

# WuS Exam Notes

Ruben Schenk

August 2021

# 1 Wahrscheinlichkeit

## 1.1 Grundbegriffe

**Def:** Der **Ereignisraum**  $\Omega \neq \emptyset$  ist die Menge aller möglichen Ergebnisse eines Zufallsexperiment. Die Element  $\omega \in \Omega$  heissen **Elementarereignisse** des Experiments.

**Def:** Die **Potenzmenge** von  $\Omega$ ,  $\mathcal{P}(\Omega)$  oder  $2^\Omega$ , ist die Menge aller Teilmengen von  $\Omega$ . Ein **prinzipielles Ereignis** ist eine Teilmenge  $A \subseteq \Omega$ . Die Klasse aller beobachtbaren Ereignisse ist  $\mathcal{F}$ .

**Def:** Ein **Wahrscheinlichkeitsmass** ist eine Abbildung  $P : \mathcal{F} \rightarrow [0, 1]$ , welche die folgenden Axiome erfüllt. Für  $A \in \mathcal{F}$  nennen wir  $P[A] \in [0, 1]$  die **Wahrscheinlichkeit**, kurz **WS**, dass  $A$  eintritt. Die geforderten Axiome sind:

1.  $P[A] \geq 0$  für alle Ereignisse  $A \in \mathcal{F}$
2.  $P[\Omega] = 1$
3.  $P[\bigcup_{i=1}^{\infty} A_i] = \sum_{i=1}^{\infty} P[A_i]$ , sofern die  $A_i \in \mathcal{F}$  paarweise disjunkt sind.

**Bmk:**  $\cup$  steht für die Vereinigung paarweiser disjunkten Mengen.  
**Bmk:** Aus den obigen Axiomen lassen sich einige grundlegende **Rechenregeln** ableiten:

- $P[A^C] = 1 - P[A]$
- $P[\emptyset] = 0$
- Für  $A \subseteq B$  gilt  $P[A] \leq P[B]$
- Für beliebige, nicht unbedingt disjunkte,  $A, B$  gilt die allgemeine **Additionsregel**:  $P[A \cup B] = P[A] + P[B] - P[A \cap B]$ .

## 1.2 Diskrete Wahrscheinlichkeit

**Def:** Ist  $\Omega = \{\omega_1, \omega_2, \dots, \omega_N\}$  endlich mit  $|\Omega| = N$  und  $\mathcal{F} = 2^\Omega$ , und sind  $\omega_1, \omega_2, \dots, \omega_N$  alle gleich wahrscheinlich, also  $p_1 = p_2 = \dots = p_N = \frac{1}{N}$ , so heisst  $\Omega$  ein **Laplace-Raum** und  $P$  die **diskrete Gleichverteilung** auf  $\Omega$ . Für beliebige  $A \subseteq \Omega$  ist

$$P[A] = \frac{\text{Anzahl der Elementarereignisse in } A}{\text{Anzahl der Elementarereignisse in } \Omega} = \frac{|A|}{|\Omega|}.$$

## 1.3 Bedingte Wahrscheinlichkeit

**Def:** Seien  $A, B$  Ereignisse und  $P[A] > 0$ . Die **bedingte Wahrscheinlichkeit** von  $B$  unter der Bedingung, dass  $A$  eintritt (kurz "gegeben  $A$ ") wird definiert durch:

$$P[B|A] := \frac{P[B \cap A]}{P[A]}.$$

Aus obiger Definition folgt direkt die sogenannte **Multiplikationsregel**: Für beliebige Ereignisse  $A, B$  ist  $P[A \cap B] = P[B|A] \cdot P[A]$ .

**Satz der totalen Wahrscheinlichkeit:** Sei  $A_1, \dots, A_n$  eine Zerlegung von  $\Omega$  (in paarweise disjunkte Ereignisse), d.h.  $\bigcup_{i=1}^n A_i = \Omega$ . Für beliebige Ereignisse  $B$  gilt dann:

$$P[B] = \sum_{i=1}^n P[B|A_i] \cdot P[A_i]$$

**Satz (von Bayes):** Für zwei Ereignisse  $A$  und  $B$  und  $P[B] \neq 0$  lautet der Satz von Bayes wie folgt:

$$P[A|B] = \frac{P[B|A] \cdot P[A]}{P[B]} = \frac{P[B|A] \cdot P[A]}{P[B|A] \cdot P[A] + P[B|A^C] \cdot P[A^C]}.$$

## 1.4 Unabhängigkeit von Ereignissen

**Def:** Zwei Ereignisse  $A, B$  heissen **stochastisch unabhängig**, falls

$$P[A \cap B] = P[A] \cdot P[B].$$

Ist  $P[A] = 0$  oder  $P[B] = 0$ , so sind  $A$  und  $B$  immer unabhängig. Für  $P[A] \neq 0$  ( $P[B] \neq 0$ ) gilt:

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

**Def:** Die Ereignisse  $A_1, \dots, A_n$  heissen **stochastisch unabhängig**, wenn für jede endliche Teilfamilie die Produktformel gilt, d.h. für  $m \in \mathcal{N}$  und  $\{k_1, \dots, k_m\} \subseteq \{1, \dots, n\}$  gilt immer:

$$P\left[\bigcap_{i=1}^m A_{k_i}\right] = \prod_{i=1}^m P[A_{k_i}]$$

# 2 Diskrete Zufallsvariablen und Verteilungen

## 2.1 Grundbegriffe

**Def:** Eine **diskrete Zufallsvariable**, kurz **ZV**, auf  $\Omega$  ist eine Funktion  $X : \Omega \rightarrow \mathbb{R}$ . Die **Verteilung** von  $X$  ist gegeben durch:

$$\mu_X(B) := P[X \in B] := P[\{\omega \in \Omega : X(\omega) \in B\}] \quad \forall B \subseteq \mathcal{W}(X).$$

Die **Verteilungsfunktion**, kurz **VF**, von  $X$  ist die Abbildung  $F_X : \mathbb{R} \rightarrow [0, 1]$ , definiert durch

$$t \rightarrow F_X(t) := P[X \leq t] := P[\{\omega : X(\omega) \leq t\}]$$

**Def:** Die **Gewichtsfunktion** oder **diskrete Dichte**, von  $X$  ist die Funktion  $p_X : \mathcal{W}(X) \rightarrow [0, 1]$ , die definiert ist durch

$$p_X(x_k) := P[X = x_k] = P[\{\omega : X(\omega) = x_k\}] \quad (\text{für } k = 1, 2, \dots).$$

**Bmk:** Ist  $\Omega$  endlich oder abzählbar mit  $\mathcal{F} = 2^\Omega$ , so ist *jede* Funktion  $X : \Omega \rightarrow \mathbb{R}$  eine diskrete Zufallsvariable.

**Def:** Für jede Teilmenge  $A \subseteq \Omega$  ist die **Indikatorfunktion**  $I_A$  von  $A$  definiert durch:

$$I_A(\omega) := \begin{cases} 1 & \text{für } \omega \in A \\ 0 & \text{für } \omega \in A^C \end{cases}$$

**Eigenschaften der Dichte und Verteilungsfunktion:**

- die Verteilungsfunktion  $F_X$  ist vollständig durch die Dichte  $p_X$  festgelegt:  $F_X(t) = P[X \leq t] = \sum_{x_k \leq t} P[X = x_k] = \sum_{x_k \leq t} p_X(x_k)$
- Die Verteilung beschreibt das stochastische Verhalten einer Zufallsvariable. Das ist das WHS-Mass  $\mu_X$ , das durch  $\mu_X(B) := P[X \in B]$  definiert ist. Ist  $X$  eine diskrete ZV, so ist  $\mu_X$  die **diskrete Verteilung**. Damit kann man die Verteilung  $\mu_X$  und die Gewichtsfunktion  $p_X$  miteinander identifizieren: der Unterschied besteht darin, dass  $\mu_X$  als Argumente Teilmengen von  $\mathcal{W}(X)$  hat,  $p_X$  hingegen Elemente von  $\mathcal{W}(X)$ . Es gilt:

$$\mu_X(B) = P[X \in B] = \sum_{x_k \in B} p_X(x_k) \quad \text{für } B \subseteq \mathcal{W}(X)$$

## 2.2 Erwartungswerte

**Def:** Sei  $X$  eine diskrete Zufallsvariable mit Gewichtsfunktion  $p_X$ . Dann definieren wir den **Erwartungswert** von  $X$  als

$$E[X] := \sum_{x_k \in \mathcal{W}(X)} x_k p_X(x_k),$$

sofern die Reihe absolut konvergiert ( $\sum_{x_k \in \mathcal{W}(X)} |x_k| p_X(x_k) < \infty$ ). Ist die Reihe nicht konvergent, so existiert der Erwartungswert nicht. Des weiteren gilt:

$$E[X] = \sum_{\omega_i \in \Omega} X(\omega_i) P[\{\omega_i\}] = \sum_{\omega_i \in \Omega} p_i X(\omega_i).$$

**Satz:** Sei  $X$  eine diskrete ZV mit Gewichtsfunktion  $p_X$ , und sei  $Y = g(X)$  für eine Funktion  $g : \mathbb{R} \rightarrow \mathbb{R}$ . Sofern die Reihe absolut konvergiert gilt:

$$E[Y] = E[g(X)] = \sum_{x_k \in \mathcal{W}(X)} g(x_k) p_X(x_k).$$

**Satz:** Seien  $X$  und  $Y$  diskrete ZV's, für die jeweils der Erwartungswert existiert. Dann gilt:

1. **Monotonie:** Ist  $X \leq Y$  (d.h.  $X(\omega) \leq Y(\omega)$  für alle  $\omega$ ), so gilt auch  $E[X] \leq E[Y]$ .
2. **Linearität:** Für beliebige  $a, b \in \mathbb{R}$  gilt  $E[aX + b] = aE[X] + b$ .
3. Falls  $X$  nur Werte in  $\mathbb{N}_0$  annimmt, so gilt

$$E[X] = \sum_{j=1}^{\infty} P[X \geq j] = \sum_{l=0}^{\infty} P[X > l]$$

**Def:** Sei  $X$  eine diskrete Zufallsvariable. Ist  $E[X^2] < \infty$ , so heisst

$$\text{Var}[X] := E[(X - E[X])^2]$$

die **Varianz** von  $X$ , und  $\sqrt{\text{Var}[X]}$  heisst die **Standardabweichung** von  $X$ . Manchmal schreibt man auch  $\text{sd}(X) := \sqrt{\text{Var}[X]}$  oder  $\sigma(X) := \sqrt{\text{Var}[X]}$ .

**Lemma:** Sei  $X$  eine diskrete ZV mit  $E[X]^2 < \infty$ , und sei  $Y = aX + b$ . Dann gilt:

1.  $\text{Var}[X] = E[X^2] - (E[X])^2$
2.  $\text{Var}[Y] = \text{Var}[aX + b] = a^2 \text{Var}[X]$

## 2.3 Gemeinsame Verteilungen, unabhängige Zufallsvariablen

**Def:** Seien  $X_1, \dots, X_n$  (diskrete oder auch beliebige) Zufallsvariablen. Die **gemeinsame Verteilungsfunktion** von  $X_1, \dots, X_n$  ist die Abbildung  $F: \mathbb{R}^n \rightarrow [0, 1]$ , definiert durch

$$(x_1, \dots, x_n) \rightarrow F(x_1, \dots, x_n) := P[X_1 \leq x_1, \dots, X_n \leq x_n].$$

Sind  $X_1, \dots, X_n$  diskrete ZV's, so definiert man ihre **gemeinsame Gewichtsfunktion**  $p: \mathbb{R}^n \rightarrow [0, 1]$  durch

$$p(x_1, \dots, x_n) := P[X_1 = x_1, \dots, X_n = x_n].$$

**Def:** Haben  $X$  und  $Y$  die gemeinsame Verteilungsfunktion  $F$ , so ist die Funktion  $F_X: \mathbb{R} \rightarrow [0, 1]$ ,

$$x \rightarrow F_X(x) := P[X \leq x] = P[X \leq x, Y < \infty] = \lim_{y \rightarrow \infty} F(x, y)$$

die Verteilungsfunktion der **Randverteilung**, kurz **RV**, von  $X$ . Analog ist  $F_Y: \mathbb{R} \rightarrow [0, 1]$ ,

$$y \rightarrow F_Y(y) := P[Y \leq y] = P[X < \infty, Y \leq y] = \lim_{x \rightarrow \infty} F(x, y)$$

die Verteilungsfunktion der Randverteilung von  $Y$ .

