

Einführung in die Stochastik für Informatiker

Dozent: Professor Mathar

Eine Vorlesungsmitschrift SS 2000

Thorsten Uthke

14. Juli 2000

Inhaltsverzeichnis

1	Einleitung	3
2	σ-Algebren und W'keitsverteilungen	4
3	Zufallsvariablen und ihre Verteilung	13
3.1	Diskrete Verteilungen/Zufallsvariablen	14
3.2	Verteilungsfunktionen	16
3.3	Dichten	18
3.4	Erzeugende Funktionen und Laplace-Transformierte	20
4	Produktrume und Zufallsvektoren	22
4.1	Produktrume	22
4.2	Zufallsvektoren und Folgen von Zufallsvariablen	22
5	Transformationen von ZV/Verteilungen	28
6	Erwartungswerte und Momente von ZV	33
7	Bedingte Verteilungen und Erwartungswerte	41
8	Grenzwertsatze	44
9	Schatzfunktionen und Konfidenzintervalle	49
9.1	Methoden zur Bestimmung von Schatzern	49
9.2	Gutekriterien fur Schatzer	52
9.3	Konfidenzintervalle	54

1 Einleitung

Betrachte "Zufallsexperimente", z.B.

- Münzwurf, Würfelwurf, Spiele, Roulette, Lotto
- Ankunft von Kunden an Schaltern, Pakete in Netzwerken
- Input für Algorithmen
- Signale, die von einer Quelle ausgesendet werden
- Positionierung von Mobilstationen in Zellnetzen

Gemeinsam in diesen Beispielen: Interessierende Größen können nicht genau vorhergesagt werden, sind zufallsabhängig

Stochastik: mathematische Behandlung von Zufallsphänomenen

Teilgebiete:

- Wahrscheinlichkeitstheorie
 - theoretisch (stochastische Prozesse, Grenzwertsätze, stochastische Differentialgleichungen)
 - angewandt = stochastische Modellierung (Warteschlangen, Zuverlässigkeitstheorie, stochastische Signalerkennung)
- mathematische Statistik (mit Teilgebieten)

Hier: Wahrscheinlichkeitstheorie, angewandt, stochastische Modellierung, Betonung der Anwendung in der Informatik

Ziel der Vorlesung: Bereitstellung der Grundlagen, Basis für weiterführende Vorlesungen

Warteschlangensysteme (I), Warteschlangennetze (II), Informationstheorie I,II, Kryptologie, stochastische Simulation, zufallsgesteuerte Optimierungsverfahren

Historische Entwicklung

Fermat (1601-65), Pascal (1623-62), Bernoulli (1654-1705)

Laplace (1749-1827): Kombinatorischer Zugang, motiviert durch

Spielprobleme, relative Häufigkeiten als Wahrscheinlichkeiten

Kolmogoroff (1933): Axiomatische Entwicklung

2 σ -Algebren und W'keitsverteilungen

Mathematische Beschreibung von Zufallsexperimenten mit Mengen.

Betrachte relevante **Ergebnisse** und fasse sie zu einer Menge zusammen.

Ω : **Ergebnismenge** (oft $\mathbb{N}, \mathbb{Z}, \mathbb{R}, \mathbb{R}^n, \{0, 1\}^{\mathbb{N}}$)

Ereignisse werden durch Teilmengen von Ω beschrieben.

Zunächst $\mathcal{P}(\Omega)$ als Ereignismenge.

W'keiten von Ereignissen durch Funktion $P : \mathcal{P}(\Omega) \rightarrow [0, 1]$ mit den Eigenschaften (*):

- $P(\Omega) = 1$
- $P(\emptyset) = 0$
- $P(A^C) = 1 - P(A) \quad \forall A \in \mathcal{P}(\Omega)$
- $P(A \cup B) = P(A) + P(B) \quad \forall A, B \in \mathcal{P}(\Omega) \text{ mit } A \cap B = \emptyset$

σ -Additivität:

$$P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i) \quad A_i \in \mathcal{P}(\Omega) \text{ mit } A_i \text{ paarweise disjunkt }^1$$

Schrechweisen:

A^C : "A tritt nicht ein", $A \in \mathcal{P}(\Omega)$

$A \cup B$: "A oder B treten ein", $A, B \in \mathcal{P}(\Omega)$

$A \cap B$: "A und B treten ein", $A, B \in \mathcal{P}(\Omega)$

Wie erhält man W'keiten? Bei endlichem Ω durch Abzählen.

Definition 2.1 (Laplacescher W'begriff) Ω sei eine endliche Menge. $|A|$ bezeichnet die Mächtigkeit von $A \subseteq \Omega$. Durch $P(A) = \frac{|A|}{|\Omega|}$ für $A \in \mathcal{P}(\Omega)$ wird eine W'vertteilung P auf $\mathcal{P}(\Omega)$ mit den Eigenschaften (*) definiert. P heißt **Laplace-Verteilung** oder **diskrete Gleichverteilung** über Ω .

Beispiel 2.2 (Binäre Suche) Geg. geordnetes Feld von $2^n - 1$ Elementen.

Schlüsselement y vergleichbar mit den Elementen.

Problem: Ist y in dem Feld vorhanden und an welcher Stelle?

Algorithmus: Binary search

Stochastisches Modell:

$$\Omega = \{0, 1, \dots, 2^n - 1\}, w \in \Omega = \begin{cases} w \geq 1 : \text{ gesuchtes Element an Stelle } w \\ w = 0 : y \text{ nicht vorhanden} \end{cases}$$

Bestimme Ereignisse A_k : y wird im k -ten Schritt gefunden. $A_1 = \{2^{n-1}\}$,

$A_2 = \{2^{n-2}, 3 \cdot 2^{n-2}\}, \dots, A_k = \{(2j-1)2^{n-k} | j = 1, \dots, 2^{k-1}\}$ für $k = 1, \dots, n$

Annahme: Jede Platznummer und 0 sind gleichwahrscheinlich. Dann $|A_k| = 2^{k-1}$,

$P(A_k) = \frac{2^{k-1}}{2^n}$ für $1 \leq k \leq n \implies$ W'keit, y in genau k Schritten zu finden

¹d.h. $A_i \cap A_j = \emptyset \quad \forall i \neq j$

Zusammengesetzte Ereignisse B_k : y wird in höchstens k Schritten gefunden

$B_k = \sum_{j=1}^k A_j$ mit $j = 1, \dots, k$ und die A_j disjunkt

$$P(B_k) = P(\bigcup_{j=1}^k A_j) = \sum_{j=1}^k P(A_j) = \sum_{j=1}^k \frac{2^{j-1}}{2^n} = \frac{1}{2^n} (2^k - 1) = \frac{2^k - 1}{2^n}$$

Komplizierte Anzahlbestimmungen durch kombinatorische Überlegungen.

Beispiel 2.3 (Hashing)

Universum U , $M \subseteq U$, $|M| = k$, M soll abgespeichert werden

Hashtafel: $a : \text{array}[0, \dots, n-1]$ of ...

Hashfunktion: $h : U \rightarrow [0, \dots, n-1]$ Einfache Funktion!

Speichere $x \in M$ in $a[h(x)]$

Kollision, falls $h(x) = h(y)$ für $x \neq y$ (Auflösung durch lineare Liste)

Stochastisches Modell:

(„Rein zufälliges“ Ablegen von k Daten in Feld der Länge n)

$S = \{1, \dots, n\}$ (Speicherplätze)

$\Omega = S^k$ ($k - n$ -Permutationen mit Wiederholungen/Kollisionen)

$A_{k,n}$ ($k - n$ -Permutationen ohne Wiederholungen/Kollisionen)

Wahrscheinlichkeit für kollisionsfreie Abspeicherung:

$$P(A_{k,n}) = \frac{|A_{k,n}|}{|\Omega|} = \frac{n(n-1)\dots(n-k+1)}{n^k} = \prod_{i=0}^{k-1} (1 - \frac{i}{n}) = \exp(\ln(\prod_{i=0}^{k-1} (1 - \frac{i}{n})))$$

$$= \exp(\sum_{i=0}^{k-1} \ln(1 - \frac{i}{n}))$$


$$\stackrel{(*)}{\leq} \exp(-\sum_{i=0}^{k-1} \frac{i}{n})$$

$$= \exp(-\frac{(k-1)k}{2n})$$

Benutzte Abschätzung (*):

$$\ln x \leq x - 1 \quad \forall x \geq 0$$

$$\implies \ln(1-x) \leq -x \quad \forall x \leq 1$$



Zahlenbeispiel: Für $n = 365$ und $k = 23$ ist $P(A_{k,n}) \leq 0,499998$

Der Laplacesche W'begriff reicht nicht aus, da

- Ω ist oft ∞ oder überabzählbar
- Viele Experimente sind nicht durch eine diskrete Gleichverteilung beschreibbar

Beispiel 2.4 (∞ -Münzwurf) Kopf $\hat{=}$ 1, Zahl $\hat{=}$ 0

Bestimme ein Modell für nicht-abbrechende Folge von Münzwürfen.

(Wird gebraucht bei der Frage „Wann tritt zum ersten Mal Kopf (Zahl) auf?“.

Jeder beliebig ferne Wurf könnte der erste sein.).

Stochastisches Modell:

$\Omega = \{w = (x_1, x_2, \dots) | x_i \in \{0, 1\}\} = \{0, 1\}^{\mathbb{N}}$ Menge der 0-1-Folgen

Bekannt: Ω ist überabzählbar.

Problem: Beschreibe Gleichverteilung auf Ω

Ansatz: $P(\{w\}) = \delta > 0$

Sei $A = \{w_1, w_2, \dots\} \subset \Omega$ unendlich, aber abzählbar. Dann $P(A) = \sum_{i=1}^{\infty} P(\{w_i\}) = \sum_{i=1}^{\infty} \delta = \infty$ Widerspruch zu $P(\Omega) = 1$.
Also: $P(\{w\}) = 0 \quad \forall w \in \Omega$ Wenig hilfreich!

Beispiel 2.5 (Gleichverteilung über $[0, 1]$) (z.B. jede reelle Zahl zwischen 0 und 1 ist gleich wahrscheinlich)

$\Omega = [0, 1]$ (Ergebnismenge)

Versuch: Ereignismenge = $\mathcal{P}(\Omega)$

Forderungen:

- 1) $P([a, b]) = b - a \quad \forall 0 \leq a < b \leq 1$
- 2) P ist σ -additiv

Es gilt: Eine Funktion P mit diesen Eigenschaften existiert nicht. Im \mathbb{R}^3 gibt es sogar keine, wenn nur endliche Additivität verlangt wird: Es gibt kein endlich additives dreihinvariantes² Maß auf $\mathcal{P}(\mathbb{R}^3)$. (Hausdorff 1914)

Für einen allgemeinen W'begriff (ohne Existenzprobleme):

Ereignismenge nicht $\mathcal{P}(\Omega)$, sondern kleineres Mengensystem wählen, das noch alle interessanten Ereignisse enthält.

