frac{1}{2}$$

Wählen  $c \leq \frac{n}{2}$  und sagen die Münze sei gezinkt, wenn  $T(\underline{x}) \leq c$  oder  $T(\underline{x}) \geq n - c$

**Definition:**

Ein Test der Nullhypothese  $H_0$  mit Verwerfungsbereich  $V \subset \mathbb{R}$  ist eine Abbildung  $T: \mathbb{R}^n \rightarrow \mathbb{R}$  mit folgender Interpretation:

- $H_0$  wird verworfen für  $T(\underline{x}) \in V$
- $H_0$  wird nicht verworfen für  $T(\underline{x}) \in V$

Beim Münzwurf ist  $V = [0, c] \cup [n - c, n]$ , wobei  $c > 0$  noch genauer bestimmt werden soll.

**Fehler 1. Art:**

$H_0$  liegt vor, wird aber verworfen

(Die Münze wird als gezinkt betrachtet, obwohl sie fair ist).

**Fehler 2. Art:**

$H_0$  liegt nicht vor, wird aber auch nicht verworfen

(Die Münze ist gezinkt, man kann es aber nicht „beweisen“).

Das Ziel ist meistens einen Test zu finden, für den die W.keit für den Fehler 1. Art ein vorgegebenes Signifikanzniveau  $\alpha$  nicht überschreitet, die W.keit für einen Fehler 2. Art aber möglichst gering hält. Dabei wird  $\alpha > 0$  klein gewählt („Im Zweifelsfalle für den Angeklagten“).

**Definition:**

Die Abbildung  $\Pi_T: \Theta \rightarrow [0, 1]$ , definiert durch  $\Pi_T(\vartheta) := P_\vartheta(T(\underline{X}) \in V)$ , heißt Gütefunktion des Test  $T$  mit Verwerfungsbereich  $V$ .

Die Zahl  $\sup_{\vartheta \in \Theta_{H_0}} \Pi_T(\vartheta)$  heißt Niveau des Tests.


Das Niveau eines Tests soll also ein vorgegebenes Signifikanzniveau  $\alpha$  nicht überschreiten.

Beim Münzwurf: Wie ist  $c$  zu wählen?

$$\begin{aligned} \Pi_T(p) &= P_p\left(\sum_{i=0}^n x_i \leq c \text{ oder } \sum_{i=1}^n x_i \geq n - c\right) \\ &= \sum_{i=0}^c \binom{n}{i} p^i (1-p)^{n-i} + \sum_{i=n-c}^n \binom{n}{i} p^i (1-p)^{n-i} \end{aligned}$$

$$\text{Niveau } \Pi_T\left(\frac{1}{2}\right) = \frac{1}{2^{n-1}} \sum_{i=0}^c \binom{n}{i}$$

Es ist also (durch ausprobieren)  $c$  möglichst groß zu wählen, so dass aber noch gilt  $\Pi\left(\frac{1}{2}\right) \leq \alpha$ .



Umgekehrt existiert für eine Stichprobe  $\underline{x}$  ein kleinstes Signifikanzniveau  $\hat{\alpha}(\underline{x})$  für welches die Nullhypothese gerade noch abgelehnt werden darf.

Beim Münzwurfbsp.:  $\hat{\alpha}(\underline{x}) = \frac{1}{2^{k-1}} \sum_{i=0}^{\min(k, n-k)} \binom{n}{i}$

$$k := x_1 + \dots + x_n = T(\underline{x})$$

$H_0$  wird genau dann verworfen, wenn  $\hat{\alpha}(x) \leq \alpha$  gilt.

$\hat{\alpha}(\underline{x})$  heißt p-Wert von  $\underline{x}$ , und gibt an, wie groß die W.keit eines Fehlers 1. Art ist, wenn  $H_0$  auf Grund von  $\underline{x}$  verworfen wird.