**Def:** Sind  $X$  und  $Y$  diskrete Zufallsvariablen mit  $\mathcal{W}(Y) = \{y_1, y_2, \dots\}$  und gemeinsamer Gewichtsfunktion  $p(x, y)$ , so ist die **Gewichtsfunktion der Randverteilung** von  $X$  gegeben durch  $p_X: \mathcal{W}(X) \rightarrow [0, 1]$ ,

$$\begin{aligned} x \rightarrow p_X(x) &= P[X = x] = \sum_{y_j \in \mathcal{W}(Y)} P[X = x, Y = y_j] \\ &= \sum_{y_j \in \mathcal{W}(Y)} p(x, y_j) \quad \text{für } x \in \mathcal{W}(X). \end{aligned}$$

**Def:** Die Zufallsvariablen  $X_1, \dots, X_n$  heissen **unabhängig**, falls gilt

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

d.h. die gemeinsame Verteilungsfunktion  $F$  ist das Produkt der Verteilungsfunktionen  $F_{X_i}$  der Randverteilungen.

## 2.4 Funktionen von mehreren Zufallsvariablen

**Satz:** Seien  $X_1, \dots, X_n$  diskrete ZV's mit endlichen Erwartungswert  $E[X_1], \dots, E[X_n]$ . Sei  $Y = a + \sum_{l=1}^n b_l X_l$  mit Konstanten  $a, b_1, \dots, b_n$ . Dann gilt:

$$E[Y] = a + \sum_{l=1}^n b_l E[X_l].$$

**Def:** Die Grösse

$$\begin{aligned} \text{Cov}(X_1, X_2) &:= E[X_1 X_2] - E[X_1]E[X_2] \\ &= E[(X_1 - E[X_1])(X_2 - E[X_2])] \end{aligned}$$

heisst die **Kovarianz** von  $X_1$  und  $X_2$ , und damit haben wir allgemein die Formel:

$$\text{Var}[X_1 + X_2] = \text{Var}[X_1] + \text{Var}[X_2] + 2\text{Cov}(X_1, X_2).$$

**Def:** Die **Korrelation** von  $X$  und  $Y$  ist definiert durch

$$\rho(X, Y) := \begin{cases} \frac{\text{Cov}(X, Y)}{\sigma(X)\sigma(Y)}, & \text{falls } \sigma(X)\sigma(Y) > 0 \\ 0, & \text{sonst} \end{cases}$$

Ist  $\text{Cov}(X, Y) = 0$ , so nennt man  $X$  und  $Y$  **unkorreliert**.

**Satz:** Seien  $X_1, \dots, X_n$  diskrete Zufallsvariablen mit endlichen Erwartungswerten  $E[X_1], \dots, E[X_n]$ . Falls  $X_1, \dots, X_n$  unabhängig sind, so ist

$$E\left[\prod_{i=1}^n X_i\right] = \prod_{i=1}^n E[X_i].$$

Insbesondere sind dann  $X_1, \dots, X_n$  paarweise unkorreliert. und es

gilt

$$\text{Var}\left[\sum_{i=1}^n X_i\right] = \sum_{i=1}^n \text{Var}[X_i].$$

sofern  $\text{Var}[X_1], \dots, \text{Var}[X_n]$  alle existieren und endlich sind.

**Bmk:** Es gelten die Implikationen

unabhängig  $\implies$  paarweise unabhängig  $\implies$  unkorreliert

Beide umgekehrten Implikationen sind in der Regel falsch.

## 2.5 Bedingte Verteilungen

**Def:** Seien  $X$  und  $Y$  diskrete Zufallsvariablen mit gemeinsamer Gewichtsfunktion  $p(x, y)$ . Die **bedingte Gewichtsfunktion** von  $X$ , gegeben dass  $Y = y$ , ist definiert durch

$$p_{X|Y}(x|y) := P[X = x|Y = y] = \frac{P[X = x, Y = y]}{P[Y = y]} = \frac{p(x, y)}{p_Y(y)}$$

für  $p_Y(y) > 0$  und 0 sonst.

## 3 Wichtige diskrete Verteilungen

### 3.1 Diskrete Gleichverteilung

**Def:** Die **diskrete Gleichverteilung** auf einer endlichen Menge  $\mathcal{W} = \{x_1, \dots, x_N\}$  gehört zu einer Zufallsvariable  $X$  mit Wertebereich  $\mathcal{W}$  und Gewichtsfunktion

$$p_X(x_k) = P[X = x_k] = \frac{1}{N} \quad \text{für } k = 1, \dots, N.$$

Das typische ist hier also, dass alle Elementarereignisse mit der gleichen Wahrscheinlichkeit auftreten. Beispiele: Ergebnis eines Würfelwurfs oder Münzwurfs, zufällige Auswahl einer dreistelligen Zahl, oder zufällige Permutationen von  $\{1, \dots, N\}$ .

### 3.2 Unabhängige 0-1-Experimente

Wir betrachten eine Folge gleichartiger Experimente die nur in Erfolg oder Misserfolg enden können (z.B. das Würfeln einer 6, das Werfen von Kopf, usw.). Wir betrachten die Ereignisse

$$A_i = \{\text{Erfolg beim } i\text{-ten Experiment}\}.$$

Wir nehmen dabei an, dass (1) die  $A_i$  unabhängig sind und (2) dass  $P[A_i] = p$  für alle  $i$  ist. Dabei heisst  $p \in [0, 1]$  der **Erfolgsparmeter**. Mit  $Y_i = I_{A_i}$  bezeichnen wir die **Indikatorfunktion** des Ereignisses  $A_i$ , also ist:

$$Y_i(\omega) = \begin{cases} 1 & \text{für } \omega \in A_i, \\ 0 & \text{für } \omega \notin A_i, \end{cases}$$

und nimmt nur die Werte 0 oder 1 an, mit  $P[Y_i = 1] = P[A_i] = p$ . Die Zufallsvariablen  $Y_i$  bilden daher eine **Folge unabhängiger 0-1-Experimente** mit Erfolgsparameter  $p$ .

### 3.3 Bernoulli-Verteilung

**Def:** Bezeichnen wir mit  $X$  das Ergebnis eines einzigen 0-1-Experiment, so hat  $X$  eine **Bernoulli-Verteilung** mit Parameter  $p$ . Wir schreiben  $X \sim Be(p)$ . Es gilt:

- Wertebereich:  $\mathcal{W}(X) = \{0, 1\}$
- Gewichtsfunktion:  $p_X(x) = p^x(1-p)^{1-x}$  für  $x \in \mathcal{W}(X)$
- Erwartungswert:  $E[X] = p$
- Varianz:  $\text{Var}[X] = E[X^2] - (E[X])^2 = p(1-p)$

### 3.4 Binomialverteilung

**Def:** Die **Binomialverteilung** mit Parametern  $n$  und  $p$  beschreibt die *Anzahl der Erfolge* bei  $n$  unabhängigen 0-1-Experimenten mit Erfolgsparameter  $p$ . Sei die Zufallsvariable  $X$  gegeben durch  $X = \sum_{i=1}^n I_{A_i} = \sum_{i=1}^n Y_i$ , dann hat diese eine Binomialverteilung. Wir schreiben  $X \sim Bin(n, p)$ . Es gilt:

- Wertebereich:  $\mathcal{W}(X) = \{0, 1, 2, \dots, n\}$
- Gewichtsfunktion:  $p_X(k) = P[X = k] = \binom{n}{k} p^k (1-p)^{n-k}$  für  $k = 0, 1, \dots, n$
- Erwartungswert:  $E[X] = \sum_{i=1}^n E[Y_i] = np$
- Varianz:  $\text{Var}[X] = \sum_{i=1}^n \text{Var}[Y_i] = np(1-p)$

### 3.5 Geometrische Verteilung

**Def:** Betrachten wir eine unendliche Folge von unabhängigen 0-1-Experimenten mit Erfolgsparameter  $p$ . Sei  $X$  die Wartezeit auf den ersten Erfolg, also

$$X = \inf\{i \in \mathbb{N} : A_i \text{ tritt ein}\} = \inf\{i \in \mathbb{N} : Y_i = 1\}$$

d.h.  $X$  ist der Index der ersten Eins in der zufälligen 0-1-Folge. Dann hat  $X$  eine **geometrische Verteilung** mit Parameter  $p$ . Wir schreiben  $X \sim Geom(p)$ . Es gilt:

- Wertebereich:  $\mathcal{W}(X) = \mathbb{N}$
- Gewichtsfunktion:  $p_X(k) = P[X = k] = p(1-p)^{k-1}$  für  $k = 1, 2, 3, \dots$
- Erwartungswert:  $E[X] = \sum_{l=0}^{\infty} P[X > l] = \sum_{l=0}^{\infty} (1-p)^l = \frac{1}{1-(1-p)} = \frac{1}{p}$
- Varianz:  $\text{Var}[X] = E[X(X-1)] + E[X] - (E[X])^2 = \frac{1-p}{p^2}$

### 3.6 Negativbinomiale Verteilung

**Def:** Betrachten wir eine unendliche Folge von unabhängigen 0-1-Experimenten mit Erfolgsparameter  $p$ , so können wir für  $r \in \mathbb{N}$  auch die Wartezeit auf den  $r$ -ten Erfolg betrachten. Dann hat  $X$  eine **negativbinomiale Verteilung** mit Parametern  $r$  und  $p$ . Wir schreiben kurz  $X \sim NB(r, p)$ .  $X$  lässt sich schreiben als:

$$X = \inf \left\{ k \in \mathbb{N} : \sum_{i=1}^k I_{A_i} = r \right\} = \inf \left\{ k \in \mathbb{N} : \sum_{i=1}^k Y_i = r \right\}.$$

Es gilt:

- Wertebereich:  $\mathcal{W}(X) = \{r, r+1, r+2, \dots\}$

- Gewichtsfunktion:  $p_X(k) = \binom{k-1}{r-1} p^r (1-p)^{k-r}$  für  $k = r, r+1, \dots$
- Erwartungswert:  $E[X] = \sum_{i=1}^r E[X_i] = \frac{r}{p}$
- Varianz:  $\text{Var}[X] = \sum_{i=1}^r \text{Var}[X_i] = \frac{r(1-p)}{p^2}$

wobei die Zufallsvariablen  $X_1, \dots, X_r \sim Geom(p)$  und ihre Summe  $X := X_1 + \dots + X_r \sim NB(r, p)$ .

### 3.7 Hypergeometrische Verteilung

**Def:** In einer Urne seien  $n$  Gegenstände, davon  $r$  vom Typ 1 und  $n-r$  vom Typ 2. Man zieht ohne Zurücklegen  $m$  der Gegenstände. Die Zufallsvariable  $X$  beschreibt die Anzahl der Gegenstände vom Typ 1 in dieser Stichprobe. Dann hat  $X$  eine **hypergeometrische Verteilung** mit Parametern  $n \in \mathbb{N}$  und  $m, r \in \{1, \dots, n\}$ . Es gilt:

- Wertebereich:  $\mathcal{W}(X) = \{0, 1, \dots, \min(m, r)\}$
- Gewichtsfunktion:

$$p_X(k) = \frac{\binom{r}{k} \binom{n-r}{m-k}}{\binom{n}{m}} \quad \text{für } k \in \mathcal{W}(X)$$

### 3.8 Poisson-Verteilung

**Def:** Die **Poisson-Verteilung** mit Parameter  $\lambda \in (0, \infty)$  ist eine Verteilung auf der Menge  $\mathbb{N}_0$  mit Gewichtsfunktion

$$p_X(k) = e^{-\lambda} \frac{\lambda^k}{k!} \quad \text{für } k = 0, 1, 2, \dots$$

Wir schreiben kurz  $X \sim \mathcal{P}(\lambda)$ . Die Poissonverteilung eignet sich zur Modellierung von seltenen Ereignissen. Sei z.B.  $X_n$  für jedes  $n$  eine Zufallsvariable mit  $X_n \sim Bin(n, p_n)$  und  $np_n = \lambda$ . Lassen wir nun  $n \rightarrow \infty$  gehen, so geht  $p_n = \frac{\lambda}{n} \rightarrow 0$ , und  $X_n$  beschreibt die Anzahl Erfolge bei sehr vielen Versuchen mit sehr kleiner Erfolgswahrscheinlichkeit, also bei seltenen Ereignissen. In diesem Sinn ist also die Poisson-Verteilung ein Grenzwert von Binomialverteilungen bei geeigneter Skalierung der Parameter. Es gilt:

- Erwartungswert:  $E[X] = \sum_{k=0}^{\infty} k p_X(k) = \lambda \sum_{j=0}^{\infty} e^{-\lambda} \frac{\lambda^j}{j!} = \lambda$
- Varianz:  $\text{Var}[X] = E[X(X-1)] + E[X] - (E[X])^2 = \lambda$