Definition 2.6 Sei $\Omega \neq \emptyset$, $\mathfrak{A} \subseteq \mathcal{P}(\Omega)$ ein System von Teilmengen von Ω . \mathfrak{A} heißt **σ -Algebra** (von Ereignissen) über Ω , wenn

- (i) $\Omega \in \mathfrak{A}$
- (ii) $A \in \mathfrak{A} \implies A^C \in \mathfrak{A}$
- (iii) $A_n \in \mathfrak{A} \quad \forall n \in \mathbb{N} \implies \bigcup_{n=1}^{\infty} A_n \in \mathfrak{A}$

(Ω, \mathfrak{A}) heißt **Meßraum**.

Mit den De Morgan-Regeln: $A_n \in \mathfrak{A} \xrightarrow{ii)} A_n^C \in \mathfrak{A} \xrightarrow{iii)} \bigcup_{n=1}^{\infty} A_n^C \in \mathfrak{A} \xrightarrow{ii)} (\bigcup_{n=1}^{\infty} A_n^C)^C \in \mathfrak{A} \implies \bigcap_{n=1}^{\infty} A_n \in \mathfrak{A} \quad \forall n \in \mathbb{N}$

σ -Algebren enthalten alle Ereignisse, die durch Verknüpfungen (abzählbar vieler Ereignisse) mit "und", "oder" und "nicht" entstehen. Dies ist wichtig für die Festlegung von W'verteilungen.

Beispiel 2.7

- a) $\mathcal{P}(\Omega)$ ist stets eine σ -Algebra (die feinste σ -Algebra)
- b) $\{\emptyset, \Omega\}$ ist eine σ -Algebra (die größte σ -Algebra)
- c) $\Omega = \mathbb{N}$, $G = \{2, 4, 6, \dots\}$, $U = \{1, 3, 5, \dots\}$, $\mathfrak{A} = \{\emptyset, G, U, \Omega\}$ ist σ -Algebra

²Wenn man im \mathbb{R}^3 einen Körper dreht, muss er derselbe bleiben.

- d) $\Omega = \mathbb{R}$, $E = \{(a, b] | a < b \text{ mit } a, b \in \mathbb{R}\}$ ist keine σ -Algebra
 Denn sei $a < b < c < d$. $(a, b] \in E$ und $(c, d] \in E$, aber $(a, b] \cup (c, d] \notin E$.

Problem: Gibt es eine kleinste (im Sinne der Mengeninklusion) σ -Algebra, die E enthält?

Lemma 2.8 $\Omega \neq \emptyset$, \mathfrak{A}_i sei σ -Algebra über Ω für alle $i \in I$. Dann ist $\bigcap_{i \in I} \mathfrak{A}_i$ ebenfalls eine σ -Algebra. (Beweis in der Übung 2)

Sei $E \subseteq \mathcal{P}(\Omega)$. $\mathfrak{A}(E) = \bigcap_{\substack{\mathfrak{A} \text{ ist } \sigma\text{-Algebra} \\ \text{und } E \subseteq \mathfrak{A}}} \mathfrak{A}$ ist die kleinste σ -Algebra, die E enthält, ist die **von E erzeugte σ -Algebra**.

Definition 2.9 Sei $\Omega = \mathbb{R}$, $E = \{(a, b] | a < b \text{ mit } a, b \in \mathbb{R}\}$.
 $\mathfrak{B} = \mathfrak{A}(E)$ heißt **Borelsche σ -Algebra**.

Auf σ -Algebren können W -Verteilungen mit den Eigenschaften (*) (Seite 4) definiert werden.

Definition 2.10 $\Omega \neq \emptyset$, \mathfrak{A} eine σ -Algebra. Eine Abbildung $P : \mathfrak{A} \rightarrow [0, 1]$ mit

- (i) $P(\Omega) = 1$
- (ii) $P(\bigcup_{n=1}^{\infty} A_n) = \sum_{n=1}^{\infty} P(A_n) \quad \forall A_n \in \mathfrak{A}$, paarweise disjunkt

heißt **Wahrscheinlichkeitsverteilung** oder **Wahrscheinlichkeitsmaß** auf (Ω, \mathfrak{A}) . $(\Omega, \mathfrak{A}, P)$ heißt **Wahrscheinlichkeitsraum**.

Der Laplacesche W -begriff (Def. 2.1) ist ein Spezialfall von Def. 2.10. Denn für $\mathfrak{A} = \mathcal{P}(\Omega)$ erfüllt $P(A) = \frac{|A|}{|\Omega|}$

- (i) $P(\Omega) = \frac{|\Omega|}{|\Omega|} = 1$
- (ii) $P(\bigcup_{n=1}^{\infty} A_n) = \frac{|\bigcup_{n=1}^{\infty} A_n|}{|\Omega|} = \frac{\sum_{n=1}^{\infty} |A_n|}{|\Omega|} = \sum_{n=1}^{\infty} \frac{|A_n|}{|\Omega|} = \sum_{n=1}^{\infty} P(A_n)$
 $\forall A_n$ paarweise disjunkt

Sei $(\Omega, \mathfrak{A}, P)$ W -raum. Eine Folge von Ereignissen $\{A_n\}_{n \in \mathbb{N}}$ heißt **aufsteigend** (**absteigend**), wenn $A_n \subseteq A_{n+1}$ ($A_{n+1} \subseteq A_n$) für alle $n \in \mathbb{N}$.

$\bigcup_{n=1}^{\infty} A_n = \lim_{n \rightarrow \infty} A_n$ ($\bigcap_{n=1}^{\infty} A_n = \lim_{n \rightarrow \infty} A_n$) heißt **Limes** der Mengenfolge $\{A_n\}$.

Lemma 2.11 (Eigenschaften von W -Verteilungen) $(\Omega, \mathfrak{A}, P)$ sei W -raum.
 $A, B, A_n \in \mathfrak{A} \quad \forall n \in \mathbb{N}$.

- a) $P(A^C) = 1 - P(A)$

- b) $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
 c) $P(A) \leq P(B)$ falls $A \subseteq B$
 d) $P(B \setminus A) = P(B) - P(A)$ falls $A \subseteq B$
 e) $\{A_n\}$ aufsteigend $\implies P(\lim_{n \rightarrow \infty} A_n) = \lim_{n \rightarrow \infty} P(A_n)$ (Stetigkeit von unten)
 $\{A_n\}$ absteigend $\implies P(\lim_{n \rightarrow \infty} A_n) = \lim_{n \rightarrow \infty} P(A_n)$ (Stetigkeit von oben)

Beweis: a)-d) in der 2. Übung

- e) 1.) $\{A_n\}$ aufsteigend, d.h. $A_n \subseteq A_{n+1} \quad \forall n \in \mathbb{N}$
 Setze $B_1 = A_1, B_2 = A_2 \setminus A_1, \dots, B_{n+1} = A_{n+1} \setminus A_n$
 Dann gilt B_n p.d. (paarweise disjunkt) und $\bigcup_{n=1}^{\infty} A_n = \bigcup_{n=1}^{\infty} B_n$. Setze $A_0 = \emptyset$,
 dann ist $P(\bigcup_{n=1}^{\infty} A_n) = P(\bigcup_{n=1}^{\infty} B_n) \stackrel{ii)}{=} \sum_{n=1}^{\infty} P(B_n) = \lim_{k \rightarrow \infty} \sum_{n=1}^k P(A_n \setminus A_{n-1})$
 $= \lim_{k \rightarrow \infty} \sum_{n=1}^k [P(A_n) - P(A_{n-1})] = \lim_{k \rightarrow \infty} P(A_k)$
 2.) $\{A_n\}$ absteigend $\implies \{A_n^C\}$ aufsteigend. Es gilt:
 $P(\bigcap_{n=1}^{\infty} A_n) = 1 - P(\bigcup_{n=1}^{\infty} A_n^C) \stackrel{1.)}{=} 1 - \lim_{n \rightarrow \infty} P(A_n^C) = \lim_{n \rightarrow \infty} (1 - P(A_n^C))$
 $= \lim_{n \rightarrow \infty} P(A_n)$

Lemma 2.12 $(\Omega, \mathfrak{A}, P)$ sei W'raum. $A_1, \dots, A_n \in \mathfrak{A}$.

- a) **Siebformel** von Pomcare-Sylvester (inclusion-exclusion-formula)

$$P\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n P(A_i) - \sum_{1 \leq i_1 < i_2 \leq n} P(A_{i_1} \cap A_{i_2}) + \sum_{1 \leq i_1 < i_2 < i_3 \leq n} P(A_{i_1} \cap A_{i_2} \cap A_{i_3}) - \dots + \dots + (-1)^{n+1} P\left(\bigcup_{i=1}^n A_i\right)$$

- b) **Bonferroni-Ungleichung** (Bonferroni inequality)

$$\sum_{i=1}^n P(A_i) - \sum_{1 \leq i_1 < i_2 \leq n} P(A_{i_1} \cap A_{i_2}) \leq P\left(\bigcup_{i=1}^n A_i\right) \leq \sum_{i=1}^n P(A_i)$$

Weitere obere bzw. untere Schranken durch Abbruch in a) nach + oder - Zeichen

Beispiel 2.13 (Sortieren) (Recourtre-Problem)

Betrachte Feld der Länge n von vergleichbaren, verschiedenen Elementen. Alle Anordnungen seien gleichwahrscheinlich.

Stoch. Modell: $\Omega = \{\text{Permutationen von } \{1, \dots, n\}\}, \mathfrak{A} = \mathcal{P}(\Omega)$

$$P(\{w\}) = \frac{1}{|\Omega|} = \frac{1}{n!} \quad \forall w \in \Omega$$

- a) Bestimme die W'keit, daß mindestens ein Element an der richtigen Stelle ist (vorsortiert).

$$A_j = \{w = (w_1, \dots, w_n) \in \Omega \mid w_j = j\} \quad j\text{-tes Element an der richtigen Stelle}$$

Gesucht: $P(A_1 \cup \dots \cup A_n) = P(\bigcup_{i=1}^n A_i)$

Berechnung mit Hilfe der Siebformel: $1 \leq i_1 < i_2 \leq n, l \leq n$

$\bigcap_{j=1}^l A_{i_j} = \{w \in \Omega \mid w_{i_j} = i_j, j = 1, \dots, l\}, \quad |\bigcap_{j=1}^l A_{i_j}| = (n-l)!$

Also $P(\bigcap_{j=1}^l A_{i_j}) = \frac{(n-l)!}{n!} = \frac{1}{\binom{n}{l} l!}$ mit $l = 1, \dots, n$

Außerdem: $|\{(i_1, \dots, i_l) \mid 1 \leq i_1 < \dots < i_l \leq n\}| = \binom{n}{l}$

Insgesamt: $P(\bigcup_{j=1}^n A_j) = \sum_{j=1}^n P(A_j) - \sum_{i < j} P(A_i \cap A_j) + \dots + (-1)^{n+1} P(\bigcap_{j=1}^n A_j)$

$$= \frac{n}{n} - \binom{n}{2} \frac{1}{\binom{n}{2} 2!} + \binom{n}{3} \frac{1}{\binom{n}{3} 3!} - \dots + (-1)^{n+1} \binom{n}{n} \frac{1}{\binom{n}{n} n!}$$

$$= 1 - \frac{1}{2!} + \frac{1}{3!} - \dots + \frac{(-1)^{n+1}}{n!}$$

$$= 1 - (1 - \frac{1}{1!} + \frac{1}{2!} - \frac{1}{3!} + \dots + \frac{(-1)^n}{n!}) \xrightarrow{n \rightarrow \infty} 1 - e^{-1} \approx 0,6321$$

n groß: W'keit für mindestens ein vorsortiertes Element ist 0,6321 (fast unabhängig von n)

- b) Bestimme die W'keit, daß mindestens k Elemente vorsortiert sind.

$$P(\bigcup_{1 \leq i_1 < \dots < i_k \leq n} \bigcap_{l=1}^k A_{i_l}) \stackrel{\text{Lemma 2.12b}}{\leq} \sum_{1 \leq i_1 < \dots < i_k \leq n} P(\bigcap_{l=1}^k A_{i_l}) = \binom{n}{k} \frac{1}{\binom{n}{k} k!} = \frac{1}{k!}$$

fällt sehr schnell mit steigendem k

- c) Bestimme die W'keit, daß genau k Elemente vorsortiert sind.