### Zweiseitiger Binomialtest

Statistisches Modell  $\mathcal{P} = \{B(1, p) : p \in [0, 1]\}$

$H_0 : P \stackrel{d}{=} B(1, p_0), p_0 \in [0, 1]$  fest

$H_A : P \in \{B(1, p) : p \neq p_0\}$

Verwerfungsbereich  $V := [0, c_1] \cup [n - c_2, n]$


Also, verwerfe  $H_0$ , wenn  $T(\underline{x}) \leq c_1$  oder  $T(\underline{x}) \geq n - c_2$

$$\begin{aligned} \Pi_T(p) &= P_p\left(\sum_{i=0}^n x_i \leq c_1 \text{ oder } \sum_{i=1}^n x_i \geq n - c_2\right) \\ &= \sum_{i=0}^{c_1} \binom{n}{i} p^i (1-p)^{n-i} + \sum_{i=n-c_2}^n \binom{n}{i} p^i (1-p)^{n-i} \end{aligned}$$

Setze  $c_1, c_2$  möglichst groß an, so dass aber noch gilt

$$\sum_{i=0}^{c_1} \binom{n}{i} p_0^i (1-p_0)^{n-i} \leq \frac{\alpha}{2}$$

$$\sum_{i=n-c_2}^n \binom{n}{i} p_0^i (1-p_0)^{n-i} \leq \frac{\alpha}{2}$$



### Einseitiger Binomialtest:

Statistisches Modell  $\mathcal{P} = \{B(1, p) : p \geq p_0\}$ ,  $p_0$  fest

$$H_0 : P \stackrel{d}{=} B(1, p_0)$$

$$H_A : P \in \{B(1, p) : p > p_0\}$$

Verwerfungsbereich  $V = [n - c, n]$ , wobei  $c$  möglichst groß zu wählen ist, aber so dass noch gilt  $P_{p_0}(T(\underline{X}) \geq n - c) \leq \alpha$

$$\text{Gütefunktion } \Pi_T(p) = \sum_{i=n-c}^n \binom{n}{i} p^i (1-p)^{n-i}$$

Niveau des Test  $\Pi_T(p_0)$

Näherung für Signifikanzniveau  $\alpha = 5\%$  und große  $n$  (Faustregel  $n p_0 q_0 > 9$ ,  $q_0 := 1 - p_0$ ):

Dann ist der Verwerfungsbereich  $V$  ungefähr gegeben durch

$$V^c = [n p_0 - 2\sqrt{n p_0 q_0}, n p_0 + \sqrt{n p_0 q_0}]$$

beim zweiseitigen Test mit  $H_0 : p = p_0$ .

### Warum?

Setzen  $Z := \frac{T - n p_0}{\sqrt{n p_0 q_0}} \approx \mathcal{N}(0, 1)$  nach zentralem Grenzwertsatz.

Also gilt:

$$P_{p_0}(n p_0 - 1,96\sqrt{n p_0 q_0} \leq T(\underline{X}) \leq n p_0 + 1,96\sqrt{n p_0 q_0})$$

$$= P_{p_0}(-1,96 \leq Z \leq 1,96) \approx 0,95 \text{ (mit Hilfe der Tabelle)}$$

Außerdem:  $1,96 \approx 2$

Analog für den einseitigen Binomialtest:

$$H_0 : p = p_0$$

$$H_A : p > p_0$$

$$V \approx [n p_0 + 1, 64\sqrt{n p_0 q_0}, n]$$

## B.7. Weitere Tests

### B.7.1. z-Test:

Statistisches Modell  $\mathcal{P} := \{\mathcal{N}(\mu, \sigma^2) : \mu \in \mathbb{R}, \sigma^2 > 0\}$

**zweiseitig:**  $H_0 : \mu = \mu_0$

$$H_A : \mu \neq \mu_0$$

Test  $T(\underline{x}) := \bar{x}$  arithmetisches Mittel

Verwerfungsbereich  $V := (-\infty, \mu_0 - c] \cup [\mu_0 + c, \infty)$

Dabei ist  $c > 0$  möglichst klein zu wählen, aber so dass noch gilt:

$$P_{\mu_0}(\bar{X} \in V) \leq \alpha$$

**Also:**

$$P_{\mu_0}(\bar{X} \in V)$$

$$= P_{\mu_0}(\bar{X} \leq \mu_0 - c) + P_{\mu_0}(\bar{X} \geq \mu_0 + c)$$

$$= P_{\mu_0}\left(\frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \leq \frac{-c}{\sigma} \sqrt{n}\right) + P_{\mu_0}\left(\frac{\bar{X} - \mu_0}{\sigma} \sqrt{n} \geq \frac{c\sqrt{n}}{\sigma}\right)$$

$$= \Phi\left(\frac{-c}{\sigma} \sqrt{n}\right) + 1 - \Phi\left(\frac{c}{\sigma} \sqrt{n}\right)$$

$$= 2 - 2\Phi\left(\frac{c}{\sigma} \sqrt{n}\right) \stackrel{!}{=} \alpha$$

**Somit:**  $c = z_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}}$

wobei  $z_{1-\frac{\alpha}{2}}$  das  $(1 - \frac{\alpha}{2})$ -quantil von  $\mathcal{N}(0, 1)$  sein soll (also  $\Phi(z_{1-\frac{\alpha}{2}}) = 1 - \frac{\alpha}{2}$ )

### Vergleich Konfidenzintervalle

Wir haben gesehen

$$P_{\mu_0}[\bar{X} - z\frac{\sigma}{\sqrt{n}} \leq \mu_0 \leq \bar{X} + z\frac{\sigma}{\sqrt{n}}] = \gamma$$

für  $z = z_{\frac{1+\gamma}{2}}$ , also  $\Phi(z) = \frac{1+\gamma}{2}$

Dies stimmt für  $\gamma := 1 - \alpha$  und  $c := z\frac{\sigma}{\sqrt{n}}$  mit obigem Resultat überein (nachprüfen).

**einseitig:**  $H_0 : \mu = \mu_0$

$H_A : \mu > \mu_0$

Verwerfungsbereich für  $T$  ist  $V = [\mu_0 + c, \infty)$  mit  $c = z_{1-\alpha}\frac{\sigma}{\sqrt{n}}$ ,  
 $z_{1-\alpha}(1 - \alpha)$ -quantil von  $\mathcal{N}(0, 1)$

**Nachtrag:**

$X_1, \dots, X_n \stackrel{d}{=} \mathcal{N}(\mu, \sigma^2)$  unabhängig,  $\mu = E(X)$

$\bar{X} = \frac{X_1 + \dots + X_n}{n}$  arithmetisches Mittel

Dann gilt: Standardisierte  $\frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \stackrel{d}{=} \mathcal{N}(0, 1)$

**Satz:** Seien  $X_1 \stackrel{d}{=} \mathcal{N}(\mu_1, \sigma_1^2), \dots, X_n \stackrel{d}{=} \mathcal{N}(\mu_n, \sigma_n^2)$  unabhängig. Dann gilt

$X_1 + \dots + X_n \stackrel{d}{=} \mathcal{N}(\mu_1 + \dots + \mu_n, \sigma_1^2 + \dots + \sigma_n^2)$

**Beweis:** Vollständige Induktion nach  $n \in \mathbb{N}$

**Ind. Verankerung**  $n = 1$  :  $\checkmark$

**Ind. schritt**  $n \rightarrow n + 1$  :

Ind.annahme: Es gelte  $X_1 + \dots + X_n \stackrel{d}{=} \mathcal{N}(\mu, \sigma^2)$ , wobei  
 $\mu := \mu_1 + \dots + \mu_n, \sigma^2 := \sigma_1^2 + \dots + \sigma_n^2$

$X_1 + \dots + X_n$  hat also eine Dichte  $\varphi_{\mu, \sigma^2}$ , und  $X_{n+1}$  hat eine Dichte  $\varphi_{\mu_{n+1}, \sigma_{n+1}^2}$ , wobei

$$\varphi_{EW, Var}(x) = \frac{1}{\sqrt{2\pi Var}} e^{-\frac{(x-EW)^2}{2 Var}}$$

Außerdem sind  $X_1 + \dots + X_n$  und  $X_{n+1}$  unabhängig (anschaulich klar).