## 4 Allgemeine Zufallsvariablen

### 4.1 Grundbegriffe

**Def:** Sei  $(\Omega, \mathcal{F}, P)$  ein Wahrscheinlichkeitsraum, also  $\Omega$  ein Grundraum,  $\mathcal{F} \subseteq 2^\Omega$  eine  $\sigma$ -Algebra von beobachtbaren Ereignissen und  $P$  ein Wahrscheinlichkeitsmass auf  $\mathcal{F}$ . Eine **Zufallsvariable (ZV)** auf  $\Omega$  ist eine messbare Funktion  $X : \Omega \rightarrow \mathbb{R}$ . Die **Verteilungsfunktion (VF)** von  $X$  ist dann eine Abbildung  $F_X : \mathbb{R} \rightarrow [0, 1]$ ,

$$t \rightarrow F_X(t) := P[X \leq t] := P[\{\omega : X(\omega) \leq t\}]$$

Jede Verteilungsfunktion  $F_X$  hat die folgende Eigenschaften:

1.  $F_X$  ist wachsend und rechtsstetig. Das bedeutet, dass  $F_X(s) \leq F_X(t)$  für  $s \leq t$  gilt und  $F_X(u) \rightarrow F_X(t)$  für  $u \rightarrow t$  mit  $u > t$ .
2.  $\lim_{t \rightarrow -\infty} F_X(t) = 0$ ,  $\lim_{t \rightarrow +\infty} F_X(t) = 1$
3. Für *stetige Verteilungen* gilt:  $\forall x : P[X = x] = 0$

Das stochastische Verhalten einer Zufallsvariable  $X$  wird durch ihre **Verteilung** beschrieben. Das ist dasjenige Wahrscheinlichkeitsmass  $\mu_X$  auf  $\mathbb{R}$ , definiert durch:

$$\mu_X(B) := P[X \in B]$$

**Def:** Eine Zufallsvariable  $X$  mit Verteilungsfunktion  $F_X(t) = P[X \leq t]$  heisst **absolut stetig mit Dichte(funktion)**  $f_x : \mathbb{R} \rightarrow [0, \infty)$ , falls gilt

$$F_X(t) = \int_{-\infty}^t f_X(s) ds \quad \text{für alle } t \in \mathbb{R}$$

Eine Dichtefunktion  $f_X$  hat, analog zur Gewichtsfunktion im diskreten Fall, stets folgende Eigenschaften:

1.  $f_X \geq 0$ , und  $f_X = 0$  ausserhalb von  $\mathcal{W}(X)$
2.  $\int_{-\infty}^{\infty} f(s) ds = 1$

### 4.2 Wichtige stetige Verteilungen

#### 4.3 Gleichverteilung

**Def:** Die **Gleichverteilung** auf einem Intervall  $[a, b]$  ist ein Modell für die zufällige Wahl eines Punktes in  $[a, b]$ . Für die zugehörige Zufallsvariable  $X$  gilt:

- Wertebereich:  $\mathcal{W}(X) = [a, b]$
- Dichtefunktion:

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

- Verteilungsfunktion:

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

Wir schreiben kurz  $X \sim \mathcal{U}(a, b)$ , dabei steht  $\mathcal{U}$  für uniform. Ein wichtiger Spezialfall ist  $\mathcal{U}(0, 1)$ .

#### 4.4 Exponentialverteilung

**Def:** Die **Exponentialverteilung** mit Parameter  $\lambda > 0$  ist das stetige Analogon der geometrischen Verteilung. Für die zugehörige Zufallsvariable  $X$  gilt:

- Wertebereich:  $\mathcal{W}(X) = [0, \infty)$
- Dichte:

$$f_X(t) = \begin{cases} \lambda e^{-\lambda t} & \text{für } t \geq 0, \\ 0 & \text{für } t < 0 \end{cases}$$

Wir schreiben  $X \sim \text{Exp}(\lambda)$ .

**Bmk:** Wie die geometrische Verteilung hat die Exponentialverteilung die Eigenschaft der "Gedächtnislosigkeit" in dem Sinne, dass gilt

$$P[X > t + s | X > s] = P[X > t]$$

Berechnung: Für  $X \sim \text{Exp}(\lambda)$  :

$$\begin{aligned} P[X > t + s | X > s] &= \frac{P[X > t + s]}{P[X > s]} = \frac{1 - F_X(t + s)}{1 - F_X(s)} \\ &= \frac{e^{-\lambda(t+s)}}{e^{-\lambda s}} = e^{-\lambda t} \\ &= 1 - F_X(t) = P[X > t] \end{aligned}$$

## 4.5 Normalverteilung

**Def:** Die **Normalverteilung**, auch kurz **NV** oder Gauss-Verteilung genannt, hat zwei Parameter  $\mu \in \mathbb{R}$  und  $\sigma^2 > 0$ . Für die zugehörige Zufallsvariable  $X$  gilt:

- Wertebereich:  $\mathcal{W}(X) = \mathbb{R}$
- Dichtefunktion:

$$f_X(t) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(t-\mu)^2}{2\sigma^2}} \quad \text{für } t \in \mathbb{R}$$

Wir schreiben  $X \sim \mathcal{N}(\mu, \sigma^2)$ .

Ein wichtiger Spezialfall ist die **Standard-Normalverteilung** mit  $\mu = 0, \sigma^2 = 1$ , also  $\mathcal{N}(0, 1)$ . Die Dichte wird mit  $\varphi(t)$  und die Verteilungsfunktion mit  $\Phi(t)$  bezeichnet. Weder für  $F_X$  noch für  $\Phi$  gibt es einen geschlossenen Ausdruck, aber das Integral

$$\Phi(t) = \int_{-\infty}^t \varphi(s) ds = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^t e^{-\frac{1}{2}s^2} ds$$

ist **tabelliert**. Ist  $X \sim \mathcal{N}(\mu, \sigma^2)$ , so ist  $F_X(t) = \Phi\left(\frac{t-\mu}{\sigma}\right)$ .

## 4.6 Erwartungswerte

Ist  $X$  stetig mit Dichte  $f_X(x)$ , so gilt

$$E[X] = \int_{-\infty}^{\infty} x f_X(x) dx,$$

sofern das Integral absolut konvergiert, ansonsten existiert der Erwartungswert nicht.

**Bsp:** Bei einer Gleichverteilung auf  $[a, b]$ : Für  $X \sim \mathcal{U}(a, b)$  ist

$$E[X] = \int_{-\infty}^{\infty} x f_X(x) dx = \int_a^b x \frac{1}{b-a} dx = \dots = \frac{a+b}{2}$$

**Bsp:** Bei einer Normalverteilung: Für  $X \sim \mathcal{N}(\mu, \sigma^2)$  ist

$$E[X] = \int_{-\infty}^{\infty} x \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} dx = \dots = \mu$$

**Bsp:** Cauchy-Verteilung: Eine **Cauchy-verteilte** Zufallsvariable  $X$  hat den Wertebereich  $\mathcal{W}(X) = \mathbb{R}$  mit der Dichtefunktion  $f_X(x) = \frac{1}{\pi} \frac{1}{1+x^2}$  für  $x \in \mathbb{R}$ . Die zugehörige Verteilungsfunktion ist  $F_X(x) = \frac{1}{2} + \frac{1}{\pi} \arctan(x)$  für  $x \in \mathbb{R}$ . Es existiert kein Erwartungswert.

**Satz:** Sei  $X$  eine Zufallsvariable und  $Y = g(X)$  eine weitere Zufallsvariable. Ist  $X$  stetig mit Dichte  $f_X$ , so ist

$$E[Y] = E[g(X)] = \int_{-\infty}^{\infty} g(x) f_X(x) dx,$$

sofern das Integral absolut konvergiert.

## 4.7 Gemeinsame Verteilungen, unabhängige Zufallsvariablen

**Def:** Die **gemeinsame Verteilungsfunktion** von  $n$  Zufallsvariablen  $X_1, \dots, X_n$  ist die Abbildung  $F : \mathbb{R}^n \rightarrow [0, 1]$

$$(x_1, \dots, x_n) \rightarrow F(x_1, \dots, x_n) := P[X_1 \leq x_1, \dots, X_n \leq x_n].$$

Falls die gemeinsame Verteilungsfunktion  $F$  von  $X_1, \dots, X_n$  sich schreiben lässt als

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

für eine Funktion  $f : \mathbb{R}^n \rightarrow [0, \infty)$ , so heisst  $f(x_1, \dots, x_n)$  die **gemeinsame Dichte** von  $X_1, \dots, X_n$ .

**Def:** Haben  $X$  und  $Y$  die gemeinsame Verteilungsfunktion  $F$ , so ist die Funktion  $F_X : \mathbb{R} \rightarrow [0, 1]$ ,

$$x \rightarrow F_X(x) := P[X \leq x] = P[X \leq x, Y < \infty] = \lim_{y \rightarrow \infty} F(x, y)$$

die Verteilungsfunktion der **Randverteilung** (RV) von  $X$ .

**Def:** Die Zufallsvariablen  $X_1, \dots, X_n$  heissen **unabhängig**, falls gilt

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

d.h. die gemeinsame Verteilungsfunktion  $F$  ist das Produkt der Verteilungsfunktionen  $F_{X_i}$  der Randverteilungen.

## 4.8 Momente

**Def:** Für  $n \in \mathbb{N}$  und falls  $E[|X|^n] < \infty$  ist, kann man das **n-te Zentralmoment** von  $X$  definieren als

$$E[(X - E[X])^n].$$

**Def:** Sei  $X$  eine Zufallsvariable. Die **absoluten Momente** von  $X$  sind definiert als  $E[|X|^p]$  für  $p > 0$ . Die **Momente** von  $X$  sind definiert als  $m_n := E[X^n]$  für  $n \in \mathbb{N}$ , unter der Voraussetzung, dass  $E[|X|^n] < \infty$ . Ist  $X$  diskret mit Gewichtsfunktion  $p_X$  und Wertebereich  $\mathcal{W}(X)$ , so gilt

$$E[|X|^p] = \sum_{x \in \mathcal{W}(X)} |x|^p p_X(x).$$

Ist  $X$  absolutstetig mit Dichtefunktion  $f_X$ , so gilt

$$E[|X|^p] = \int_{-\infty}^{\infty} |x|^p f_X(x) dx.$$

## 4.9 Funktionen und Transformationen von Zufallsvariablen

**Satz:** Sei  $F$  eine stetige und streng monoton wachsende Verteilungsfunktion, mit Umkehrfunktion  $F^{-1}$ . Ist  $X \sim \mathcal{U}(0, 1)$  und  $Y = F^{-1}(X)$ , so hat  $Y$  gerade die Verteilungsfunktion  $F$ .

## 5 Ungleichungen und Grenzwertsätze

**Idee:** In vielen Situationen taucht die *Summe von vielen gleichartigen Zufallsvariablen* auf. Wir möchten wissen, wie sich diese Summe etwa verhält, und untersuchen deshalb ihre Asymptotik, wenn die Anzahl der Summanden gegen unendlich geht.

### 5.1 Ungleichungen

**Prop. (Markov-Ungleichung):** Sei  $X$  eine Zufallsvariable und ferner  $g : \mathcal{W}(X) \rightarrow [0, \infty)$  eine wachsende Funktion. Für jedes  $c \in \mathbb{R}$  mit  $g(c) > 0$  gilt dann

$$P[X \geq c] \leq \frac{E[g(X)]}{g(c)}.$$

**Korr. (Chebyshev-Ungleichung):** Sei  $Y$  eine Zufallsvariable mit endlicher Varianz. Für jedes  $b > 0$  gilt dann

$$P[|Y - E[Y]| \geq b] \leq \frac{\text{Var}[Y]}{b^2}.$$

## 5.2 Das Gesetz der grossen Zahlen

**Satz (schwaches Gesetz der grossen Zahlen):** Sei  $X_1, X_2, \dots$  eine Folge von unabhängigen Zufallsvariablen, die alle den gleichen Erwartungswert  $E[X_i] = \mu$  und die gleiche Varianz  $\text{Var}[X_i] = \sigma^2$  haben. Sei

$$\bar{X}_n = \frac{1}{n} S_n = \frac{1}{n} \sum_{i=1}^n X_i.$$

Dann konvergiert  $\bar{X}_n$  für  $n \rightarrow \infty$  in Wahrscheinlichkeit/stochastisch gegen  $\mu = E[X_i]$ , d.g.

$$P[|\bar{X}_n - \mu| > \epsilon] \xrightarrow{n \rightarrow \infty} 0 \quad \text{für jedes } \epsilon > 0.$$

**Satz (starkes Gesetz der grossen Zahlen):** Sei  $X_1, X_2, \dots$  eine Folge von unabhängigen Zufallsvariablen, die alle dieselbe Verteilung haben, und ihr Erwartungswert  $E[X_i] = \mu$  sein endlich. Für

$$\bar{X}_n = \frac{1}{n} S_n = \frac{1}{n} \sum_{i=1}^n X_i$$

gilt dann

$$\bar{X}_n \xrightarrow{n \rightarrow \infty} \mu \quad \text{P-fastsicher (P-f.s.),}$$

d.h.

$$P\left[\left\{\omega \in \Omega : \bar{X}_n(\omega) \xrightarrow{n \rightarrow \infty} \mu\right\}\right] = 1.$$

**Bmk:** Man hat es oft mit Zufallsvariablen zu tun, die unabhängig sind und alle dieselbe Verteilung haben. Der Kürze halber nennt man solche Zufallsvariablen *i.i.d.* (independent identically distributed).