Nach a): W'keit, daß in einem Feld der Länge $n-k$ kein Element vorsortiert

$$\text{ist: } 1 - \frac{1}{1!} + \frac{1}{2!} - \dots + \frac{(-1)^{n-k}}{(n-k)!}$$

\implies Anzahl der Anordnungen, beim denen kein Element vorsortiert ist:

$$(n-k)! (1 - \frac{1}{1!} + \frac{1}{2!} - \dots + \frac{(-1)^{n-k}}{(n-k)!})$$

Anzahl der Möglichkeiten, ein Feld der Länge n in ein Teilfeld der Länge $n-k$ und eines der Länge k aufzuteilen: $\binom{n}{k}$

Insgesamt: W'keit, daß genau k Elemente vorsortiert sind:

$$\frac{1}{n!} \binom{n}{k} (n-k)! (1 - \frac{1}{1!} + \frac{1}{2!} - \dots + \frac{(-1)^{n-k}}{(n-k)!}) = \frac{1}{k!} (1 - \frac{1}{1!} + \frac{1}{2!} - \dots + \frac{(-1)^{n-k}}{(n-k)!})$$

Wie legt man W'keiten fest, wenn schon bekannt ist, daß das Ergebnis in einer bestimmten Teilmenge liegt?

Motivierendes Beispiel 5000 Chips von zwei Firmen. Ω mit $|\Omega| = 5000$.

A : Chips der Firma A, mit $|A| = 1000$

B : Chips der Firma B, mit $|B| = 4000$

D : Defekte Chips, mit $|D| = 300$

Gelte: $|A \cap D| = 100$ (10% defekt) und $|B \cap D| = 200$ (5% defekt)

Ziehe zufällig einen Chip (Laplace-Modell).

W'keit, daß der Chip defekt ist, wenn er von Firma A stammt:

$$P(D|A) = \frac{|D \cap A|}{|A|} = \frac{|D \cap A|/\Omega}{|A|/\Omega} = \frac{P(D \cap A)}{P(A)} = \frac{100/5000}{1000/5000} = 0,1$$

$$\text{Auch: } P(A|D) = \frac{|A \cap D|}{|D|} = \frac{|A \cap D|/\Omega}{|D|/\Omega} = \frac{P(A \cap D)}{P(D)} = \frac{100/5000}{300/5000} = \frac{1}{3}$$

Definition 2.14 $(\Omega, \mathfrak{A}, P)$ sei W'raum. $A, B \in \mathfrak{A}$, $P(B) > 0$. $P(A|B) = \frac{P(A \cap B)}{P(B)}$ heit (**elementare**) **bedingte Wahrscheinlichkeit von A unter (der Hypothese) B** . Durch $P(A^3|B) : \mathfrak{A} \rightarrow [0, 1]$ mit $A \mapsto P(A|B)$ wird eine W'vertelung auf \mathfrak{A} definiert, die (**elementare**) **bedingte Verteilung unter B** .

Satz 2.15 $(\Omega, \mathfrak{A}, P)$ sei W'raum. $B_n \in \mathfrak{A}$ fr $n \in \mathbb{N}$ sei Partition von Ω , d.h. $\bigcup_{n=1}^{\infty} B_n = \Omega$ und B_n paarweise disjunkt.

a) **Satz von der totalen W'keit** Fr alle $A \in \mathfrak{A}$ gilt:

$$P(A) = \sum_{n=1}^{\infty} P(A|B_n)P(B_n) \quad (\text{Konvention: "Nicht definiert"} \cdot 0 = 0, \text{ z.B. } \frac{x}{0} \cdot 0 = 0)$$

b) **Bayes-Formel** Falls $P(A) > 0$, gilt fr alle $n \in \mathbb{N}$

$$P(B_n|A) = \frac{P(A|B_n)P(B_n)}{\sum_{j=1}^{\infty} P(A|B_j)P(B_j)}$$

Beweis:

$$a) P(A) = P\left(\bigcup_{n=1}^{\infty} A \cap B_n\right) = \sum_{n=1}^{\infty} P(A \cap B_n) = \sum_{n=1}^{\infty} P(A|B_n)P(B_n)$$

$$b) P(B_n|A) = \frac{P(B_n \cap A)}{P(A)} = \frac{P(A|B_n)P(B_n)}{\sum_{j=1}^{\infty} P(A|B_j)P(B_j)}$$

Wichtiger Spezialfall: $P(A|B) = P(A|B^C)$, wobei $P(B) > 0$, $P(B^C) > 0$ (*)
(W'keit fr das Eintreten von A hngt nicht vom Eintreten von B ab.)

Dann gilt: $P(A) = P(A \cap B) + P(A \cap B^C) = P(A|B)P(B) + P(A|B^C)P(B^C) \stackrel{(*)}{=} P(A|B)(P(B) + P(B^C)) = P(A|B) = \frac{P(A \cap B)}{P(B)}$

$$\text{Also: } P(A) = \frac{P(A \cap B)}{P(B)} \iff P(A)P(B) = P(A \cap B)$$

Diese Definition wird erweitert auf n Ereignisse $A_1, \dots, A_n \in \mathfrak{A}$, bzw. auf Folgen von Ereignissen.

Definition 2.16 $(\Omega, \mathfrak{A}, P)$ sei W'raum. $A_1, \dots, A_n \in \mathfrak{A}$ Ereignisse. A_1, \dots, A_n heien (**gemeinsam**) **stochastisch unabhngig**, wenn $P(A_{i_1} \cap \dots \cap A_{i_k}) = P(A_{i_1}) \dots P(A_{i_k})$ fr alle $1 \leq i_1 < \dots < i_k \leq n$ und fr alle k .

Eine Folge $\{A_n\}_{n \in \mathbb{N}}$ von Ereignissen heit stochastisch unabhngig, wenn die A_1, \dots, A_n fr alle $n \in \mathbb{N}$ stochastisch unabhngig sind.

Beachte: Aus paarweiser stochastischer Unabhngigkeit folgt nicht die (gemeinsame) stochastische Unabhngigkeit!

Lemma 2.17 $(\Omega, \mathfrak{A}, P)$ sei W'raum. $A_1, \dots, A_n \in \mathfrak{A}$.

Es gilt: $A_1, \dots, A_n \in \mathfrak{A}$ stochastisch unabhngig

$$\iff \forall B_i \in \{A_i, A_i^C\}, i = 1, \dots, n: P\left(\bigcap_{i=1}^n B_i\right) = \prod_{i=1}^n P(B_i)$$


Es gilt: $A_1, \dots, A_n \in \mathfrak{A}$ stochastisch unabhngig

$$\iff \forall B_i \in \{A_i, A_i^C\}, i = 1, \dots, n: B_1, \dots, B_n \text{ stochastisch unabhngig}$$

³ A variabel in \mathfrak{A}

Beweis: Stochastik für Informatiker (Mathar & Pfeiffer)

Beispiel 2.18 System bestehe aus 5 Komponenten:



System ist intakt, wenn mindestens ein "Pfad" intakt ist.

W'keit, daß Komponente i intakt ist: p_i für $i = 1, \dots, 5$ (Werte in Skizze)

{Komponente K_i intakt} seien stochastisch unabhängige Ereignisse.

Modellbildung: $\Omega = \{(x_1, \dots, x_5) | x_i \in \{0, 1\}\}$ ($x_i = 1$: Komponente i intakt)

$A_i = \{(x_1, \dots, x_5) | x_i = 1\}$, $P(A_i) = p_i$ (Komponente i intakt)

A_1, \dots, A_5 stochastisch unabhängig

$S = (A_1 \cap A_4) \cup (A_2 \cap A_4) \cup (A_2 \cap A_5) \cup (A_3 \cap A_5)$ (System intakt)

$P(S) = P((A_1 \cap A_4) \cup (A_2 \cap A_4) \cup (A_2 \cap A_5) \cup (A_3 \cap A_5))$ Vereinigung nicht disjunkter Mengen \implies Berechnung mit Sylvesterformel möglich, aber sehr aufwendig!

Mit Satz 2.15 a):

$$P(S) = \underbrace{P(S|A_2)P(A_2)}_{(*1)} + \underbrace{P(S|A_2^C)P(A_2^C)}_{(*2)}$$

$$(*1): P(S|A_2) = P(A_4 \cup A_5) = 1 - P(A_4^C \cap A_5^C) = 1 - P(A_4^C)P(A_5^C) \\ = 1 - (1 - p_4)(1 - p_5)$$

$$(*2): P(S|A_2^C) = P((A_1 \cap A_4) \cup (A_3 \cap A_5)) = 1 - P((A_1 \cap A_4)^C \cap (A_3 \cap A_5)^C) \\ = 1 - (1 - p_1 p_4)(1 - p_3 p_5)$$

$$\text{Insgesamt: } P(S) = [1 - (1 - p_4)(1 - p_5)]p_2 + [1 - (1 - p_1 p_4)(1 - p_3 p_5)](1 - p_2) \\ = \dots = 1 - p_2(1 - p_4)(1 - p_5) - (1 - p_2)(1 - p_1 p_4)(1 - p_3 p_5) = 0,90062$$

Mit Satz 2.15 b): (W'keit, daß Komponente 2 intakt, wenn System intakt)

$$P(A_2|S) = \frac{P(S|A_2)P(A_2)}{P(S)} = \frac{0,91 \cdot 0,8}{0,90062} = 0,80833$$

Betrachte Limites von Mengenfolgen die nicht notwendig auf- oder absteigend sind.