Faltungsformel für unabhängige ZVen mit Dichte:  $(X_1 + \dots + X_n) + X_{n+1}$  hat eine Dichte

$$g(y) = \int_{-\infty}^{\infty} \varphi_{\mu, \sigma^2}(x) \varphi_{\mu_{n+1}, \sigma_{n+1}^2}(y - x) dx, y \in \mathbb{R}$$

Es gilt  $\varphi_{\mu, \sigma^2}(x) \varphi_{\mu_{n+1}, \sigma_{n+1}^2}(y-x) = \underbrace{\varphi_{\mu+\mu_{n+1}, \sigma^2+\sigma_{n+1}^2}(y)}_{\text{gesuchter Faktor}} \cdot \underbrace{\varphi_{\tilde{\mu}, \tilde{\sigma}^2}(x)}_{\text{ergibt sich}},$

wobei  $\tilde{\mu} = \frac{\mu\sigma_{n+1}^2 + (\mu_{n+1}-y)\sigma^2}{\sigma^2 + \sigma_{n+1}^2}$

$\tilde{\sigma} = \frac{\sigma^2 \cdot \sigma_{n+1}^2}{\sigma^2 + \sigma_{n+1}^2}$

Somit  $g(y) = \varphi_{\mu+\mu_{n+1}, \sigma^2+\sigma_{n+1}^2}(y) \cdot \underbrace{\int_{-\infty}^{\infty} \varphi_{\tilde{\mu}, \tilde{\sigma}^2}(x) dx}_{=1}$

Also:  $X_1 + \dots + X_{n+1}$  ist  $\mathcal{N}(\mu + \mu_{n+1}, \sigma^2 + \sigma_{n+1}^2)$   
 $= \mu_1 + \dots + \mu_{n+1}, \sigma_1^2 + \dots + \sigma_{n+1}^2 \square$

### B.7.2. t-Test

Beim t-Test wird im Gegensatz zum z-Test nicht angenommen, dass die Varianz  $\sigma^2$  bekannt ist.

**zweiseitig:** statistisches Modell  $P = \{\mathcal{N}(\mu, \sigma^2) : \mu \in \mathbb{R}, \sigma^2 > 0\}$

$H_0 : P \in \{\mathcal{N}(\mu_0, \sigma^2) : \sigma^2 > 0\}, \mu_0 \in \mathbb{R}$  fest

$H_A : P \in \{\mathcal{N}(\mu, \sigma^2) : \mu \neq \mu_0, \sigma^2 > 0\}$

Verwerfungsbereich für  $\bar{X} : V := (-\infty, \mu_0 - c] \cup [\mu_0 + c, \infty)$

Wie ist  $c$  zu wählen für ein vorgegebenes Signifikanzniveau  $\alpha$ ?

Test  $T(\underline{X}) := \sqrt{n} \frac{\bar{X} - \mu_0}{\sqrt{S^2}}$

$S^2 = \frac{1}{n-1} ((X_1 - \bar{X})^2 + \dots + (X_n - \bar{X})^2)$

Betrachten  $T(\underline{X}) = \frac{(\bar{X} - \mu_0)}{\sqrt{\frac{\sigma^2}{n}}} \sqrt{n-1} \frac{1}{\sqrt{Y}}$  mit

$Y = \frac{n-1}{\sigma^2} S^2, \sigma^2$  die „echte“ Varianz

**Satz:** Unter  $H_0$  gilt:  $Z \stackrel{d}{=} \mathcal{N}(0, 1), Y \stackrel{d}{=} X_{n-1}^2$ ,  $Z$  und  $Y$  sind unabhängig, d.h.  $T$  ist t-verteilt mit  $n-1$  Freiheitsgraden.

$$\begin{aligned}
\text{Durch } P_{\mu_0}(\bar{X} \in V) &= P_{\mu_0}(|T(\underline{X})| \leq c \frac{n}{S}) \\
&= 2 - 2P_{\mu_0}(T(\underline{X}) \geq c \frac{\sqrt{n}}{S}) \\
&\stackrel{!}{=} \alpha
\end{aligned}$$

erhalten wir  $c := \frac{S}{\sqrt{n}} t_{n-1, 1-\frac{\alpha}{2}}$

$t_{n-1, 1-\frac{\alpha}{2}}$  ist das  $(1 - \frac{\alpha}{2})$ -quantil der t-Verteilung mit  $n - 1$  Freiheitsgraden.