## 5.3 Der Zentrale Grenzwertsatz

**Satz (zentral Grenzwertsatz, ZGS):** Sei  $X_1, X_2, \dots$  eine Folge von i.i.d. Zufallsvariablen mit  $E[X_i] = \mu$  und  $\text{Var}[X_i] = \sigma^2$ . Für die Summe

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

gilt dann

$$\lim_{n \rightarrow \infty} P\left[\frac{S_n - n\mu}{\sigma\sqrt{n}} \leq x\right] = \Phi(x) \quad \text{für alle } x \in \mathbb{R},$$

wobei  $\Phi$  die Verteilungsfunktion der  $\mathcal{N}(0, 1)$ -Verteilung ist.

## 5.4 Grosse Abweichungen & Chernoff-Schranken

**Def:** Die **momenterzeugende Funktion** einer Zufallsvariable  $X$  ist

$$M_X(t) := E[e^{tX}] \quad \text{für } t \in \mathbb{R},$$

das ist immer wohldefiniert in  $[0, \infty]$ , kann aber  $+\infty$  werde.

**Satz:** Seien  $X_1, \dots, X_n$  i.i.d. Zufallsvariablen, für welche die momenterzeugende Funktion  $M_X(t)$  für alle  $t \in \mathbb{R}$  endlich ist. Für jedes  $b \in \mathbb{R}$  gilt dann

$$P[S_n \geq b] \leq \exp\left(\inf_{t \in \mathbb{R}} (n \log M_X(t) - tb)\right).$$

**Satz:** Seien  $X_1, \dots, X_n$  unabhängig mit  $X_i \sim \text{Be}(p_i)$  und  $S_n = \sum_{i=1}^n X_i$ . Sei ferner

$$\mu_n := E[S_n] = \sum_{i=1}^n p_i$$

und  $\delta > 0$ . Dann gilt

$$P[S_n \geq (1 + \delta)\mu_n] \leq \left(\frac{e^\delta}{(1 + \delta)^{(1 + \delta)}}\right)^{\mu_n}.$$

## 6 Schätzer

### 6.1 Grundbegriffe

**Def:** Sei  $X_1, \dots, X_n$  eine Stichprobe, für die wir ein Modell suchen. Wir haben also einen Parameterraum  $\Theta$  und für jedes  $\vartheta \in \Theta$  einen Wahrscheinlichkeitsraum  $(\Sigma, \mathcal{F}, P_\vartheta)$ . Meistens ist  $\Theta \subseteq \mathbb{R}^m$ , und wir suchen dann für die Parameter  $\vartheta_1, \dots, \vartheta_m$  **Schätzer**  $T_1, \dots, T_m$  aufgrund unserer Stichprobe. Solche Schätzer sind Zufallsvariablen der Form  $T_j = t_j(X_1, \dots, X_n)$ , wobei wir die **Schätzfunktionen**  $t_j : \mathbb{R}^n \rightarrow \mathbb{R}$  noch geeignet finden müssen. Einsetzen von Daten  $x_i = X_i(\omega)$ ,  $i = 1, \dots, n$ , liefert dann **Schätzwerte**  $T_j(\omega) = t_j(x_1, \dots, x_n)$  für  $\vartheta_j$ ,  $j = 1, \dots, m$ .

### 6.2 Maximum-Likelihood-Methode

Im jedem folgenden Modell  $P_\vartheta$  sind  $X_1, \dots, X_n$  entweder diskret mit gemeinsamer Gewichtsfunktion  $p_{\bar{X}}(x_1, \dots, x_n; \vartheta)$  oder stetig mit gemeinsamer Dichtefunktion  $f_{\bar{X}}(x_1, \dots, x_n; \vartheta)$ . Meistens sind die  $X_i$  unter  $P_\vartheta$  i.i.d., dann ist also die gemeinsame Gewichtsfunktion

$$p_{\bar{X}}(x_1, \dots, x_n; \vartheta) = \prod_{i=1}^n p_X(x_i; \vartheta)$$

bzw. die gemeinsame Dichtefunktion

$$f_{\bar{X}}(x_1, \dots, x_n; \vartheta) = \prod_{i=1}^n f_X(x_i; \vartheta).$$

Anschaulich ist  $p_{\bar{X}}(x_1, \dots, x_n; \vartheta) = P_\vartheta[X_1 = x_1, \dots, X_n = x_n]$  gerade die Wahrscheinlichkeit im Modell  $P_\vartheta$ , dass unsere Stichprobe  $X_1, \dots, X_n$  die Werte  $x_1, \dots, x_n$  liefert, und  $f_{\bar{X}}(x_1, \dots, x_n; \vartheta)$  ist das übliche stetige Analogon.

**Def:** Die **Likelihood-Funktion** ist

$$L(x_1, \dots, x_n; \vartheta) := \begin{cases} p_{\bar{X}}(x_1, \dots, x_n; \vartheta) & \text{im diskreten Fall,} \\ f_{\bar{X}}(x_1, \dots, x_n; \vartheta) & \text{im stetigen Fall.} \end{cases}$$

Die Funktion  $\log L(x_1, \dots, x_n; \vartheta)$  heisst **log-Likelihood-Funktion**. Sie hat gegenüber der Likelihood-Funktion den Vorteil, dass sie im i.i.d.-Fall durch eine Summe (statt ein Produkt) gegeben und damit zum Rechnen oft wesentlich einfacher ist.

**Def:** Der **Maximum-Likelihood-Schätzer (ML-Schätzer)**  $T_{\text{ML}}$  für  $\vartheta$  wird dadurch definiert, dass er

$$\vartheta \rightarrow L(X_1, \dots, X_n; \vartheta)$$

als Funktion von  $\vartheta$  maximiert, d.h.

$$T_{\text{ML}} = t_{\text{ML}}(X_1, \dots, X_n) \in \arg \max_{\vartheta \in \Theta} L(X_1, \dots, X_n; \vartheta).$$

**Bsp:** *Bernoulli-Verteilung:* Im Modell  $P_p$  seien  $X_1, \dots, X_n$  i.i.d.  $\sim \text{Be}(p)$ . Hier ist  $\vartheta = p$  und der ML-Schätzer für  $\vartheta$  ist gegeben durch

$$T = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n.$$

**Bsp:** *Normalverteilung:* Im Modell  $P_{\vartheta}$  seien  $X_1, \dots, X_n$  i.i.d.  $\sim \mathcal{N}(\mu, \sigma^2)$ . Der ML-Schätzer für  $\vartheta = (\mu, \sigma^2)$  ist gegeben durch

$$T_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}_n,$$

$$T_2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_n)^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - (\bar{X}_n)^2.$$

Der Schätzer  $T = (T_1, T_2)$  im obigen Beispiel ist ganz allgemein auch der sogenannte **Momentenschätzer** für

$$(E_\vartheta[X], \text{Var}_\vartheta[X])$$

in jedem Modell  $P_\vartheta$ , wo  $X_1, \dots, X_n$  i.i.d. sind.

Für eine Funktion  $h : \Theta \rightarrow \mathbb{R}^d$  wollen wir die  $d$  Grössen  $h_j(\vartheta)$ ,  $j = 1, \dots, d$ , schätzen. Um den **Momentenschätzer** für  $h(\vartheta)$  zu bestimmen, gehen wir in der Regel wie folgt vor:

1. Für  $j = 1, \dots, d$  berechnen wir in jedem Modell  $P_\vartheta$  das  $j$ -te Moment  $m_j(\vartheta) = E_\vartheta[X^j]$  als Funktion des Parameters  $\vartheta$ .

2. Für  $j = 1, \dots, d$  definieren wir das  $j$ -te **empirische Mittel** oder **Stichprobenmittel** als

$$\tilde{m}_j(x_1, \dots, x_n) := \frac{1}{n} \sum_{i=1}^n x : i^j.$$

3. Wir betrachten das System von  $d$  Gleichungen  $\tilde{m}_j(x_1, \dots, x_n) = m_j(\vartheta)$ , und fassen das auf als ein Gleichungssystem für die  $d$  Unbekannten  $h_1(\vartheta), \dots, h_d(\vartheta)$ . Falls eine eindeutige Lösung existiert, so nennen wir diese  $t_{MM}(x_1, \dots, x_n)$ . Der Momentenschätzer für  $h(\vartheta)$  ist dann definiert durch  $T_{MM} := t_{MM}(X_1, \dots, X_n)$ .

### 6.3 Verteilungsaussagen

**Satz:** Seien  $X_1, \dots, X_n$  i.i.d.  $\sim \mathcal{N}(\mu, \sigma^2)$ . Dann gilt:

- $\bar{X}_n$  ist normalverteilt gemäss  $\mathcal{N}(\mu, \frac{1}{n}\sigma^2)$ , und damit gilt  $\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$ .
- $\frac{n-1}{\sigma^2} S^2 = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \bar{X}_n)^2$  ist  $\chi^2$ -verteilt mit  $n-1$  Freiheitsgraden.
- $\bar{X}_n$  und  $S^2$  sind unabhängig.
- Der Quotient

$$\frac{\bar{X}_n - \mu}{S/\sqrt{n}} = \frac{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}}{\frac{S}{\sigma}} = \frac{\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}}{\sqrt{\frac{1}{n-1} \frac{n-1}{\sigma^2} S^2}}$$

ist  $t$ -verteilt mit  $n-1$  Freiheitsgraden.

## 7 Tests

### 7.1 Grundbegriffe

Wie im letzten Abschnitt betrachten wir eine Stichprobe  $X_1, \dots, X_n$  sowie eine Familie von Wahrscheinlichkeiten  $P_\vartheta$  mit  $\vartheta \in \Theta$ . Wir haben nun eine Vermutung, wo in  $\Theta$  der richtige Parameter  $\vartheta$  liegen könnte, wollen diese aber mit Hilfe der Daten überprüfen. Das Grundproblem ist also, eine Entscheidung zwischen zwei konkurrierenden Modellklassen zu treffen - der **Hypothese**  $\Theta_0 \subseteq \Theta$  und der **Alternative**  $\Theta_A \subseteq \Theta$ , wobei  $\Theta_0 \cap \Theta_A = \emptyset$ . Meist schreibt man das als:

Hypothese  $H_0 : \vartheta \in \Theta_0$ ,

Alternative  $H_A : \vartheta \in \Theta_A$ .

**Def:** Ein **Test** ist allgemein eine Entscheidungsregel, die zu gegebenen Daten  $X_1, \dots, X_n$  einen von zwei Werten liefert. Dabei nimmt man als die zwei Werte 0 und 1, und man interpretiert den Wert 1 als die Entscheidung, die Hypothese  $H_0$  abzulehnen.

Konkreter sieht die Entscheidungsregel meist folgendermassen aus. Man hat eine Abbildung  $t : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $(x_1, \dots, x_n) \rightarrow t(x_1, \dots, x_n)$ , und einen **kritischen Bereich** oder **Verwerfungsbereich**  $K \subseteq \mathbb{R}$ .

Die Zufallsvariable  $T = t(X_1, \dots, X_n)$  heisst dann **Teststatistik**. Die Entscheidungsregel ist  $I_{\{t(x_1, \dots, x_n) \in K\}}$ , d.h. man verwirft die Hypothese genau dann, wenn der realisierte Wert  $t(x_1, \dots, x_n) = t(X_1(\omega), \dots, X_n(\omega)) = T(\omega)$  im Verwerfungsbereich  $K$  liegt.

Die Entscheidung bei einem Test kann auf zwei verschiedene Arten falsch herauskommen:

- Fehler 1. Art:** Die Hypothese wird zu unrecht abgelehnt. Das passiert für  $\vartheta \in \Theta_0$  und  $T \in K$ . Deshalb heisst  $P_\vartheta[T \in K]$  für  $\vartheta \in \Theta_0$  die Wahrscheinlichkeit für einen Fehler 1. Art.
- Fehler 2. Art:** Die Hypothese wird zu Unrecht akzeptiert. Das passiert für  $\vartheta \in \Theta_A$  und  $T \notin K$ , und deshalb heisst  $P_\vartheta[T \notin K] = 1 - P_\vartheta[T \in K]$  für  $\vartheta \in \Theta_A$  die Wahrscheinlichkeit für einen Fehler 2. Art.