Beispiel 2.19 (unendlicher Münzwurf) $\Omega = \{w = (x_1, x_2, \dots) | x_i \in \{0, 1\}\}$

$A_n = \{w = (x_1, x_2, \dots) | x_n = 1\}$ (im n -ten Wurf fällt Kopf)

Beschreibe das Ereignis A : es fällt ∞ -oft Kopf = es treten ∞ viele der A_n ein

$$A = \{w | w \in A_n \text{ für } \infty \text{ viele } n\} = \{w | \forall k \exists n \geq k : w \in A_n\} = \bigcap_{k=1}^{\infty} \bigcup_{n=k}^{\infty} A_n$$

Analog: B : Fast alle der A_n treten ein (alle bis auf endlich viele Ausnahmen)

$$B = \{w | w \in A_n \text{ für fast alle } n\} = \{w | \exists k \forall n \geq k : w \in A_n\} = \bigcup_{k=1}^{\infty} \bigcap_{n=k}^{\infty} A_n$$

Definition 2.20 $(\Omega, \mathfrak{A}, P)$ sei W'raum. $A_n \in \mathfrak{A}$, $n \in \mathbb{N}$

$$\limsup_{n \rightarrow \infty} A_n = \lim_{n \rightarrow \infty} \left(\bigcup_{k=n}^{\infty} A_k \right) = \bigcap_{n=1}^{\infty} \bigcup_{k=n}^{\infty} A_k \text{ hei\u00dft } \mathbf{Limes\ superior} \text{ der } \{A_n\}$$

Der Limes superior einer Ereignisfolge $\{A_n\}$ ist die Menge der $w \in \Omega$, die in unendlich vielen der A_n liegen; d.h., da\u00df unendlich viele der A_n eintreten.

$$\liminf_{n \rightarrow \infty} A_n = \lim_{n \rightarrow \infty} \left(\bigcap_{k=n}^{\infty} A_k \right) = \bigcup_{n=1}^{\infty} \bigcap_{k=n}^{\infty} A_k \text{ hei\u00dft } \mathbf{Limes\ inferior} \text{ der } \{A_n\}$$

Der Limes inferior einer Ereignisfolge $\{A_n\}$ ist die Menge der $w \in \Omega$, die in fast allen der A_n liegen; d.h., da\u00df fast alle der A_n eintreten.

Satz 2.21 (Borel-Cantelli-Lemma, auch 0-1-Gesetz)

$(\Omega, \mathfrak{A}, P)$ sei W'raum. $A_n \in \mathfrak{A}$, $n \in \mathbb{N}$

- a) $\sum_{n=1}^{\infty} P(A_n) < \infty \implies P(\limsup_{n \rightarrow \infty} A_n) = 0$
- b) $\sum_{n=1}^{\infty} P(A_n) = \infty \implies P(\limsup_{n \rightarrow \infty} A_n) = 1$, falls $\{A_n\}_{n \in \mathbb{N}}$ stoch. unabh.

Beweis:

a) $P\left(\sum_{n=k}^{\infty} A_n\right) \leq \sum_{n=k}^{\infty} P(A_n) \rightarrow 0$ (f\u00fcr $k \rightarrow \infty$)

$$P(\limsup_{n \rightarrow \infty} A_n) = P\left(\bigcap_{k=1}^{\infty} \underbrace{\bigcup_{n=k}^{\infty} A_n}_{B_k, \text{ absteigend}}\right) \stackrel{\text{Lemma 2.11e}}{=} \lim_{k \rightarrow \infty} P\left(\sum_{n=k}^{\infty} A_n\right) = 0$$

b) R\u00fcckseite von \u00dcbung 3

Beispiel 2.22 ∞ -W\u00fcrfelwurf, unabh\u00e4ngige W\u00fcrfe,

$$\Omega = \{w = (w_1, w_2, \dots) | w_i \in \{1, \dots, 6\}\}$$

W'keit, da\u00df ∞ -oft die Sequenz 1, 2, \dots , 6 f\u00e4llt?

Setze $A_n = \{w | w_n = 1, w_{n+1} = 2, \dots, w_{n+5} = 6\}$ (ab dem n -ten Wurf f\u00e4llt die Sequenz 1, 2, \dots , 6) Beachte: $\{A_n\}_{n \in \mathbb{N}}$ ist nicht stoch. unabh\u00e4ngig!

Die Folge $\{A_{6n}\}_{n \in \mathbb{N}}$ ist stoch. unabh\u00e4ngig. Mit Borel-Cantelli gilt:

$$P(\limsup_{n \rightarrow \infty} A_n) \geq P(\limsup_{n \rightarrow \infty} A_{6n}) = 1, \text{ da } \sum_{n=1}^{\infty} P(A_{6n}) = \sum_{n=1}^{\infty} \frac{1}{6^6} = \infty.$$

3 Zufallsvariablen und ihre Verteilung

Zur Motivation: $(\Omega, \mathfrak{A}, P)$ W'raum: Beschreibung von Zufallsexperimenten, Modellierung von Zufallseinflüssen

- Oft interessiert nicht das gesamte Modell, sondern gewisse Teilgrößen, z.B. 5000 Stichproben mit Ausgang "gut/schlecht". Von Interesse ist nur die Anzahl der schlechten Stücke.
 $\Omega = \{(x_1, \dots, x_{5000}) | x_i \in \{g, s\}\}$ wäre die Ereignismenge
 $T = \{0, \dots, 5000\}$ von Interesse
- Ergebnisse von Zufallsexperimenten sind oft Zahlen oder Vektoren. Oft sind arithmetische Operationen nützlich, z.B. 5000 Münzwürfe mit Ergebnis 0 oder 1 (s.o.). $x_1, \dots, x_{5000} \in \{0, 1\}$
 Von Interesse: Anzahl Einsen: $\sum_{i=1}^{5000} x_i$
 oder $x_1, \dots, x_n \in \mathbb{R}^+$ (z.B. Verzögerungszeiten in einem Switch)
 $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ (mittlere Verzögerungszeit, Mittelwert)

Modellierung allgemein mit Zufallsvariablen

Definition 3.1 (Zufallsvariable) $(\Omega, \mathfrak{A}, P)$ sei W'raum. Eine Abbildung $X : \Omega \rightarrow \mathbb{R}$ heißt **Zufallsvariable (ZV)** oder **Zufallsgröße** (random variable (r.v.)), wenn $X^{-1}(B) = \{w \in \Omega | X(w) \in B\} \stackrel{\text{kurz}}{=} \{X \in B\} \in \mathfrak{A}$ für alle $B \in \mathfrak{B}^1$. Diese Bedingung heißt **Meßbarkeit** von X .

Schreibweise: $X : (\Omega, \mathfrak{A}) \rightarrow (\mathbb{R}, \mathfrak{B}^1)$ (X ist Abbildung und meßbar)

Bemerkung: Der Begriff "Zufallsvariable" hat sich eingebürgert, obwohl es sich eigentlich um "Funktionen" handelt. Betont wird die Modellierung des Zufalls, wichtig ist die Verteilung von ZV.

Lemma 3.2 $X : (\Omega, \mathfrak{A}) \rightarrow (\mathbb{R}, \mathfrak{B}^1)$ sei Zufallsvariable. Durch

$P^X(B) := P(X^{-1}(B)) = P(\{w | X(w) \in B\}) \stackrel{\text{kurz}}{=} P(X \in B)$ für $B \in \mathfrak{B}^1$ wird eine W'vertelung auf $(\mathbb{R}, \mathfrak{B}^1)$ definiert. P^X heißt **Verteilung der ZV X** .

Beweis: Überprüfe Definition 2.10:

(i) $P^X(\mathbb{R}) = P(X^{-1}(\mathbb{R})) = P(\Omega) = 1$

(ii) B_n paarw. disj., $B_n \in \mathfrak{B}^1$, $n \in \mathbb{N}$

$$\begin{aligned} P^X\left(\bigcup_{n=1}^{\infty} B_n\right) &= P\left(X^{-1}\left(\underbrace{\bigcup_{n=1}^{\infty} B_n}_{\substack{\in \mathfrak{B}^1 \\ \in \mathfrak{A}}}\right)\right) = P\left(\underbrace{\bigcup_{n=1}^{\infty} X^{-1}(B_n)}_{\text{paarw. disj.}}\right) \\ &= \sum_{n=1}^{\infty} P(X^{-1}(B_n)) = \sum_{n=1}^{\infty} P^X(B_n) \end{aligned}$$

Wesentlich in Definition 3.1: "meßbar", d.h. ZV X induzieren auf $(\mathbb{R}, \mathfrak{B}^1)$ die Verteilung P^X . Math. Modell für Zufallsexperimente häufig:

$$(\Omega, \mathfrak{A}, P) \xrightarrow{X} (\mathbb{R}, \mathfrak{B}^1, P^X)$$

Modelliert alle Zufallseinflüsse, genaue Kenntniss oft nicht erforderlich, lediglich Existenz nötig

Modelliert die interessierenden beobachteten Größen, P^X oft als Parameter bekannt. Beachte: $(\mathbb{R}, \mathfrak{B}^1, P^X)$ ist ein W'raum, bisherige Regeln gelten auch hier

Beispiel 3.3 (Binomialverteilung) n -facher Münzwurf, Kopf $\hat{=}$ 1, Zahl $\hat{=}$ 0, Würfe unabhängig. Kopf mit W'keit p , Zahl mit W'keit $1 - p$ in jedem Wurf.

Modell: $\Omega = \{w = (x_1, \dots, x_n) | x_i \in \{0, 1\}\}$ $\mathfrak{A} = \mathcal{P}(\Omega)$,

$$P(\{(x_1, \dots, x_n)\}) = \underbrace{p \dots p}_{\text{Anz. Einsen}} \underbrace{(1-p) \dots (1-p)}_{\text{Anz. Nullen}} = p^{\sum_{i=1}^n x_i} (1-p)^{n - \sum_{i=1}^n x_i}$$

$$\text{ZV } X = \text{Anz. der Einsen} \quad X(w) = X((x_1, \dots, x_n)) = \sum_{i=1}^n x_i$$

Wertebereich von X : $T = \{0, 1, \dots, n\}$

Verteilung von X : $P^X(\{k\}) = P(X^{-1}(\{k\})) = P(\{w | X(w) = k\})$

$$\stackrel{\text{kurz}}{=} P(X = k) = P(\{(x_1, \dots, x_n) | \sum_{i=1}^n x_i = k\})$$

$$= \sum_{(x_1, \dots, x_n) : \sum_{i=1}^n x_i = k} p^{\sum_{i=1}^n x_i} (1-p)^{n - \sum_{i=1}^n x_i}$$

$$= \sum_{(x_1, \dots, x_n) : \sum_{i=1}^n x_i = k} p^k (1-p)^{n-k} = \binom{n}{k} p^k (1-p)^{n-k} \quad \text{für } k = 0, 1, \dots, n$$

Eine Zufallsvariable heißt **binomialverteilt** mit den Parametern $n \in \mathbb{N}$, $p \in [0, 1]$, wenn $P(X = k) = \binom{n}{k} p^k (1-p)^{n-k}$ für $k = 0, 1, \dots, n$.