**Aufgabe:** Überprüfen Sie, dass dies äquivalent ist zu den Resultaten beim Konfidenzintervall.

### B.7.3. Chi-Quadrat-Anpassungstest

Der Ausgang eines Zufallsexperiments sei aufgeteilt in  $k$  Klassen.

$H_0$ : Die  $k$  Klassen treffen mit W.keiten  $p_1, \dots, p_k$  ein (wobei  $p_1 + \dots + p_k = 1$ )

$H_A$ :  $H_0$  stimmt nicht

Seien  $n_i$  : Anzahl „Treffer“ i-te Klasse

$n := n_1 + \dots + n_k$  Umfang der Stichprobe

$$\text{Test } T := \sum_{i=1}^k \frac{(n_i - n \cdot p_i)^2}{n \cdot p_i}$$

Dabei ist  $n \cdot p_i$  die erwartete Anzahl „Treffer“ der i-ten Klasse.

Verwerfen  $H_0$  wenn  $T$  „zu groß“ ist.

**Satz:**  $T$  konvergiert für  $n \rightarrow \infty$  gegen  $\chi_{k-1}^2$ -Verteilung.

Eine genauere Analyse ergibt folgende Faustregel für  $\alpha = 5\%$ :

Gilt  $n \cdot p_i \geq 1$  für alle  $i \in \{1, \dots, k\}$  und  $n \cdot p_i \geq 4$  für mind. 80% der  $i \in \{1, \dots, k\}$ , so ist  $H_0$  zu verwerfen, falls  $T \geq \nu + 2\sqrt{2\nu}$  ist, wobei  $\nu := k - 1$ .

Falls die Bedingungen nicht erfüllt sind, fasst man mehrere Klassen zu einer zusammen (wodurch  $k$  kleiner wird).

**B.7.4. Chi-Quadrat-Unabhängigkeitstest:**

Der Ausgang eines Zufallsexperiments wird nach klassifizierten Merkmalen untersucht.  
(Bsp.: Haarfarbe und Augenfarbe eines zufällig gewählten Menschen)

$H_0$ : Die beiden Merkmale sind unabhängig voneinander

$H_A$ :  $H_0$  stimmt nicht

Seien  $r$ : Anzahl Klassen 1. Merkmal

$s$ : Anzahl Klassen 2. Merkmal

$n_{i,j}$ : Anzahl „Treffer“  $i$ -te Klasse 1. Merkmal und  $j$ -te Klassen 2. Merkmal

Gegeben seien  $p_i^1 := P(i\text{-te Klasse 1. Merkmal})$

$p_j^2 := P(j\text{-te Klasse 2. Merkmal})$

z.B. ML-Schätzer:

$n_i^1$ : Anzahl Treffer  $i$ -te Klasse 1. Merkmal

$n_j^2$ : Anzahl Treffer  $j$ -te Klasse 2. Merkmal

$$n := n_1^1 + \dots + n_r^1 = n_1^2 + \dots + n_s^2$$

$$\hat{p}_i^1 = \frac{n_i^1}{n}, \hat{p}_i^2 = \frac{n_j^2}{n}$$

Unter  $H_0$  gilt  $p_{ij} := P(1.\text{Merkmal } i\text{-te Klasse, } 2.\text{Merkmal } j\text{-te Klasse})$

$$= p_i^1 \cdot p_j^2$$

$$\chi^2\text{-Anpassungstest: } T = \sum_{i=1}^r \sum_{j=1}^s \frac{\overbrace{(n_{ij} - np_i^1 \cdot p_j^2)}^{=np_{ij}}}{np_i^1 \cdot np_j^2}$$

$$\text{z.B. ML-Schätzer } T = n \cdot \sum_{i=1}^r \sum_{j=1}^s \frac{(n_{ij} - \frac{n_i^1 n_j^2}{n})^2}{\frac{n_i^1 \dots n_j^2}{n}} = n \sum_{i=1}^r \sum_{j=1}^s \frac{n_{ij}^2}{n_i^1 n_j^2} - n$$

**Faustregel:** Verwerfe  $H_0$  falls  $T \geq \nu + 2\sqrt{2\nu}$ , wobei

$$\nu = (r-1)(s-1) = r \cdot s + 1 - (r-1) - (s-1)$$

**B.7.5. Vorzeichentest:**

Sei  $X$  eine ZV mit Dichte  $f$  und Verteilungsfunktion  $F$ .