Weil ein gleichzeitige Minimieren auf  $\Theta_0$  und Maximieren auf  $\Theta_A$  der Fehlerwahrscheinlichkeit in der Regel grundsätzlich nicht möglich ist, hat sich folgendes zweistufiges Vorgehen durchgesetzt:

- Man wählt zuerst ein **Signifikanzniveau**  $\alpha \in (0, 1)$  und sorgt zunächst für

$$\sup_{\vartheta \in \Theta_0} P_\vartheta[T \in K] \leq \alpha,$$

d.h. man kontrolliert die Wahrscheinlichkeit für einen Fehler 1. Art durch  $\alpha$ .

- Anschliessend versucht man, die **Macht** der Tests, die Funktion

$$\beta : \Theta_A \rightarrow [0, 1], \quad \vartheta \rightarrow \beta(\vartheta) := P[T \in K],$$

möglichst gross zu bekommen. Das heisst, man versucht die Grösse  $1 - \beta(\vartheta) = P_\vartheta[T \notin K]$  für  $\vartheta \in \Theta_A$ , also die Wahrscheinlichkeit für einen Fehler 2. Art, möglichst klein zu bekommen.

**Bmk:** Bei einer diskreten Teststatistik  $T$  kann ein vorgegebenes Niveau  $\alpha$  in der Regel nicht eingehalten werden, d.h. es ist unmöglich, einen kritischen Bereich  $K$  mit  $P_\vartheta[T \in K] = \alpha$  zu finden. Einen Ausweg bietet ein sogenannter **randomisierter Test**. Man wählt dazu  $\gamma \in [0, 1]$  so, dass gilt  $\gamma P_{\vartheta_0}[T > c] + (1 - \gamma) P_{\vartheta_0}[T > c + 1] = \alpha$  und entscheidet wie folgt: Ist  $T > c$ , so verwirft man  $H_0$  mit Wahrscheinlichkeit  $\gamma$ , d.h.  $H_0$  wird abgelehnt, falls erstens  $T > c$  gilt und zweitens eine unabhängige  $\mathcal{U}(0, 1)$ -verteilte Zufallsvariable einen Wert  $\leq \gamma$  realisiert.

### 7.2 Konstruktion von Tests

Der folgende systematische Ansatz führt in vielen Situationen zu einem optimalen Test. Sei  $L(x_1, \dots, x_n; \vartheta)$  die Likelihood-Funktion. Für diskrete  $X_i$  ist also im Modell  $P_\vartheta$  die Wahrscheinlichkeit  $P_\vartheta[X_1 = x_1, \dots, X_n = x_n]$ , die beobachteten Werte  $x_1, \dots, x_n$  zu erhalten. Für  $\vartheta_0 \in \Theta_0$  und  $\vartheta_A \in \Theta_A$  betrachten wir den **Likelihood-Quotienten**

$$R(x_1, \dots, x_n; \vartheta_0, \vartheta_A) := \frac{L(x_1, \dots, x_n; \vartheta_A)}{L(x_1, \dots, x_n; \vartheta_0)}.$$

Ist der Quotient gross, dann sind die Beobachtungen  $x_1, \dots, x_n$  als Resultate im Modell  $P_{\vartheta_A}$  deutlich wahrscheinlicher als im Modell  $P_{\vartheta_0}$ .

**Satz (Neyman-Pearson-Lemma):** Sei  $\Theta_0 = \{\vartheta_0\}$  und  $\Theta_A = \{\vartheta_A\}$ . Sei  $T := R(X_1, \dots, X_n; \vartheta_0, \vartheta_A)$  und  $L := (c, \infty)$  sowie  $\alpha^* := P_{\vartheta_0}[T \in K] = P_{\vartheta_0}[T > c]$ . Der **Likelihood-Quotienten-Test** mit Teststatistik  $T$  und kritischem Bereich  $K$  ist dann im folgenden Sinn optimal: Jeder andere Test mit Signifikanzniveau  $\alpha \leq \alpha^*$  hat kleinere Macht bzw. eine grössere Wahrscheinlichkeit für einen Fehler 2. Art.

### 7.3 Der p-Wert

Wir haben folgende Situation: Sei  $X_1, \dots, X_n$  eine Stichprobe vom Umfang  $n$ . Wir wollen eine Hypothese  $H_0 : \vartheta = \vartheta_0$  gegen eine Alternative  $H_A : \vartheta \in \Theta_A$  testen. Wir nennen  $T = t(X_1, \dots, X_n)$  die Teststatistik und  $K$  den kritischen Bereich zum fixierten Niveau  $\alpha$ . Seien  $x_i = X(\omega)$ ,  $i = 1, \dots, n$ , die realisierten Daten. Bei einem Test zum Niveau  $\alpha$  wird dann also die Hypothese abgelehnt, wenn  $T(\omega) = t(x_1, \dots, x_n)$  einen Wert in  $K$  ergibt, und wir haben  $P_{\vartheta_0}[T \in K] \leq \alpha$ .

**Def:** Alternativ zum obigen Vorgehen kann man auch den sogenannten **p-Wert** berechnen. Das ist die Wahrscheinlichkeit, unter der Hypothese  $H_0$  einen mindest so extremen Wert für  $T$  zu bekommen wie den Wert  $T(\omega)$  aus der Stichprobe. "Extrem" bezieht sich dabei auf die Alternative - ist also beispielsweise  $H_A : \vartheta > \vartheta_0$  und entspricht das einem grossen Wert von  $T$ , so ist

$$p\text{-Wert}(\omega) = P_{\vartheta_0}[T > t_0] |_{t_0 = t(x_1(\omega), \dots, x_n(\omega))},$$

d.h. wir berechnen die Wahrscheinlichkeit  $t_0 \rightarrow P_{\vartheta_0}[T > t_0]$  als Funktion von  $t_0$  und setzen dann für  $t_0$  den zufälligen Wert  $T(\omega)$  ein.

### 7.4 z-Test

Test für den Erwartungswert einer Normalverteilung mit bekannter Varianz der Grundgesamtheit. Seien also  $X_1, \dots, X_n \sim \mathcal{N}(\theta, \sigma^2)$ -verteilt (i.i.d.) für bekanntes  $\sigma > 0$ .

- Hypothese:**  $H_0 : \theta = \theta_0$
- Teststatistik:**

$$T = \frac{\bar{X}_n - \theta_0}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1) \quad \text{unter } P_{\theta_0}$$

- Kritische Bereiche** (zum Signifikanzniveau  $\alpha \in (0, 1)$ ) kann an Tabelle abgelesen werden:

Alternative $H_A$	Kritischer Bereich
$\theta < \theta_0$	$(-\infty, z_\alpha)$
$\theta > \theta_0$	$(z_{1-\alpha}, \infty)$
$\theta \neq \theta_0$	$(-\infty, z_{\alpha/2}) \cup (z_{1-\alpha/2}, \infty)$

Dabei bezeichnet  $z_\alpha$  das  $\alpha$ -Quantil der Standardnormalverteilung. Man findet es, indem man in der Tabelle der

Standardnormalverteilung nach  $\Phi^{-1}(\alpha)$  sucht. Aus Symmetriegründen gilt  $z_\alpha = -z_{1-\alpha}$ .

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

### Rezept Fehler 2. Art berechnen:

Nehme an: einseitiger z-Test,  $T = \frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}}$ ,  $\mu_0 = 70$

$H_0 : \mu = \mu_0$ ;  $H_A : \mu < \mu_0$ .

Kritischer Bereich mit 5%-Niveau:  $K = (-\infty, -1.645)$

Objective: Fehler 2. Art finden für  $\mu_A = 69.5$ . Wir nehmen an, dass

$T = \frac{\bar{X}_n - \mu_A}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$  unter  $P_{\mu_A}$

$$\begin{aligned} \text{Fehler 2. Art} &= P_{\mu_A}[T \notin K] \\ &= P_{\mu_A}[T > -1.645] \\ &= P_{\mu_A}\left[\frac{\bar{X}_n - \mu_0}{\sigma/\sqrt{n}} > -1.645\right] \\ &= P_{\mu_A}\left[\frac{\bar{X}_n - \mu_A}{\sigma/\sqrt{n}} > \frac{\mu_0 - \mu_A}{\sigma/\sqrt{n}} - 1.645\right] \\ &= 1 - P_{\mu_A}\left[\frac{\bar{X}_n - \mu_A}{\sigma/\sqrt{n}} \leq \frac{\mu_0 - \mu_A}{\sigma/\sqrt{n}} - 1.645\right] \\ &= 1 - \Phi\left(\frac{\mu_0 - \mu_A}{\sigma - \sqrt{n}} - 1.645\right) \quad \text{weil } \sim \mathcal{N}(0, 1) \end{aligned}$$

## 7.5 t-Test

Test für den Erwartungswert einer Normalverteilung mit unbekannter Varianz. Seien also  $X_1, \dots, X_n \sim \mathcal{N}(\mu, \sigma^2)$ -verteilt (i.i.d.) für unbekanntes  $\sigma > 0$ .

- **Hypothese:**  $H_0 : \mu = \mu_0$ . Formal präziser wäre  $\Theta_0 = \{\theta = (\mu_0, \sigma), \sigma > 0\}$
- **Teststatistik:**  $T = \frac{\bar{X}_n - \mu_0}{S/\sqrt{n}} \sim t_{n-1}$  unter  $P_{\mu_0}$ , wobei  $S^2 :=$  empirische Stichprobenvarianz
- **Kritische Bereiche** (zum Signifikanzniveau  $\alpha \in (0, 1)$ ) kann aus Tabelle abgelesen werden:

Alternative $H_A$	Kritischer Bereich
$\mu < \mu_0$	$(-\infty, t_{n-1, \alpha})$
$\mu \neq \mu_0$	$(-\infty, t_{n-1, \alpha/2}) \cup (t_{n-1, 1-\alpha/2}, \infty)$

Dabei bezeichnet  $t_{m, \alpha}$  das  $\alpha$ -Quantil der  $t_m$ -Verteilung. Aus Symmetriegründen gilt  $t_{m, \alpha} = -t_{m, 1-\alpha}$ :

$$\int_{-\infty}^{t_{m, \alpha}} f_m(x) dx = \alpha$$

wobei  $f_m$  die Dichte der  $t_m$  Verteilung ist. Diesen Wert erhält man aus einer Tabelle zur  $t$ -Verteilung.

## 7.6 Gepaarte Zweistichproben-Tests für Normalverteilungen

Seien  $X_1, \dots, X_n, Y_1, \dots, Y_n$  Zufallsvariablen, so dass  $(X_i, Y_i)$  natürliche Paare bilden. Bezeichnen wir nun  $Z_i := X_i - Y_i$ .

- **bekannte Varianz:** Falls  $Z_1, \dots, Z_n \sim \mathcal{N}(\theta, \sigma^2)$  (i.i.d.) für bekanntes  $\sigma > 0$ , dann kann z-Test analog zu Kapitel 8.3 angewendet werden.
- **unbekannte Varianz:** Falls  $Z_1, \dots, Z_n \sim \mathcal{N}(\mu, \sigma^2)$  (i.i.d.) für unbekanntes  $\sigma > 0$ , dann kann t-Test analog zu Kapitel 8.4 angewendet werden.

## 7.7 Ungepaarte Zweistichproben-Tests für Normalverteilungen

Seien  $X_1, \dots, X_n \sim \mathcal{N}(\mu_X, \sigma_X^2)$  (i.i.d.) und  $Y_1, \dots, Y_m \sim \mathcal{N}(\mu_Y, \sigma_Y^2)$  (i.i.d.), so dass alle  $X_i, Y_j$  unabhängig.

### 7.7.1 Normalverteilungen mit bekannten Varianzen

Seien also  $\sigma_X, \sigma_Y$  bekannt.

- **Hypothese:**  $H_0 : \mu_X - \mu_Y = \mu_0$  (bspw.  $\mu_0 = 0$ )
- **Teststatistik:**

$$T = \frac{\bar{X}_n - \bar{Y}_m - \mu_0}{\sqrt{\frac{\sigma_X^2}{n} + \frac{\sigma_Y^2}{m}}} \sim \mathcal{N}(0, 1) \quad \text{für } P_{\mu_0}$$

Die kritischen Bereiche zum Signifikanzniveau sind analog zur Tabelle aus Kapitel 8.3.

### 7.7.2 Normalverteilungen mit unbekanntem aber gleichen Varianzen

Sei also  $\sigma_X = \sigma_Y = \sigma$  für  $\sigma > 0$  unbekannt.

- **Hypothese:**  $\mu_X - \mu_Y = \mu_0$  (bspw.  $\mu_0 = 0$ )
- **Teststatistik:**

$$T = \frac{\bar{X}_n - \bar{Y}_m - \mu_0}{S \sqrt{\frac{1}{n} + \frac{1}{m}}} \sim t_{n+m-2} \quad \text{unter } P_{\mu_0}$$

- **Kritische Bereiche:** analog zu Tabelle aus Kapitel 8.4, jedoch ist nun die Anzahl der Freiheitsgrade  $n + m - 2$  und nicht mehr  $n - 1$ .