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

Interpretation: $\text{Bin}(n, p)$ ist die W'vertelung der Anzahl der "Treffer" in einer Bernoulli-Serie⁴ der Länge n mit Trefferw'keit p .

Im weiteren: Allgemeine Methoden zur Beschreibung von W'vertelungen, direkt formuliert für ZV.

Beachte: Mit $X = \text{Identität}$ lassen sich die folgenden Überlegungen auch direkt auf W'maße P anwenden.

3.1 Diskrete Verteilungen/Zufallsvariablen

Definition 3.4 Eine ZV X (auf einem W'raum $(\Omega, \mathfrak{A}, P)$), bzw. deren Verteilung P^X , heißt **diskret**, wenn eine höchstens abzählbare Menge $T = \{t_1, t_2, \dots\}$ mit $P^X(T) = P(X \in T) = 1$ existiert. T heißt **Träger** (support) von X bzw. P^X .

⁴Münzwurf-Serie der Länge n , unabhängige Würfe, Trefferw'keit p

X sei diskrete ZV mit Träger $T = \{t_1, t_2, \dots\}$, $A \in \mathfrak{B}^1$. Dann gilt:

$$P^X(A \cap T) \stackrel{\text{Lemma 2.11b}}{=} P^X(A) + \underbrace{P^X(T)}_{=1} - \underbrace{P^X(A \cup T)}_{=1} = P^X(A)$$

$$\text{Also: } P(X \in A) = P^X(A) = P^X(A \cap T) = P^X\left(\bigcup_{i=1}^{\infty} (A \cap \{t_i\})\right) = \sum_{i:t_i \in A} P^X(\{t_i\})$$

$$= \sum_{i:t_i \in A} P(X = t_i)$$

D.h. P^X , die Verteilung von X , ist eindeutig festgelegt durch $P(X = t_i)$ für $i = 1, 2, \dots$

Definition 3.5 X sei diskrete ZV mit Träger $T = \{t_1, t_2, \dots\}$. $f_X : T \rightarrow [0, 1]$ mit $f_X(t_i) = P(X = t_i)$ für $i = 1, 2, \dots$ heißt **Zähldichte** (discrete density function) der ZV X .

$X \sim \text{Bin}(n, p)$ (siehe Beispiel 3.3) ist ein Beispiel für eine diskrete ZV mit $f_X(k) = \binom{n}{k} p^k (1-p)^{n-k}$ für $k = 0, 1, \dots, n$. ($0 \leq p \leq 1$ ist ein Parameter)

Beispiel 3.6 (Geometrische Verteilung)

Unendlicher unabhängiger Münzwurf (siehe Beispiel 3.3).

$$\Omega = \{w = (x_1, x_2, \dots) \mid x_i \in \{0, 1\}\}$$

$X =$ Wartezeit bis zum ersten Treffer ("1"), Träger $T = \mathbb{N}_0$.

$$P(X = k) = P(\{w = (x_1, x_2, \dots) \mid x_1 = x_2 = \dots = x_k = 0, X_{k+1} = 1\}) = (1-p)^k p$$

für $k = 0, 1, \dots$

Die Verteilung mit der Zähldichte $f_X(k) = (1-p)^k p$ für $k = 0, 1, \dots$ ($0 < p \leq 1$ ein Parameter) heißt **geometrische Verteilung**. Bezeichnung: $X \sim \text{Geo}(p)$, $0 < p \leq 1$.

Beispiel 3.7 (Poissonverteilung, Gesetz seltener Ereignisse)


Sei $p_n \in (0, 1)$ mit $n \cdot p_n \rightarrow \lambda$ für $n \rightarrow \infty$, $\lambda > 0$. Dann gilt:

$$\binom{n}{k} p_n^k (1-p_n)^{n-k} \xrightarrow{n \rightarrow \infty} e^{-\lambda} \frac{\lambda^k}{k!} \quad \forall k \in \mathbb{N}$$

$$\text{Es gilt } e^{-\lambda} \frac{\lambda^k}{k!} \geq 0 \text{ und } e^{-\lambda} \underbrace{\sum_{k=0}^{\infty} \frac{\lambda^k}{k!}}_{e^\lambda} = 1.$$

Eine diskrete ZV X mit Zähldichte $f_X(k) = e^{-\lambda} \frac{\lambda^k}{k!}$ für $k = 0, 1, \dots$ heißt **Poissonverteilt**. ($\lambda > 0$ ein Parameter) Bezeichnung: $X \sim \text{Poi}(\lambda)$, $\lambda > 0$.

Interpretation: n Stücke gleicher Länge



Wahrscheinlichkeit für das Auftreten eines Ereignisses in jedem Teilstück ist $\frac{\lambda}{n}$, Auftreten unabhängig


3.2 Verteilungsfunktionen

Definition 3.8 Eine Funktion $F : \mathbb{R} \rightarrow [0, 1]$ mit den Eigenschaften

- (i) F monoton steigend (nicht notwendigerweise streng monoton)
- (ii) $\lim_{x \rightarrow +\infty} F(x) = 1, \lim_{x \rightarrow -\infty} F(x) = 0$
- (iii) F ist rechtsseitig stetig, d.h. $\forall x_0, x_n \downarrow x_0 : F(x_n) \rightarrow F(x_0)$

heißt **Verteilungsfunktion** (VF) ([cumulative] distribution function, cdf).

Beispiel



Satz 3.9 $(\Omega, \mathfrak{A}, P)$ sei W'raum. $X : (\Omega, \mathfrak{A}) \rightarrow (\mathbb{R}, \mathfrak{B}^1)$ eine ZV.

Durch $F_X(x) = P(X \leq x) = P(\{w \in \Omega | X(w) \leq x\}) = P^X((-\infty, x])$ für $x \in \mathbb{R}$ wird eine Verteilungsfunktion definiert, die **Verteilungsfunktion der ZV X** , bzw. der Verteilung P^X .

Beweis: Übung 5

Verteilungen auf $(\mathbb{R}, \mathfrak{B}^1)$ werden eindeutig durch VF beschrieben.

Satz 3.10 (Eindeutigkeitssatz für VF) 2 ZV X und Y besitzen dieselbe Verteilung (auf $(\mathbb{R}, \mathfrak{B}^1)$) $\iff F_X(x) = F_Y(x)$ für alle $x \in \mathbb{R}$.

Beweis: " \implies " einfach, in Übung 5

" \impliedby " sehr schwierig! Benutzt Fortsetzungs- und Eind.-satz der Maßtheorie

Darstellungsmethoden für Verteilungen/ZV

- Diskrete ZV \rightarrow Zähldichte $f_x(t_i)$
- Auf $(\mathbb{R}, \mathfrak{B}^1)$ Verteilungsfunktionen $F_X(x) = P(X \leq x)$ mit $x \in \mathbb{R}$

Beispiel 3.11 (Verteilungsfunktionen)

a) X heißt **gleichverteilt (rechteckverteilt)** (uniform, rectangle distributed)

auf $[0, 1]$, Bezeichnung $X \sim R(0, 1)$, wenn $F_X(x) = \begin{cases} 0 & , x \leq 0 \\ x & , 0 < x < 1 \\ 1 & , x \geq 1 \end{cases}$


Seien $0 \leq a < b \leq 1$.

$$\begin{aligned} P(a < x \leq b) &= P(\{w | a < X(w) \leq b\}) = P(\{w | X(w) \leq b\} \setminus \{w | X(w) \leq a\}) \\ &= P(\{w | X(w) \leq b\}) - P(\{w | X(w) \leq a\}) = P(X \leq b) - P(X \leq a) \\ &= F_X(b) - F_X(a) = b - a \end{aligned}$$

(W'keit für zufälligen Wert im Intervall $(a, b]$ ist gleich der Länge von $(a, b]$, nämlich $b - a$.)

Analog: Rechteckverteilung auf $[a, b]$, Bezeichnung $X \sim R(a, b)$ für $a < b \in \mathbb{R}$ mit

$$F_X(x) = \begin{cases} 0 & , x \leq a \\ \frac{1}{b-a}(x-a) & , a < x < b \\ 1 & , x \geq b \end{cases}$$




Seien $a \leq c < d \leq b$.

$$P(c < x \leq d) = F_X(d) - F_X(c) = \frac{1}{b-a}(d-a) - \frac{1}{b-a}(c-a) = \frac{1}{b-a}(d-c)$$

b) X heißt **exponentialverteilt**, $X \sim Exp(\lambda)$, $\lambda > 0$ ein Parameter, wenn

$$F_X(x) = \begin{cases} 1 - e^{-\lambda x} & , x \geq 0 \\ 0 & , x < 0 \end{cases} = (1 - e^{-\lambda x}) \cdot \mathbb{1}_{(0, \infty]}(x)$$


Bei dieser Darstellung benutzt: **Indikatorfunktion** $\mathbb{1}_A(x) = \begin{cases} 1 & x \in A \\ 0 & x \notin A \end{cases}$



c) Diskrete ZV X mit geordnetem Träger $T = \{t_1, t_2, \dots\} \subseteq \mathbb{R}$, Zähldichte $f_X(t_i) = p_i$, $p_i \geq 0$ und $\sum_{i=1}^{\infty} p_i = 1$.

$$\text{Dann } F_X(x) = P(X \leq x) = \sum_{k: t_k \leq x} P(X = t_k) = \sum_{k: t_k \leq x} p_k = \sum_{j=1}^{k-1} p_j, \text{ falls}$$

$t_{k-1} \leq x < t_k$, $k = 1, 2, \dots$ (und $t_0 = -\infty$).



Zum Beispiel: $X \sim Geo(p)$ mit $f_X(k) = (1-p)^k p$, $k \in \mathbb{N}_0$ und $(0 < p \leq 1)$.

$$\text{Es gilt: } \sum_{j=0}^k (1-p)^j p = p \frac{1-(1-p)^{k+1}}{1-(1-p)} = 1 - (1-p)^{k+1}$$

$$\text{Also: } F_X(x) = \begin{cases} 0 & , x < 0 \\ 1 - (1-p)^{\lfloor x \rfloor + 1} & , x \geq 0 \end{cases}$$

Berechnung von Wahrscheinlichkeiten mit Verteilungsfunktionen

X sei ZV mit Verteilungsfunktion $F_X(x) = P(X \leq x)$. $a < b \in \mathbb{R}$

- $P(a < X \leq b) = P^X((-\infty, b] \setminus (-\infty, a]) = P^X((-\infty, b]) - P^X((-\infty, a]) = F_X(b) - F_X(a)$
- Sei $a \in \mathbb{R}$, $a_n < a_{n+1} < a$ mit $a_n \rightarrow a$ für $n \rightarrow \infty$. Dann ist $(a_n, a]$ absteigend mit $\lim_{n \rightarrow \infty} (a_n, a] = \{a\}$.

$$P(x = a) = P^X(\{a\}) = P^X(\lim_{n \rightarrow \infty} (a_n, a]) \stackrel{\text{Lemma 2.11b}}{=} \lim_{n \rightarrow \infty} P^X((a_n, a])$$

$$= \lim_{n \rightarrow \infty} (F_X(a) - F_X(a_n)) = F_X(a) - \lim_{n \rightarrow \infty} F_X(a_n) = F_X(a) - F_X(a-)^5$$

Insbesondere: Ist F_X stetig, so gilt $P(X = a) = 0$ für alle $a \in \mathbb{R}$.