Ein Median von  $X$ , bzw. von  $F$ , ist eine Zahl  $\mu \in \mathbb{R}$  mit  $F(\mu) = P(X \leq \mu) = \frac{1}{2}$

- Ist  $\mu$  ein Median von  $X$ , so gilt

$$P(X \leq \mu) = P(X \geq \mu) = \frac{1}{2}, \text{ da } P(X = \mu) = 0$$


- Ein Median muss nicht eindeutig sein.

**Bsp.:**



- Existiert  $E(X)$  und ist  $f$  symm. bzgl.  $E(X)$ , dann ist  $E(X)$  ein Median.

**Bsp.:**  $\mathcal{N}(\mu, \sigma^2)$



$H_0$  :  $\mu_0$  ist ein Median

$H_A$  : nicht  $H_0$

Stichprobe  $\underline{X} = (X_1, \dots, X_n)$

Test  $T(\underline{X}) := \#\{i \in \{1, \dots, n\}; X_i > \mu_0\}$

Unter  $H_0$  gilt  $T(\underline{X}) \stackrel{d}{=} B(n, \frac{1}{2})$

Weiter mit Binomialtest

### B.7.6. Wilcoxon-Test:

**Voraussetzung:**  $f$  ist symm. bzgl. eines Parameters  $\mu$  ( $\mu$  ist dann automatisch ein Median und  $\mu = E(X)$  falls existent)

$$H_0 : \mu = \mu_0$$

$$H_A : \mu \neq \mu_0$$

Stichprobe  $\underline{x} = (x_1, \dots, x_n)$

Ordnen  $|\mu_0 - x_i|$  der Größe nach (aufsteigend) und weisen  $i$  den entsprechenden Rang zu

$T(\underline{x}) =$  Summe der Ränge derjenigen  $i \in \{1, \dots, n\}$  für die gilt  $x_i - \mu_0 > 0$

**Bsp.:**  $n = 5, \mu_0 = 4$


|                 |     |     |     |     |     |
|-----------------|-----|-----|-----|-----|-----|
| $x_i$           | 3,2 | 4,8 | 5,6 | 4,4 | 6,2 |
| $ x_i - \mu_0 $ | 1,8 | 0,2 | 0,6 | 0,6 | 1,2 |
| Vorzeichen      | -   | -   | +   | -   | +   |
| Rang            | 5   | 1   | 2,5 | 2,5 | 4   |

$$T(\underline{x}) = 6,5$$

$T$  nimmt Werte in  $\{0, \dots, \frac{n(n+1)}{2}\}$


Man verwirft  $H_0$  falls  $T$  zu „klein“ oder zu „groß“ ist. (siehe Tabelle)

Vergleiche Vorzeichentest:



Bei einer solchen Dichte lässt sich  $H_0$  mit dem Wilcoxon-Test eher verwerfen (vgl. Übung 46)

Vergleiche mit t-Test:



$S$  muss klein sein beim t-Test um  $H_0$  zu verwerfen. Bei Ausreißern lässt sich  $H_0$  mit dem Wilcoxon-Test eher verwerfen (vgl. Übung 45).

## Klausurhinweise

**Klausur:** Datum: 18.07.  
Zeit: 13.15 Uhr (pünktlich da sein)  
Dauer: 90 Minuten  
Raum: N6 Hörsaalzentrum  
Hilfsmittel: zwei A4-Blätter (handbeschrieben, beidseitig), **kein** Taschenrechner

Klausurteilnahme (oder offizielle Entschuldigung) ist Voraussetzung für die Zulassung zur Nachklausur.

**Sprechstunde:** Di, 14-17 Uhr, C-Bau A17