Dabei benutzen wir für die Varianz ein gewichtetes Mittel aus den Stichprobenvarianzen  $S_X, S_Y$ , definiert als

$$S^2 := \frac{(n-1)S_X^2 + (m-1)S_Y^2}{n+m-2}$$

## 8 Konfidenzbereiche

**Def:** Formal ist ein realisierter **Konfidenzbereich** für  $\vartheta$  zu Daten  $x_1, \dots, x_n$  eine Menge  $C(x_1, \dots, x_n) \subseteq \Theta$ . In den meisten Fällen ist

das ein Intervall, dessen Endpunkte von  $x_1, \dots, x_n$  abhängen. Ersetzen wir die Daten  $x_1, \dots, x_n$  durch die sie generierenden Zufallsvariablen, so ist  $\tilde{C}(\omega) := C(X_1, \dots, X_n)$  also eine zufällige Teilmenge von  $\Theta$ , mit Realisierung  $\hat{C}(\omega) = C(X_1(\omega), \dots, X_n(\omega))$  bei einem festen  $\omega$ . Ein solches  $C$  heisst Konfidenzbereich zum Niveau  $1 - \alpha$ , falls gilt:

$$P_\vartheta[C(X_1, \dots, X_n) \ni \vartheta] \geq 1 - \alpha \quad \text{für alle } \vartheta \in \Theta,$$

d.h. in jedem Modell erwischt man den Parameter mit grosser Wahrscheinlichkeit.

## 9 Nice To Know

### 9.1 Ableitung, Integration

- **Summenregel**  $(f(x) + g(x))' = f'(x) + g'(x)$
- **Produktregel**  $(f(x) \cdot g(x))' = f'(x)g(x) + f(x)g'(x)$
- **Quotientenregel**  $\left(\frac{f(x)}{g(x)}\right)' = \frac{f'(x)g(x) - f(x)g'(x)}{g^2(x)}$  ( $g \neq 0$ )
- **Kettenregel**  $(f(g(x)))' = (f \circ g)' = f'(g(x))g'(x)$
- **Partielle Integration:**  $\int_a^b f'(x) \cdot g(x) dx = [f(x)g(x)]_a^b - \int_a^b f(x)g'(x)$
- **Substitution:**  $\int_{\phi(a)}^{\phi(b)} f(x) dx = \int_a^b f(\phi(t))\phi'(t) dt$
- $a + c, b + c \in I$   $\int_a^b f(t + c) dt = \int_{a+c}^{b+c} f(x) dx$
- $ca, cb \in I$ :  $\int_a^b f(ct) dt = \frac{1}{c} \int_a^b f(x) dx$
- **Logarithmus:**  $\int \frac{f'(t)}{f(t)} dt = \log(|f(x)|)$ , bzw.  $\int_a^b \frac{f'(t)}{f(t)} dt = \log(f(b)) - \log(f(a))$

### 9.2 Schätzer Rezepte

#### 9.2.1 Maximum Likelihood Schätzer

- Likelihood-Funktion  $L$  bestimmen
- Falls Zufallsvariablen i.i.d., dann  $\log L$  bestimmen
- $\log L$  (oder  $L$ ) maximieren: ableiten von  $\log L$  (oder  $L$ ) und gleich 0 setzen.
- $\Rightarrow$  Funktion, die Parameter schätzt

#### 9.2.2 Momentenschätzer mit zentralen/rohen Momenten

$k$ -tes rohes Moment:  $E[X^k]$

$k$ -tes empirisches  $\tilde{\cdot}$ :  $\frac{1}{n} \sum_{i=1}^n x_i^k$

$k$ -tes zentrales Moment:  $E[(X - E[X])^k]$

1. theoretisches  $\tilde{\cdot} = E[X]$ , 2. theoretisches  $\tilde{\cdot} = \text{Var}[X]$

1. empirisches  $\tilde{\cdot} = \bar{X}$ , 2. empirisches  $\tilde{\cdot} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ ,  $k$ -tes empirisches  $\tilde{\cdot}$ :  $\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k$

### 9.3 Zusammenhänge Tests

Zusammenhänge  $\alpha$  (Signifikanzniveau), Fehler 1. Art,  $\beta$  (Macht), Fehler 2. Art ( $1 - \beta$ )

- $\alpha$  grösser  $\iff$  Fehler 1. Art grösser  $\iff$  Fehler 2. Art kleiner  $\iff$  Macht grösser
- $\alpha$  kleiner  $\iff$  Fehler 1. Art kleiner  $\iff$  Fehler 2. Art



größer  $\iff$  Macht kleiner

## 9.4 Beispiel p-Wert

Beispiel: Hintergrundfarbe einer Webseite ändern und schauen, ob sich die Besuchsdauer von Nutzern verändern.

$$\mu = 20$$

- Nullhypothese  $H_0: \mu = 20$  nach der Änderung
- Alternative  $H_A: \mu > 20$  nach der Änderung
- Signifikanzniveau:  $\alpha = 0.05$
- Stichprobe:  $n = 100, \bar{X} = 25, (\sigma)$
- p-Wert:  $P[\bar{X} \geq 25 | H_0 \text{ ist wahr}]$
- Falls p-Wert  $< \alpha$ :  $H_0$  verwerfen (und  $H_A$  akzeptieren)
- Falls p-Wert  $\geq \alpha$ :  $H_0$  nicht verwerfen (keine Aussage)

Der p-Wert ist **nicht**  $P[H_0 \text{ ist wahr} | \text{Stichprobe}]$

## 9.5 Begriffe Tests

Modell: z.B. Unter  $P_\varphi$  sind die  $X_i$  i.i.d.  $\sim \text{Poi}(\lambda), i = 1, \dots, 6, \lambda$  unbekannt.

Teststatistik: Hilfsfunktion bei statistischen Tests. Kann zum Beispiel mittels Likelihood-Quotienten-Vorgehen gefunden werden.

**Punkte;** Beispiel jeweils in Klammern:

- Modell (Unter  $P_\vartheta$  sind die  $X_i$  i.i.d.  $\sim \text{Poi}(\dots)$ )
- Nullhypothese ( $H_0: p = \dots$ )
- Alternativhypothese ( $H_A: p < \dots$ )
- Teststatistik ( $T = \langle R \rangle$  also Likelihood-Quotienten verwenden)
- Verteilung der Teststatistik unter der Nullhypothese ( $H_0: T \sim \text{Bin}(\dots)$ )
- Verwerfungsbereich ( $K = [a, b], P_{\vartheta_0}[T \in K] \leq 5\% \dots$ )
- beobachteter Wert der Teststatistik ( $t = T(\omega) = 6$ )
- Testentscheid (Nullhypothese wird nicht verworfen...)
- eventuell p-Wert

### Wichtig:

Falls beobachtetes Ergebnis im Verwerfungsbereich:  $H_0$  wird abgelehnt,  $H_A$  wird angenommen.

Falls beobachtetes Ergebnis nicht im Verwerfungsbereich:  $H_0$  wird nicht abgelehnt (keine Aussage über Annahme!), keine Aussage über  $H_A$

**p-Wert:** kleinstes Niveau, auf dem der Test die Nullhypothese noch verwirft.

Auch: Falls  $H_0: p = 123, H_A: p < 123$  Mit Statistik  $P_{H_0}[T \leq \text{Beobachteter Wert}]$ . p-Wert ist so wie die Signifikanz des Testresultats.

## 9.6 Summenformeln

- $\sum_{i=1}^n i = \frac{n(n+1)}{2}$
- $\sum_{i=0}^n k^i = \frac{1-k^{n+1}}{1-k}$
- $\sum_{i=1}^n i^2 = \frac{n(n+1)(2n+1)}{6}$

- $\sum_{i=1}^n i^3 = \frac{n^2(n+1)^2}{4}$
- $(a+b)^n = \sum_{k=0}^n \binom{n}{k} a^{n-k} b^k$

## 10 Exercises

### 10.1 Aufgabe 1 - Multiple Choice

1) Münze (fair) wird 2x geworfen. Für  $i = 1, 2$  sei  $K_i$  das Ereignis, dass beim  $i$ -ten Wurf Kopf erscheint. Dann gilt:

1.  $K_1$  und  $K_2$  unabhängig.
2.  $K_1$  und  $K_2$  disjunkt.
3.  $K_1$  und  $K_2$  unabhängig und  $K_1 \cup K_2 = \Omega$

$K_1 = \{(K, K), (K, Z)\}$  und  $K_2 = \{(K, K), (Z, K)\}$ , daher sind 2 und 3 falsch. 1 richtig da  $P[K_1 \cap K_2] = P[K_1] \cdot P[K_2]$ .

2)  $A$  und  $B$  Ereignisse mit  $P[A] > 0$  und  $A \cap B = \emptyset$ .  $P[B|A] = 0$  ist

1. wahr.
2. nicht wahr.

$$P[B|A] = \frac{P[A \cap B]}{P[A]} = \frac{0}{P[A]} = 0.$$

3) Untersuchung einer Bodenprobe auf Stoffe  $X$  und  $Y$ .  $A$ : "X in Probe",  $B$ : "Y in Probe". Es gilt  $P[A] = 0.1$  und  $P[B] = 0.3$ . Wir wissen, dass WHS, dass die Probe weder  $X$  noch  $Y$  enthält, ist 0.7. Dann:

1.  $P[A \cap B] = 0.03$
2.  $P[A \cap B] = 0.1$
3. Zu wenig Infos für  $P[A \cap B]$

Es gilt  $P[A \cap B] = P[A] + P[B] - P[A \cup B]$ . Es gilt  $P[A \cup B] = 1 - P[(A \cup B)^C] = 1 - 0.7 = 0.3$ . Nun gilt  $P[A \cap B] = 0.1 + 0.3 - 0.3 = 0.1$

4) Sei  $X$  eine ZV mit  $E[X] = 2, \text{Var}[X] = 3$ . Dann gilt:

1.  $E[X^2] = 4$
2.  $E[X^2] = 7$
3. Zu wenig Infos um  $E[X^2]$  zu berechnen.

Es gilt  $\text{Var}[X] = E[X^2] - (E[X])^2 \Rightarrow E[X^2] = \text{Var}[X] + (E[X])^2 = 3 + 4 = 7$ .

5) Wie oft einen fairen Würfel im Schnitt werfen bis eine 3 kommt?

1. 6 mal
2. 6<sup>6</sup> mal
3. 6! mal

Sei  $X$  die Anzahl versuche, bis eine 3 erscheint. Dann ist  $X \sim \text{Geom}(\frac{1}{6})$ . Es gilt  $E[X] = \frac{1}{p} = 6$ .

6) Sei  $X$  eine ZV mit Verteilungsfunktion

$$F_X(x) = \begin{cases} 1 - e^{-cx}, & x \geq 0, \\ 0, & x < 0, \end{cases}$$

für ein  $c > 0$ . Der Median (d.h.  $F_X^{-1}(\frac{1}{2})$ ) beträgt:

1.  $\frac{1}{2}$
2.  $\frac{1}{c} \ln 2$
3.  $1 - e^{-\frac{1}{2}c}$

$$y = 1 - e^{-cx} \Rightarrow \ln y = \ln(1 - e^{-cx}) = \frac{\ln 1}{\ln e^{-cx}} = \frac{\ln 1}{-cx \ln e} = \frac{\ln 1}{-cx} \Rightarrow -cx \ln y = \ln 1 \Rightarrow x = \frac{\ln 1}{-c \ln y} = -\frac{1}{c} \ln(1 - y) = F_X^{-1}(y).$$

Dann ist  $F_X^{-1}(\frac{1}{2}) = -\frac{1}{c} \ln(1 - \frac{1}{2}) = -\frac{1}{c} \ln \frac{1}{2} = -\frac{1}{c} \ln 2^{-1} = \frac{1}{c} \ln 2$ .

7) Seien 10% der Menschen Raucher.  $X$  sei die Anzahl Raucher unter 100 zufällig gewählten Personen. Wie gross ist die Standardabweichung von  $X$ ?

1. 3
2.  $\sqrt{10}$
3. 10

Es gilt  $X \sim \text{Bin}(100, 0.1)$ . Die Standardabweichung ist gegeben durch  $\sqrt{\text{Var}[X]}$ , und  $\text{Var}[X]$  für  $X \sim \text{Bin}(n, p)$  ist  $np(1-p) = 100 \cdot 0.1(1-0.1) = 9$  und daher ist  $\sqrt{\text{Var}[X]} = 3$ .

8)  $X$  und  $Y$  zwei ZV die lognormalverteilt und unabhängig sind, d.h.  $\ln X$  und  $\ln Y$  sind normalverteilt. Dann gilt:

1.  $XY$  ist lognormalverteilt
2.  $XY$  ist normalverteilt
3.  $e^{x+y}$  ist normalverteilt

Da  $\ln XY = \ln X + \ln Y$  gilt, ist  $\ln XY$  als Summe unabhängiger normalverteilter ZV ebenfalls normalverteilt und daher ist  $XY$  lognormalverteilt.