- $P(a \leq X \leq b) = P(X = a) + P(a < X \leq b) = F_X(a) - F_X(a-) + F_X(b) - F_X(a) = F_X(b) - F_X(a-)$

Bedienzeit X von Anforderungen an einen Server seien $Exp(\lambda)$ -verteilt, $X \sim Exp(\lambda)$, $\lambda > 0$.

Problem: Bestimme die Zeit X_α , unterhalb derer die Bedienzeit mit vorgegebener Wahrscheinlichkeit α liegt, z.B. $\alpha = 0.99$. Bestimme also X_α mit $P(X \leq X_\alpha) = \alpha$.

Interpretation: In 99% der Fälle ist die Bedienzeit kürzer als X_α .

Graphisch für $X \sim Exp(\lambda)$:



Definition 3.12 X sei ZV mit Verteilungsfunktion $F_X(x)$, $0 \leq \alpha \leq 1$.

$X_\alpha = \min\{x | F_X(x) \geq \alpha\}$ heißt **α -Quantil** (α -Percentil, $(1 - \alpha)$ -Fraktile) von F_X . $F_X^-(t) = \min\{x | F_X(x) \geq t\}$, $t \in (0, 1)$, heißt **Pseudoinverse** von F_X . (Nötig, weil X_α genau in einem Sprung von F_X liegen könnte.)


- Graphisch bei nicht-stetigen Vfkt.
- Ist F invertierbar, so gilt $F^- = F^{-1}$ (Inverse).

Betrachte: $\alpha = \frac{1}{2}$. $X_{\frac{1}{2}}$ heißt **Median** von F_X . Es gilt $P(X \leq X_{\frac{1}{2}}) \leq \frac{1}{2}$ und $P(X < X_{\frac{1}{2}} \leq \frac{1}{2}) \leq \frac{1}{2}$. Der Median "halbiert" die Verteilung, ist in diesem Sinn der "mittlere Wert". Der Median ist ein Schätzer für den mittleren Wert, der robust gegen Ausreißer ist.

3.3 Dichten

Methode zur Konstruktion von Verteilungsfunktionen, Verteilungen.

Definition 3.13 $f: \mathbb{R} \rightarrow \mathbb{R}^+$ sei (uneigentlich Riemann-)integrierbar mit $\int_{-\infty}^{\infty} f(x) dx = 1$. Durch $F(x) = \int_{-\infty}^x f(t) dt$ wird eine Verteilungsfunktion definiert.



⁵linksseitiger Grenzwert von $F_X(a)$

Gilt für eine ZV X , daß $F_X(x) = F(x)$, so heißt f (**Verteilungs-**) **Dichte** (probability density function (pdf)) von X bzw. P^X . X bzw. P^X heißt dann **absolut-stetig**.


Mit dem Hauptsatz der Differential- und Integralrechnung: $f(x) = F'(X)$ für alle Stetigkeitspunkte x von f .

Beispiel 3.14

a) Rechteckverteilung auf $[a, b]$, $a < b \in \mathbb{R}$, $X \sim R(a, b)$:

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

$$F(x) = \int_{-\infty}^x f(t)dt = \begin{cases} \frac{1}{b-a}(x-a) & , a \leq x \leq b \\ 0 & , x \leq a \\ 1 & , x \geq b \end{cases}$$




Beachte: Die Dichte $\hat{f}(x) = \frac{1}{b-a} \mathbb{1}_{(a,b)}(x)$ führt zu derselben Verteilungsfunktion F . Dichten sind nicht eindeutig, sie sind "fast sicher" eindeutig.

b) Exponentialverteilung, $X \sim Exp(\lambda)$ mit $\lambda > 0$:

$$f(x) = \lambda e^{-\lambda x} \mathbb{1}_{[0,\infty)}(x) \text{ für alle } x \in \mathbb{R}$$

$$F(x) = \int_{-\infty}^x f(t)dt = \int_0^x \lambda e^{-\lambda t} dt = -e^{-\lambda t} \Big|_0^x$$


$$= 1 - e^{-\lambda x} \text{ mit } x \geq 0$$



c) Normalverteilung, $X \sim N(\mu, \sigma^2)$ mit $\mu \in \mathbb{R}$, $\sigma > 0$:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \text{ für alle } x \in \mathbb{R}$$

$$F(x) = \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^x e^{-\frac{(t-\mu)^2}{2\sigma^2}} dt$$



hat keine "geschlossene" Darstellung. Berechnung numerisch, approximativ oder mit Tabellen.

Berechnung von Wahrscheinlichkeiten mit Dichten

X sei ZV mit Verteilungsfunktion F_X und f_X , $a < b \in \mathbb{R}$.

- $P(a < X \leq b) = F_X(b) - F_X(a) = \int_{-\infty}^b f_X(t)dt - \int_{-\infty}^a f_X(t)dt = \int_a^b f_X(t)dt$
- $P(X = a) = F_X(a) - F_X(a-) = 0$, da $F_X(x) = \int_{-\infty}^x f_X(t)dt$ stetig
- $P(a < X \leq b) = \int_a^b f_X(t)dt$
- Allgemein gilt bei absolut-stetigen ZV (also solchen mit Dichte)
 $P(X \in \langle a, b \rangle) = \int_a^b f_X(t)dt$, wobei \langle bzw. \rangle beliebig für "abgeschlossen" oder "offen" steht
- Schreibe allgemein für Mengen $B \in \mathfrak{B}^1$: $P(X \in B) = \int_B f_X(t)dt$ (auch wenn B kein Intervall)

3.4 Erzeugende Funktionen und Laplace-Transformierte

Eine weitere Methode zur eindeutigen Beschreibung von Verteilungen.

Definition 3.15

- a) X sei diskrete ZV mit Träger $T = \{t_1, t_2, \dots\}$ und Zähldichte $f_X(t_k) = p_k$ mit $k \in \mathbb{N}_0$. Dann heißt $G_X(z) = \sum_{k=0}^{\infty} p_k z^k$ mit $|z| < 1$ **erzeugende Funktion** von X bzw. P^X (probability generating function).
- b) X sei absolut-stetig mit Dichte f_X , wobei $f_X(x) = 0$, falls $x < 0$ (d.h. $P(X < 0) = 0$). Dann heißt $L_X(s) = \int_0^{\infty} e^{-sx} f_X(x) dx$ mit $s \geq 0$ die **Laplace-Transformierte** von X bzw. P^X .

Analog zu Satz 3.10 für Verteilungsfunktionen gilt auch hier Eindeutigkeit.

Satz 3.16

- a) X und Y seien diskrete Zufallsvariablen mit demselben Träger T . X und Y besitzen dieselbe Verteilung $\iff G_X(z) = G_Y(z)$ für alle $|z| \leq 1$.
- b) X, Y seien absolut-stetig mit $f_X(x) = f_Y(x) = 0$ für alle $x < 0$. X und Y haben dieselbe Verteilung $\iff L_X(s) = L_Y(s)$ für alle $s \geq 0$.

Beweis:

- a) Eindeutigkeitssatz für Potenzreihen
 b) Feller II, Seite 403, Kapitel XIII oder Satz von Stone-Weierstraß

Satz 3.17 (Inversionsformeln)

- a) $G_X(z)$ sei erzeugende Funktion einer diskreten ZV X mit Träger $T = \{t_1, t_2, \dots\}$. Dann gilt $P(X = t_k) = \frac{1}{k!} G_X^{(k)}(0)$.
- b) $L_X(s)$ sei Laplace-Transformierte einer absolut-stetigen ZV X . Dann gilt:

$$f_X(x) = \lim_{y \rightarrow \infty} \frac{1}{2\pi i} \int_{c-iy}^{c+iy} e^{sx} L_X(s) ds \text{ für alle } c \in \mathbb{R}$$
 (Integration über den Weg $c - iy \rightarrow c + iy$)

Beispiel 3.18

- a) Geometrische Verteilung, $X \sim Geo(p)$ mit $0 < p \leq 1$

$$G_X(z) = \sum_{k=0}^{\infty} (1-p)^k p z^k = p \sum_{k=0}^{\infty} ((1-p)z)^k = \frac{p}{1-z+pz} \text{ mit } |z| \leq 1$$
- b) Poissonverteilung, $X \sim Poi(\lambda)$ mit $\lambda > 0$

$$G_X(z) = \sum_{k=0}^{\infty} e^{-\lambda} \frac{\lambda^k}{k!} z^k = e^{-\lambda} \sum_{k=0}^{\infty} \frac{(\lambda z)^k}{k!} = e^{-\lambda} e^{\lambda z} = e^{-\lambda(1-z)} \text{ für alle } z \in \mathbb{R}$$

c) Rechteckverteilung, $X \sim R(0, 1)$

$$L_X(s) = \int_0^1 e^{-sx} dx = \frac{1-e^{-s}}{s} \text{ für alle } s \geq 0$$

d) Exponentialverteilung, $X \sim Exp(\lambda)$

$$L_X(s) = \int_0^{\infty} e^{-sx} \lambda e^{-\lambda x} dx = \frac{\lambda}{\lambda+s} \underbrace{\int_0^{\infty} (\lambda+s)e^{-(s+\lambda)x} dx}_{1, \text{ da Integral über die Dichte}} = \frac{\lambda}{\lambda+s}$$

e) Gammaverteilung, $X \sim \Gamma(\alpha, \lambda)$

$$L_X(s) = \int_0^{\infty} e^{-sx} \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x} dx = \frac{\lambda^\alpha}{(\lambda+s)^\alpha} \underbrace{\int_0^{\infty} \frac{(\lambda+s)^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-(\lambda+s)x} dx}_1 = \left(\frac{\lambda}{\lambda+s}\right)^\alpha$$

f) Erlangverteilung, $X \sim Erl(n, \lambda) = \Gamma(n, \lambda)$ für $n \in \mathbb{N}$

L wie in e) oder alternativ mit Satz 6.10 für X als Faltung der Exp -Vert.:

$$L_{X_1+\dots+X_n}(s) = L_{X_1}(s) \cdot \dots \cdot L_{X_n}(s) = L_{X_1}^n(s) \text{ für stid } X_i,$$

$$\text{hier: } X_i \sim Exp(\lambda), L_{X_i} = \frac{\lambda}{\lambda+s}, \text{ also } L_{X_1}^n(s) = \left(\frac{\lambda}{\lambda+s}\right)^n$$


Nice to know...

$$\sum_{k=0}^{\infty} x^k = \frac{1}{1-x}$$

$$\sum_{k=0}^{\infty} \frac{x^k}{k!} = e^x$$

4 Produkträume und Zufallsvektoren

Zufallsexperimente mit mehreren Ausgängen (gleichzeitig oder dasselbe Experiment mehrfach wiederholt).



Ausgänge gemeinsam betrachten: $(\Omega, \mathfrak{A}, P) \xrightarrow{X=(X_1, \dots, X_n)} (\mathbb{R}^n, ?, ?)$

4.1 Produkträume

Gegeben Meßräume $(\Omega_i, \mathfrak{A}_i)$ für $i = 1, \dots, n$. Oft $(\Omega_i, \mathfrak{A}_i) = (\mathbb{R}, \mathfrak{B}^1)$.

Setze $\Omega = \times_{i=1}^n \Omega_i = \{w = (w_1, \dots, w_n) | w_i \in \Omega_i\}$.


Frage: Welche σ -Algebra über Ω wählen?

Ansatz: $\varepsilon = \{A_1 \times \dots \times A_n | A_i \in \mathfrak{A}_i, i = 1, \dots, n\}$

Aber: ε ist im Allgemeinen keine σ -Algebra über $\Omega = \times_{i=1}^n \Omega_i$.

Gegenbeispiel: $\Omega_1 = \Omega_2 = \mathbb{R}$, $\mathfrak{A}_1 = \mathfrak{A}_2 = \mathfrak{B}^1$. Dann $C_1 = [-1, 0] \times [-1, 0] \in \varepsilon$,
 $C_2 = [0, 1] \times [0, 1] \in \varepsilon$, aber $C_1 \cup C_2 \notin \varepsilon$,

ist nicht als kartesisches Produkt



zweier Mengen darstellbar.

Definition 4.1 (Produkt- σ -Algebra)

$(\Omega_i, \mathfrak{A}_i)$ seien Meßräume, $i = 1, \dots, n$. $\varepsilon = \{A_1 \times \dots \times A_n | A_i \in \mathfrak{A}_i, i = 1, \dots, n\}$.


$\otimes_{i=1}^n \mathfrak{A}_i := \mathfrak{A}(\varepsilon)$ ⁶ heißt **Produkt- σ -Algebra** von $\mathfrak{A}_1, \dots, \mathfrak{A}_n$ über $\Omega = \times_{i=1}^n \Omega_i$.

$(\times_{i=1}^n \Omega_i, \otimes_{i=1}^n \mathfrak{A}_i)$ heißt **Produkt-Meßraum** der $(\Omega_i, \mathfrak{A}_i)$ für $i = 1, \dots, n$.

Beispiel 4.2 $(\Omega_i, \mathfrak{A}_i) = (\mathbb{R}, \mathfrak{B}^1)$. $\varepsilon = \{B_1 \times \dots \times B_n | B_i \in \mathfrak{B}^1\}$.

$\mathfrak{A}(\varepsilon)$ heißt **n -dimensionale Borelsche σ -Algebra**.

Graphisch für $n = 2$:



" \mathfrak{B}^n enthält alle n -dimensionalen Rechtecke"

4.2 Zufallsvektoren und Folgen von Zufallsvariablen

Definition 4.3 $(\Omega, \mathfrak{A}, P)$ sei W'raum. Eine Abb. $X = (X_1, \dots, X_n) : \Omega \rightarrow \mathbb{R}^n$ heißt **Zufallsvektor**, wenn $X^{-1}(B) \in \mathfrak{A}$ für alle $B \in \mathfrak{B}^n$ (Meßbarkeit). Bezeichnung: $X : (\Omega, \mathfrak{A}) \rightarrow (\mathbb{R}^n, \mathfrak{B}^n)$.

Bemerkung: Es gilt: $X = (X_1, \dots, X_n)$ ist Zufallsvektor $\iff X_1, \dots, X_n$ sind ZV.

⁶D.h. wir definieren $\otimes_{i=1}^n \mathfrak{A}_i$ als die von ε erzeugte σ -Algebra

Lemma 4.4 X sei Zufallsvektor.

Durch $P^X(B) = P(X^{-1}(B)) = P(\{w|X(w) \in B\}) \stackrel{\text{kurz}}{=} P(X \in B)$ für alle $B \in \mathfrak{B}^n$ wird eine Wahrscheinlichkeitsverteilung auf $(\mathbb{R}^n, \mathfrak{B}^n)$ definiert.

$P^X = P^{(X_1, \dots, X_n)}$ heißt **gemeinsame Verteilung** von (X_1, \dots, X_n) .

Im folgenden werden gemeinsame Verteilungen mit Verteilungsfunktionen und Dichten beschrieben. Klar: X_1, \dots, X_n diskret $\implies (X_1, \dots, X_n)$ diskret. Verteilung mit Zähldichten, wie in Kapitel 3 beschreiben.

Satz 4.5 X sei Zufallsvektor. P^X wird eindeutig beschrieben durch die (n -dimensionale) Verteilungsfunktion $F_X(x_1, \dots, x_n) = P^X((-\infty, x_1] \times \dots \times (-\infty, x_n]) = P^X(\{w|X_1(w) \in (-\infty, x_1], \dots, X_n(w) \in (-\infty, x_n]\})$
 $= P(\{w|X_1(w) \leq x_1\} \cap \dots \cap \{w|X_n(w) \leq x_n\}) \stackrel{\text{kurz}}{=} P(X_1 \leq x_1, \dots, X_n \leq x_n)$.
 Bezeichnung: $X \sim F_X$

Beschreibung von Verteilungen mit n -dimensionalen Dichten ist oft einfacher.

Definition 4.6 $F_X(x_1, \dots, x_n)$ sei die Verteilungsfunktion des Zufallsvektors X . Eine (uneigentlich Riemann-)integrierbare Funktion $f_X : \mathbb{R}^n \rightarrow \mathbb{R}^+$ heißt **Dichte** von X , wenn $F_X(x_1, \dots, x_n) = \int_{-\infty}^{x_n} \dots \int_{-\infty}^{x_1} f(t_1, \dots, t_n) dt_1 \dots dt_n$ für alle $x_1, \dots, x_n \in \mathbb{R}$. X heißt dann **absolut-stetig** mit Dichte f_X .

Bezeichnung: $X \sim f_X$.

Sprechweisen: X hat/besitzt/ist verteilt nach Vfkt. F_X /Dichte f_X .

Berechnung von Wahrscheinlichkeiten mit Dichten:

$X = (X_1, \dots, X_n)$ sei absolut-stetig mit Verteilung P^X , Verteilungsfunktion F_X und Dichte f_X . Dann ist $P^X(\langle a_1, b_1 \rangle \times \dots \times \langle a_1, b_1 \rangle) = P(a_1 \leq X_1 \leq b_1, \dots, a_n \leq X_n \leq b_n) = \int_{a_n}^{b_n} \dots \int_{a_1}^{b_1} f_X(t_1, \dots, t_n) dt_1 \dots dt_n$ für alle $a_i \leq b_i \in \mathbb{R}$, wobei "("
 bzw. ")
" beliebig für "offen" oder "abgeschlossen" stehen.

Allgemein: $P^X(B) = \int_{\dot{B}} \dots \int f_X(t_1, \dots, t_n) dt_1 \dots dt_n$ für alle $B \in \mathfrak{B}^n$.

Mit dem Hauptsatz der Differential- und Integralrechnung gilt $f_X(x_1, \dots, x_n) = \frac{\partial}{\partial x_1 \dots \partial x_n} F_X(x_1, \dots, x_n)$ in allen Stetigkeitspunkten (x_1, \dots, x_n) von f_X .

Beispiel 4.7 (Indizierung mit X zur Vereinfachung weggelassen)

a) Gleichverteilung auf $T \in \mathfrak{B}^n$ mit $c = \int_{\dot{T}} \dots \int 1 dx_1 \dots dx_n < \infty$


$$F(x_1, \dots, x_n) = \frac{1}{c} \mathbb{1}_T(x_1, \dots, x_n) = \begin{cases} \frac{1}{c} & , (x_1, \dots, x_n) \in T \\ 0 & , \text{sonst} \end{cases}$$

Speziell:

- Auf dem Einheitswürfel des \mathbb{R}^n
 $T = \{(x_1, \dots, x_n) | 0 \leq x_i \leq 1, i = 1, \dots, n\} = [0, 1]^n$
 $f(x_1, \dots, x_n) = \mathbb{1}_T(x_1, \dots, x_n)$

$$F(x_1, \dots, x_n) = \begin{cases} 0 & , \exists i : x_i < 0 \\ \min\{x_1, 1\} \cdot \dots \cdot \min\{x_n, 1\} & , \text{sonst} \end{cases}$$

Graphisch für $n = 2$:



- Auf der Einheitskugel des \mathbb{R}^n

$$T = \{(x_1, \dots, x_n) \mid \sum_{i=1}^n x_i^2 \leq 1\}, \quad c = \frac{\pi^{\frac{n}{2}}}{\Gamma(\frac{n}{2}+1)} \text{ Volumen der Einheitskugel}$$

$$\Gamma(n) = (n-1)! \text{ für alle } n \in \mathbb{N}, \Gamma(\frac{1}{2}) = \sqrt{\pi}, \Gamma(x+1) = x\Gamma(x)$$

$$f(x_1, \dots, x_n) = \frac{\Gamma(\frac{n}{2}+1)}{\pi^{\frac{n}{2}}} \mathbb{1}_T(x_1, \dots, x_n) \text{ mit } (x_1, \dots, x_n) \in \mathbb{R}^n$$

Die Verteilungsfunktion ist schwierig zu berechnen \rightarrow Dirichlet-Integral

- b) n -dimensionale Normalverteilung, $X \sim N(\mu, \Sigma)$, $\mu \in \mathbb{R}^n$, $\Sigma \in \mathbb{R}^{n \times n}$ positiv definit. Für $x = (x_1, \dots, x_n)^T \in \mathbb{R}^n$ ist

$$f(x_1, \dots, x_n) = \frac{1}{(2\pi)^{\frac{n}{2}} (\det \Sigma)^{\frac{1}{2}}} e^{-\frac{1}{2}(x-\mu)^T \Sigma^{-1} (x-\mu)}$$

- c) $f_1, \dots, f_k : \mathbb{R}^n \rightarrow \mathbb{R}^+$ seien n -dim. Dichten (auch $n = 1$), $\alpha_1, \dots, \alpha_k \geq 0$, $\sum_{i=1}^k \alpha_i = 1$. Dann ist $f(x) = \sum_{i=1}^k \alpha_i f_i(x)$, $x = (x_1, \dots, x_n) \in \mathbb{R}^n$, eine n -dimensionale Dichte. $f(x)$ heißt **Mischung** der Dichten f_1, \dots, f_k .