9) Die stetige Zufallsvariable  $X$  habe die kumulative Verteilungsfunktion

$$F(x) = 1 - e^{-2x}, \quad x \geq 0.$$

Welche der folgenden Aussagen ist richtig?

1. Die Dichte von  $X$  ist  $f(x) = 2xe^{-2x}, x \geq 0$
2.  $P[X \geq 0.5] = e^{-0.5}$
3.  $P[X = 1] = 1 - e^{-2}$
4. Für  $Y = 2X$  gilt  $P[Y \leq 2] = 1 - e^{-2}$

1. Falsch. Dichte ist (Verteilungsfunktion)'.  $(1 - e^{-2x})' = (-e^{-2x})' = -1 \cdot (-2x)' \cdot (e^{-2x}) = 2e^{-2x}$ . 2. Falsch.  $P[X \geq 0.5] = 1 - P[X < 0.5] = 1 - F(0.5) = 1 - (1 - e^{-2 \cdot 0.5}) = e^{-1}$ . 3. Falsch. Für stetige Verteilungen gilt  $P[X = x] = 0$  für alle  $x$ . Dies ist weil  $P[X = x] = P[x \geq X \geq x]$ , was einem Integral von  $x$  nach  $x$  gleicht. 4. Richtig.  $P[Y \leq 2] = P[2X \leq 2] = P[X \leq 1] = 1 - e^{-2 \cdot 1} = 1 - e^{-2}$ .

10) Bei der Berechnung des realisierten p-Wertes eines Tests

1. muss man wissen, ob der Test einseitig oder zweiseitig ist.
2. braucht man die konkreten Daten nicht.
3. muss man das Signifikanzniveau  $\alpha$  kennen.

1. Man muss wissen, was es bedeutet, dass die Teststatistik  $T$  einen extremen Wert als den beobachteten Wert  $t = T(\omega)$  annimmt. Bei zweiseitigen Tests betrachtet man daher das Ereignis  $\{|T| < (>) t\}$ , während dies für einseitige Tests  $\{T < (>) t\}$  ist. 11) Seien  $A$  und  $B$  zwei Ereignisse. Die Aussage  $P[A^C \cap B^C] = 1 - P[A \cap B]$  ist:

1. wahr
2. nicht wahr

2. Es gilt  $P[A^C \cap B^C] = 1 - P[(A^C \cap B^C)^C] = P[A \cup B]$ .

12) Seien  $A$  und  $B$  zwei Ereignisse. Das Additionsgesetz  $P[A \cup B] = P[A] + P[B]$  gilt, falls:

1.  $A$  und  $B$  unabhängig sind
2.  $A$  und  $B$  disjunkt sind.
3.  $A$  eine Teilmenge von  $B$  ist.

2. Die ganze Formel ist  $P[A \cup B] + P[A \cap B] = P[A] + P[B]$ , wenn nun  $A$  und  $B$  disjunkt sind, dann ist  $P[A \cap B] = 0$  und die obige Formel gilt.

12) Wir betrachten einen Labortest für eine Krankheit. Sei  $A$  das Ereignis, dass eine getestete Person die Krankheit hat. Sei  $B$  das Ereignis, dass der Test positiv ist. Man weiss  $P[B|A] = 0.99$  und  $P[B^C|A^C] = 0.995$ . Der Anteil der Bevölkerung, der die Krankheit hat, ist 0.1%. Wie gross ist die WHS, dass eine zufällig gewählte Person mit einem positiven Test tatsächlich die Krankheit hat?

1.  $P[A|B] \simeq 0.065$
2.  $P[A|B] \simeq \mathbf{0.165}$
3.  $P[A|B] \simeq 0.560$

2. Nach dem Satz von Bayes gilt:

$$P[A|B] = \frac{P[B|A] \cdot P[A]}{P[B|A] \cdot P[A] + P[B|A^C] \cdot P[A^C]} = \frac{0.99 \cdot 0.001}{0.99 \cdot 0.001 + (1 - 0.995) \cdot 0.999} \simeq 0.165$$

13) Seien  $X$  und  $Y$  unkorrelierte ZV mit Varianzen  $\text{Var}[X] = 2$  und  $\text{Var}[Y] = 3$ . Wie gross ist die Varianz von  $Z = 7X - 2Y$ ?

1. 86
2. **110**
3. 8

2. Es gilt  $\text{Var}[aX + b] = a^2 \text{Var}[X]$ . Daher ist  $\text{Var}[7X - 2Y] = 7^2 \text{Var}[X] + (-2)^2 \text{Var}[Y] = 49 \cdot 2 + 4 \cdot 3 = 110$ .

14) Ein fairer Würfel wird 1800mal geworfen. Die Zufallsvariable  $X$  sei die Anzahl der Würfe mit Augenzahl 6. Wie gross ist die Varianz von  $X$ ?

1. 1800
2. 300
3. **250**

3. Es gilt, dass  $x \sim \text{Bin}(1800, \frac{1}{6})$  ist. Daher ergibt sich  $\text{Var}[X] = 1800 \cdot \frac{1}{6} \cdot \frac{5}{6} = 250$ .

15) Seien  $X \sim \mathcal{N}(0, 1)$  und  $Y \sim \text{Unif}(0, 1)$  ZV mit  $\text{Cov}(X, Y) = 0$ . Was ist korrekt?

1.  $X$  und  $Y$  sind unabhängig
2.  $E[\mathbf{XY}] = \mathbf{0}$
3. Keine der Aussagen trifft zu.

2. Da  $X \sim \mathcal{N}(0, 1)$  ist, gilt  $E[X] = 0$ . Mit  $0 = \text{Cov}(X, Y) = E[XY] - E[X]E[Y]$  gilt  $E[XY] = 0$ . Die beiden ZV sind zwar unkorreliert, müssen aber nicht unbedingt unabhängig sein.

16) Seien  $X$  und  $Y$  unabhängig und identisch  $\text{Poi}(\frac{9}{2})$  verteilt. Wie gross ist die Standardabweichung der Zufallsvariablen  $X + Y$ ?

1. **3**
2.  $\frac{9}{2}$
3.  $\sqrt{\frac{9}{2}}$

1. Da  $X$  und  $Y$  sind, gilt  $\text{Var}[X+Y] = \text{Var}[X] + \text{Var}[Y] = \frac{9}{2} + \frac{9}{2} = 9$ . Daher ist  $\sqrt{\text{Var}[X+Y]} = \sqrt{9} = 3$ .

## 10.2 Aufgabe 2 - $\chi^2$ -Verteilung

Eine Zufallsvariable  $Y$  heisst  $\chi^2$ -verteilt mit Freiheitsgrad  $v \in \mathbb{N}$  ( $Y \sim \chi_v^2$ ), falls

$$Y = \sum_{k=1}^v Z_k^2,$$

wobei  $Z_1, \dots, Z_v$  i.i.d.  $\mathcal{N}(0, 1)$ -verteilt sind.

a) Zeige, dass  $E[Y] = v$  und  $\text{Var}[Y] = 2v$  gilt.

Für ganzzahlige Werte von  $v$  kann  $Y$  geschrieben werden als  $Y = \sum_{k=1}^v Z_k^2$  mit  $Z_1, \dots, Z_v$  i.i.d.  $\mathcal{N}(0, 1)$ . Daraus folgt einerseits:

$$E[Y] = \sum_{k=1}^v E[Z_k^2] = v \cdot 1 = v.$$

Andererseits ist wegen der Unabhängigkeit und identischen Verteilung der  $Z_k$ :

$$E[Y^2] = E[(Z_1^2 + Z_2^2 + \dots + Z_v^2)^2] = vE[Z_1^4] + v(v-1)(E[Z_1^2])^2,$$

oder alternativ

$$\text{Var}[Y] = \text{Var}\left[\sum_{k=1}^v Z_k^2\right] = \sum_{k=1}^v \text{Var}[Z_k^2] = v(E[Z_1^4] - (E[Z_1^2])^2).$$

Mit  $E[Z_1^2] = 1$  und

$$E[Z_1^4] = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} Y x^4 e^{-x^2/2} dx = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} Y x^3 x e^{-x^2/2} dx = \frac{1}{\sqrt{2\pi}} \left(-x^3 e^{-x^2/2}\right) \Big|_{-\infty}^{\infty} + \frac{3}{\sqrt{2\pi}} \int_{-\infty}^{\infty} Y x^2 e^{-x^2/2} dx = 3$$

erhalten wir schliesslich  $E[Y^2] = 3v + v(v-1) = v^2 + 2v$  und daraus  $\text{Var}[Y] = (v^2 + 2v) - v^2 = 2v$ , beziehungsweise

$$\text{Var}[Y] = v(3 - 1) = 2v.$$

b) Gib mit Hilfe der Chebyshev-Ungleichung eine untere Schranke für die Wahrscheinlichkeit

$$P\left[\left|\frac{Y}{v} - 1\right| \leq \frac{3}{4}\right]$$

an. Wie lautet der konkrete Wert der Schranke für  $v = 12$ ? Die Chebyshev-Ungleichung lautet  $P[|Y - v| > c] \leq \frac{\text{Var}[Y]}{c^2} = \frac{2v}{c^2}$ . Somit folgt:

$$P\left[\left|\frac{Y}{v} - 1\right| \leq \frac{3}{4}\right] = P\left[\left|\frac{Y - v}{v}\right| \leq \frac{3}{4}\right] = 1 - P\left[|Y - v| > \frac{3v}{4}\right] \geq 1 - \frac{2v}{9v^2/16} = 1 - \frac{32}{9v}.$$

Für  $v = 12$  erhalten wir somit:

$$P\left[\left|\frac{Y}{v} - 1\right| \leq \frac{3}{4}\right] = \frac{19}{27}.$$

c) Leite eine Annäherung für die obige Wahrscheinlichkeit mit Hilfe des zentralen Grenzwertsatzes her. Wie lautet der konkrete Wert der Approximation für  $v = 12$ ?

Die  $Y_i = Z_i^2$  sind i.i.d.  $\sim \chi_1^2$ , also ist  $E[Y_i] = 1$  und  $\text{Var}[Y_i] = 2$ ,  $i = 1, \dots, v$ . Der zentrale Grenzwertsatz für  $Y = \sum_{i=1}^v Y_i$  liefert

$$Z = \frac{Y - vE[Y_i]}{\sqrt{v\text{Var}[Y_i]}} = \frac{Y - v}{\sqrt{2v}} \sim_{\text{approx.}} \mathcal{N}(0, 1).$$

Eine Approximation der Wahrscheinlichkeit ergibt sich daher durch

$$P\left[\left|\frac{Y}{v} - 1\right| \leq \frac{3}{4}\right] = P\left[\left|\frac{Y - v}{v}\right| \leq \frac{3}{4}\right] = P\left[\left|\frac{Y - v}{\sqrt{2v}}\right| \leq \frac{3}{4}\sqrt{\frac{v}{2}}\right] \simeq \varphi\left(\frac{3}{4}\sqrt{\frac{v}{2}}\right) - \varphi\left(-\frac{3}{4}\sqrt{\frac{v}{2}}\right).$$

Für  $v = 12$  erhalten wir

$$P\left[\left|\frac{Y}{v} - 1\right| \leq \frac{3}{4}\right] \simeq \varphi\left(\frac{3}{4}\sqrt{6}\right) - \varphi\left(-\frac{3}{4}\sqrt{6}\right) = 2\varphi\left(\frac{3}{4}\sqrt{6}\right) - 1$$

und mit Hilfe der Abkürzung  $\sqrt{6} \simeq \sqrt{6.25} = 2.5$  folgt  $\frac{3}{4}\sqrt{6} \simeq \frac{15}{8} = 1.875$ , wodurch wir den konkreten Wert wie folgt erhalten:

$$P\left[\left|\frac{Y}{v} - 1\right| \leq \frac{3}{4}\right] \simeq 2\varphi(1.875) - 1 \simeq 2 \cdot 0.9696 - 1 = 0.9392.$$

## 10.3 Aufgabe 3 - Verteilung und Dichte

Peter und Hans sitzen pro Woche die zufälligen Zeiten  $P$  und  $H$  über ihren Stochastikserien. Peters Zeitaufwand  $P$  kann durch eine Uniform(0, 1)-verteilte Zufallsvariable beschrieben werden. Hans braucht gegeben Peters Zeit  $P$  die zufällige Zeit  $H$ , die uniform auf  $(0, P)$ -verteilt ist.

a) Bestimme die gemeinsame Dichte von  $H$  und  $P$ , und skizzieren den Bereich, auf dem die Dichte positiv ist.

Da  $P \sim \mathcal{U}(0, 1)$ , gilt  $f_P(p) = 1_{[0,1]}(p)$ . Da  $H|P \sim \mathcal{U}(0, P)$ , gilt  $f_{H|P}(h|p) = \frac{1}{p} 1_{[0,p]}(h)$  wobei für beide Dichtefunktionen gilt, dass  $1_{[a,b]} := 1$ , falls  $a \leq x \leq b$ , 0 sonst. Somit verschwindet  $f_{H|P}$  ausserhalb des Dreiecks

$$D := \{(p, h) \mid 0 < h < p \leq 1\}.$$

Für die gemeinsame Dichte von  $P$  und  $H$  ergibt sich:

$$f_{P,H}(p, h) = f_{H|P}(h|p)f_P(p) = \frac{1}{p} 1_{[0,p]}(p)$$

Der Bereich  $D$ , wo  $f_{H,P}$  positiv ist, bildet ein Dreieck von der  $x$ -Achse von 0 bis 1 und der Geraden  $x = y$ , ebenfalls von 0 bis 1.

b) Bestimmen Sie die Randdichte von  $H$ .

Die Randdichte von  $H$  berechnet sich für  $0 < h \leq 1$  als Integral über die gemeinsame Dichte, also

$$f_H(h) = \int_{-\infty}^{\infty} f_{P,H}(p, h) dp = \int_0^1 \frac{1}{p} 1_{[0,p]}(h) dp = \int_h^1 \frac{1}{p} dp = -\log h.$$

c) Bestimme den Erwartungswert von  $H$ . Vergleiche diesen mit dem Erwartungswert von  $P$ .

Mit partieller Integration folgt

$$\begin{aligned} E[H] &= - \int_0^1 h \log h \, dh = - \frac{h^2}{2} \log h \Big|_0^1 + \int_0^1 \frac{h^2}{2} \frac{1}{h} dh \\ &= 0 + \int_0^1 \frac{h^2}{2} \frac{1}{h} dh = \frac{h^2}{4} \Big|_0^1 = \frac{1}{4}. \end{aligned}$$

Andererseits ist  $E[P] = \frac{1}{2}$ , also  $E[H] = \frac{E[P]}{2}$ .

d) Bestimme die Kovarianz zwischen  $H$  und  $P$ . Sind  $H$  und  $P$  unabhängig?

Man hat

$$\begin{aligned} E[PH] &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} ph f_{P,H}(p, h) \, dh \, dp = \int_0^1 dp \int_0^p h \, dh \, dp \\ &= \int_0^1 \frac{p^2}{2} dp = \frac{1}{6}, \end{aligned}$$

und somit

$$\text{Cov}(P, H) = E[PH] - E[P]E[H] = \frac{1}{6} - \frac{1}{2} \cdot \frac{1}{4} = \frac{1}{24}.$$

Da  $\text{Cov}(P, H) \neq 0$  ist, sind  $H$  und  $P$  somit nicht unabhängig.

## 10.4 Aufgabe 4 - Test

Unterhalb einer Kläranlage wurden 16 unabhängige Wasserproben aus einem Fluss entnommen und jeweils deren Ammoniumkonzentration  $X_i$  (angegeben in  $\mu\text{gNH}_4\text{-N/l}$ ) mit einem Messgerät bestimmt. Der Mittelwert der Proben ergab  $\bar{x} = 204.2$ . Wir wollen wissen, ob mit diesem Experiment eine Überschreitung des Grenzwertes von  $200 \mu\text{gNH}_4\text{-N/l}$  nachgewiesen werden kann (auf dem 5%-Niveau).

a) Angenommen die Standardabweichung sei im Voraus bekannt und betrage  $10 \mu\text{gNH}_4\text{-N/l}$ . Finde einen geeigneten statistischen Test um zu prüfen, ob eine Grenzwertüberschreitung nachgewiesen werden kann. Wie lauten die Modellannahmen?

Da die Standardabweichung der Messungen bekannt ist, entscheiden wir uns für einen  $z$ -Test. Wir nehmen an, dass die Ammoniumkonzentrationen  $X_i$  unabhängig und identisch normalverteilt sind für  $i = 1, \dots, 16$ , mit  $\sigma^2 = 100$  und  $\mu$  unbekannt.

b) Führe den Test aus Punkt a) durch. Gib dazu folgendes explizit an:  $H_0$  und  $H_A$ , die Teststatistik, den realisierten Wert der Teststatistik, den Verwerfungsbereich sowie das Testergebnis.

- $H_0 : X_i$  i.i.d.,  $\sim \mathcal{N}(\mu_0, \sigma^2)$  mit  $\mu_0 = 200$ ,  $\sigma = 10$
- $H_A : X_i$  i.i.d.,  $\sim \mathcal{N}(\mu, \sigma^2)$  mit  $\mu > 200$ ,  $\sigma = 10$  (einseitig)

- Teststatistik:  $Z = \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$  unter  $H_0$
- Verwerfungsbereich: Wir suchen  $\mathcal{K} = \{z_{1-\alpha} \leq z\}$ , also der Bereich, wo  $H_0$  verworfen wird. Aus der Normalverteilungstabelle erhalten wir 1.64 für 0.9495 und 1.65 für .9505 (in unserem Fall ist  $z_{1-\alpha} = 1 - 0.05 = 0.95$ ), daher ist unser Verwerfungsbereich  $\mathcal{K} = [1.645, \infty)$
- Wert der Teststatistik:  $z = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{n}} = \frac{204.2 - 200}{10/\sqrt{16}} = \frac{4.2}{2.5} = 1.68$
- Testentscheid: Da  $1.68 \in \mathcal{K}$  wird die Nullhypothese  $H_0$  verworfen. Die Überschreitung des Grenzwertes ist auf dem 5%-Niveau signifikant.

c) Wir wahrscheinlich ist es, dass man mit 16 unabhängigen Wasserproben eine Grenzwertüberschreitung nachweisen kann, wenn die wahre Ammoniumkonzentration tatsächlich über dem Grenzwert und zwar bei  $205 \mu\text{gNH}_4\text{-N/l}$  liegt?

Wir fragen nach der Wahrscheinlichkeit, dass  $T \in \mathcal{K}$  mit  $\mu_A = 205 \mu\text{gNH}_4\text{-N/l}$ . Mit anderen Worten kann  $H_0$  verworfen werden, falls der Mittelwert der Messungen  $\bar{X} \geq 204.2$  (oder grösser 204.1) ist. Wir gehen dazu wieder zu einer standardisierten normalverteilten Zufallsvariable über. Mit  $\mu_A = 205$  und  $\sigma = 10$  erhält man

$$\begin{aligned} P_{\mu_A}[\bar{X} > 204.1] &= P_{\mu_A} \left[ \frac{\bar{X} - \mu_A}{\sigma/\sqrt{n}} > \frac{204.1 - \mu_A}{\sigma/\sqrt{n}} \right] \\ &= P_{\mu_A} \left[ \frac{\bar{X} - \mu_A}{\sigma/\sqrt{n}} > -0.36 \right] = P[Z > -0.36]. \end{aligned}$$

Diese Wahrscheinlichkeit ist wegen der Symmetrie der Normalverteilung gleich  $P[Z \leq 0.36]$ . Aus der Tabelle der Normalverteilungen entnehmen wir, dass dies gleich 0.6406 ist. Die gesuchte WHS (oder auch die Macht des Tests an der Stelle  $\mu = \mu_A = 205$ ) ist also ungefähr 64%.

d) Wir wahrscheinlich ist es, dass man mit 16 unabhängigen Wasserproben fälschlicherweise eine Grenzüberschreitung nachweist, obwohl die wahre Ammoniumkonzentration bei  $200 \mu\text{gNH}_4\text{-N/l}$  liegt und den Grenzwert somit genau einhält?

Das ist genau das Niveau des Tests und war mit 5% in der Aufgabenstellung gegeben.

## 10.5 Aufgabe 5 - Schätzer und p-Wert

Die WHS, dass an einem beliebigen Tag in einer Grosstadt erhöhte (d.h. einen kritischen Wert überschreitende) Schadstoffemissionen gemessen werden, sei  $p$ . Zusätzlich nehmen wir an, dass die Emissionshöhen an unterschiedlichen Tagen unabhängig sind.

a) Sei in einem Zeitraum von  $n$  Tagen  $X_n$  die Anzahl derjenigen Tage, an denen erhöhte Emissionswerte gemessen werden. Welche Verteilung hat  $X_n$ ? Wie lauten die Parameter der Verteilung?

$X_n \sim \text{Bin}(n, p)$ . Genau gesagt ist  $X_n = \sum_{i=1}^n B_i$ , wobei  $B_i \sim \text{Ber}(p)$  und i.i.d. und daher  $X \sim \text{Bin}(n, p)$ .

b) Innerhalb der letzten 345 Tage wurden an 207 Tagen erhöhte Emissionswerte gemessen. Finde zuerst einen vernünftigen Schätzer  $\hat{p}$  für  $p$  und bestimme unter einer Normalapproximation ein 99% - Vertrauensintervall für  $\hat{p}$ . Welche realisierten Ergebnisse findet man für Schätzwert und Vertrauensintervall?

Ein Schätzer für  $p$  ist  $\hat{p} = \frac{1}{n} X_n = \frac{207}{345} = \frac{69}{115} = \frac{3}{5} = 0.6$ . Laut Normalapproximation ist  $X_n \sim \text{approx} \mathcal{N}(np, np(1-p))$ , also

$$\hat{p} \sim \text{approx} \mathcal{N} \left( p, \frac{1}{n} p(1-p) \right)$$

und damit ein approximatives Vertrauensintervall gegeben durch

$$\hat{p} \pm \phi^{-1} \left( 1 - \frac{\alpha}{2} \right) \sqrt{\hat{p}(1-\hat{p}) \frac{1}{n}},$$

wobei  $\alpha = 0.01$ . Weiter ergibt sich das realisierte Intervall mit  $\hat{p}(\omega) = \frac{1}{n} X_n(\omega)$ ,  $X_n(\omega) = 207$  und  $n = 345$  durch

$$0.6 \pm \phi^{-1}(0.995) \sqrt{0.6 \cdot 0.4 \cdot \frac{1}{345}}.$$

Mit dem Wert  $\phi^{-1}(0.995) = 2.575$  erhält man mit Hilfe der Approximationen

$$0.6 \pm 2.575 \sqrt{0.6 \cdot 0.4 \cdot \frac{1}{345}} = \dots = [0.5485, 0.6515]$$

als realisiertes approximatives 99%-Vertrauensintervall für  $p$ .

c) Neue Massnahmen werden implementiert, von denen man sich eine Reduktion von  $p$  auf 0.4 erhofft. 100 Tage nach der Implementierung soll daher versucht werden, statistisch zu belegen, dass  $p$  auf unter 0.4 gefallen ist. Formuliere die für die Belegung der Aussage geeigneten Null- und Alternativhypothesen und bestimme mittels Normalapproximation den maximalen approximativen Verwerfungsbereich für das Signifikanzniveau 0.05.

Zur Belegung der Aussage wählt man folgende Hypothesen:

- $H_0 : p = 0.4$
- $H_A : p < 0.4$

Der Verwerfungsbereich ist  $\mathcal{K} = \{x : x \leq c\}$ , wobei  $c \in \mathbb{N}_0$  so gross wie möglich mit  $P_{0.4}[X_{100} \leq c] \leq 0.05$  ist. Zur Berechnung von  $P[X_{100} \leq c]$  verwendet man die Normalapproximation. Unter Berücksichtigung der Kontinuitätskorrektur ergibt sich:

$$\begin{aligned} P_{0.4}[X_{100} \leq c] &= P_{0.4} \left[ \frac{X_{100} - 40}{\sqrt{0.4 \cdot 0.6 \cdot 100}} \leq \frac{c - 40}{\sqrt{0.4 \cdot 0.6 \cdot 100}} \right] \\ &\simeq \phi \left( \frac{c - 40 + 0.5}{\sqrt{0.4 \cdot 0.6 \cdot 100}} \right). \end{aligned}$$

Somit benötigen wir  $\phi \left( \frac{c - 39.5}{\sqrt{0.4 \cdot 0.6 \cdot 100}} \right) \leq 0.05$ , beziehungsweise

$$1 - \phi \left( \frac{c - 39.5}{\sqrt{0.4 \cdot 0.6 \cdot 100}} \right) = \phi \left( \frac{39.5 - c}{\sqrt{0.4 \cdot 0.6 \cdot 100}} \right) \geq 0.95,$$

oder

$$c \leq 39.5 - \phi^{-1}(0.95) \sqrt{0.4 \cdot 0.6 \cdot 100} \simeq 39.5 - 1.645 \sqrt{25}.$$

Somit ist der maximale approximative Verwerfungsbereich  $\{x : x \leq 31\}$ .