Stochastische Unabhängigkeit

Definition 4.8 X_1, \dots, X_n seien ZV. (Dann ist $X = (X_1, \dots, X_n)$ ein Zufallsvektor.) X_1, \dots, X_n heißen **stochastisch unabhängig**, wenn $F_X(x_1, \dots, x_n) = F_{X_1}(x_1) \cdot \dots \cdot F_{X_n}(x_n)$ für alle $(x_1, \dots, x_n) \in \mathbb{R}^n$.

Also: X_1, \dots, X_n stoch. unabh., wenn $P(X_1 \leq x_1, \dots, X_n \leq x_n) = P(X_1 \leq x_1) \cdot \dots \cdot P(X_n \leq x_n)$ für alle $(x_1, \dots, x_n) \in \mathbb{R}^n$.

$P(\{w \mid X_1(w) \leq x_1\} \cap \dots \cap P(\{w \mid X_n(w) \leq x_n\}) = P(\{w \mid X_1(w) \leq x_1\} \cdot \dots \cdot P(\{w \mid X_n(w) \leq x_n\})$, d.h. X_1, \dots, X_n sind stoch. unabh. genau dann, wenn die Ereignisse $\{w \mid X_i(w) \leq x_i\}$ für $i = 1, \dots, n$ und alle x_1, \dots, x_n stoch. unabh. im Sinn der Definition 2.16 sind.

(Beachte: Auswahlen von i_1, \dots, i_k durch Setzen der anderen $x_j = \infty$.)

Lemma 4.9 (X_1, \dots, X_n) sei Zufallsvektor, absolut-stetig mit Dichte $f_{(X_1, \dots, X_n)}$.

Dann hat jedes der X_i eine Dichte $f_{X_i}(x)$

$$= \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_{(X_1, \dots, X_n)}(x_1, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_n) dx_1 \dots dx_{i-1} dx_{i+1} \dots dx_n.$$

Es gilt: $f_{(X_1, \dots, X_n)}(x_1, \dots, x_n) = \prod_{i=1}^n f_{X_i}(x_i)$ für alle $x_1, \dots, x_n \in \mathbb{R}$

$\implies X_1, \dots, X_n$ stoch. unabh.

Umgekehrt: Sind X_1, \dots, X_n stoch. unabh., absolut-stetig mit Dichten f_{X_i} , so ist $f_{(X_1, \dots, X_n)}(x_1, \dots, x_n) = \prod_{i=1}^n f_{X_i}(x_i)$ für alle $(x_1, \dots, x_n) \in \mathbb{R}^n$ eine Dichte des Zufallsvektors (X_1, \dots, X_n) .

Beweis:

$$f_{X_i}(x) = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} f_{(X_1, \dots, X_n)}(x_1, \dots, x_{i-1}, x, x_{i+1}, \dots, x_n) dx_1 \dots dx_{i-1} dx_{i+1} \dots dx_n$$

ist eine Dichte von x_i , da $F_{X_i}(x) = P(X_i \leq x) = \int_{-\infty}^x f_{X_i}(t_i) dt_i$.

$$\text{Es gilt } F_{(X_1, \dots, X_n)}(x_1, \dots, x_n) = \int_{-\infty}^{x_n} \dots \int_{-\infty}^{x_1} \prod_{i=1}^n f_{X_i}(t_i) dt_i \dots dt_n$$

$$= \prod_{i=1}^n \int_{-\infty}^{x_i} f_{X_i}(t_i) dt_i = \prod_{i=1}^n F_{X_i}(x_i) \text{ f\"ur alle } x_1, \dots, x_n \in \mathbb{R}.$$

Also X_1, \dots, X_n stochastisch unabhängig nach Definition 4.8.

$$\text{Umgekehrt: } X_1, \dots, X_n \text{ stoch. unabh.} \implies F_{(X_1, \dots, X_n)}(x_1, \dots, x_n) = \prod_{i=1}^n F_{X_i}(x_i)$$

$$= \prod_{i=1}^n \int_{-\infty}^{x_i} f_{X_i}(t_i) dt_i = \int_{-\infty}^{x_n} \dots \int_{-\infty}^{x_1} \prod_{i=1}^n f_{X_i}(t_i) dt_i \dots dt_n \implies \prod_{i=1}^n f_{X_i}(x_i) \text{ ist eine}$$

Dichte von (X_1, \dots, X_n) .

Im Fall von Zähldichten vereinfacht sich Lemma 4.9 zu:

Lemma 4.10 X_1, \dots, X_n seien diskrete ZV mit Trägern T_1, \dots, T_n . Dann gilt:
 X_1, \dots, X_n stoch. unabh. $\iff P(X_1 = t_1, \dots, X_n = t_n) = \prod_{i=1}^n P(X_i = x_i)$ für alle $t_i \in T_i$.

Beweis: Übung 8 Aufgabe 29

Definition 4.11 Eine Folge von ZV $\{X_n\}_{n \in \mathbb{N}}$ auf einem W'raum $(\Omega, \mathfrak{A}, P)$ heißt **stochastisch unabhängig**, wenn X_1, \dots, X_n stochastisch unabhängig für alle $n \in \mathbb{N}$. Besitzen stochastisch unabhängige ZV alle dieselbe Verteilung, so heißen sie **stochastisch unabhängig identisch verteilt (stid)** (i.i.d., independent identically distributed).

Beispiel 4.12

a) X_1, X_2 stid $\sim \text{Bin}(n, p)$

$$\begin{aligned} P(X_1 = X_2) &= P^{(X_1, X_2)}(\{(i, j) | 0 \leq i, j \leq n, i = j\}) \\ &= \sum_{i=0}^n P^{(X_1, X_2)}(\{(i, i)\}) = \sum_{i=0}^n P(X_1 = i, X_2 = i) \\ &= \sum_{i=0}^n P(X_1 = i)P(X_2 = i) = \sum_{i=0}^n \left[\binom{n}{i} p^i (1-p)^{n-i} \right]^2 \end{aligned}$$

b) X_1, X_2 stochastisch unabhängig, absolut-stetig mit Dichten f_1, f_2

$$P(X_1 = X_2) = \int \int_{X_1=X_2} f(x_1, x_2) dx_1 dx_2 = \int_{-\infty}^{\infty} \underbrace{\int_{x_2}^{x_2} f_1(x_1) dx_1}_{0} f_2(x_2) dx_2 = 0$$

$$\boxed{f(x_1, x_2) = f_1(x_1) f_2(x_2)}$$

Beispiel 4.13 X_1, \dots, X_n stid $\sim F$ (Verteilungsfunktion)

a) $Y = \max^7\{X_1, \dots, X_n\}$

Interpretation z.B. Maximum der Laufzeiten (X_1, \dots, X_n)

$$P(Y \leq x) = P(X_1 \leq x, \dots, X_n \leq x) = \prod_{i=1}^n P(X_i \leq x) = F^n(x) \text{ für alle } x \in \mathbb{R}$$

Also: $Y = \max\{X_1, \dots, X_n\}$ hat die Verteilungsfunktion $F^n(x)$.

b) $Y = \min\{X_1, \dots, X_n\}$

$$P(Y > x) = P(X_1 > x, \dots, X_n > x) = (1 - F(x))^n$$

Also: $Y = \min\{X_1, \dots, X_n\}$ hat die Verteilungsfunktion $1 - (1 - F(x))^n$.

Z.B. X_i stid $\sim \text{Exp}(\lambda)$, dann $P(Y \leq x) = 1 - e^{-n\lambda x} \implies Y \sim \text{Exp}(n\lambda)$

Beispiel 4.14 X_1, X_2 stid $\sim \text{Exp}(\lambda)$ mit $\lambda > 0$

$$P(X_1 + X_2 \leq z) = \int_{0 \leq X_1 + X_2 \leq z} \int \lambda e^{-\lambda x_1} \mathbb{1}_{[0, \infty)}(x_1) \lambda e^{-\lambda x_2} \mathbb{1}_{[0, \infty)}(x_2) dx_1 dx_2$$

$$= \int_0^z \int_0^{z-x_2} \lambda e^{-\lambda x_1} \lambda e^{-\lambda x_2} dx_1 dx_2 = \int_0^z \lambda e^{-\lambda x_2} [1 - e^{-\lambda(z-x_2)}] dx_2$$

$$= \int_0^z [\lambda e^{-\lambda x_2} - \lambda e^{-\lambda z}] dx_2 = 1 - e^{-\lambda z} - \lambda z e^{-\lambda z} = F_{X_1+X_2}(z) \text{ für } z \geq 0$$

Durch Differenzieren:

$$f_{X_1+X_2}(z) = \lambda e^{-\lambda z} - \lambda(e^{-\lambda z} - \lambda z e^{-\lambda z}) = \lambda^2 z e^{-\lambda z} \text{ für } z \geq 0$$

Also: Die Verteilung der Summe von stochastisch unabhängig identisch $\text{Exp}(\lambda)$ -verteilten ZV ist absolut stetig mit Dichte $f(x) = \lambda^2 x e^{-\lambda x} \mathbb{1}_{[0, \infty)}(x)$.

Eine allgemeine Klasse von Verteilungen, die diese Dichte als Spezialfall enthält, sind die **Γ -Verteilungen** mit den Dichten $f_{\alpha, \lambda}(x) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x} \mathbb{1}_{[0, \infty)}(x)$ mit $\alpha, \lambda > 0$ als Parameter, wobei $\Gamma(\alpha) = \int_0^\infty x^{\alpha-1} e^{-x} dx$ das Γ -Integral (insbesondere $\Gamma(n) = (n-1)! \quad \forall n \in \mathbb{N}$) ist. Eine ZV mit Dichte $f_{\alpha, \lambda}(x)$ heißt $\Gamma(\alpha, \lambda)$ -verteilt.

Spezialfälle:

(i) $\alpha = 1 \rightarrow \text{Exp}(\lambda)$ -Verteilung

(ii) $\alpha = 2 \rightarrow$ s.o., Verteilung der Summe von 2 stid $\text{Exp}(\lambda)$ -verteilten ZV

(iii) $\alpha = n \in \mathbb{N} \rightarrow$ Erlang-Verteilung mit Parametern n, λ

$$f_{n, \lambda}(x) = \frac{\lambda^n}{(n-1)!} x^{n-1} e^{-\lambda x} \mathbb{1}_{[0, \infty)}(x)$$

Beispiel 4.15 $\{X_n\}_{n \in \mathbb{N}}$ Folge von stid ZV, $B \in \mathfrak{B}^1$.

$S = \min\{n \in \mathbb{N} | X_n \in B\}$ heißt **erste Eintrittszeit in B** .

Verteilung von S : $P(S = k) = P(X_1 \notin B, \dots, X_{k-1} \notin B, X_k \in B)$
 $= P(X_1 \notin B) \cdot \dots \cdot P(X_{k-1} \notin B) P(X_k \in B) = (1-p)^{k-1} p$ für $k \in \mathbb{N}$,
wobei $p = P(X_1 \in B) = \dots = P(X_n \in B)$.

Also: S geometrisch verteilt mit Träger \mathbb{N} . $S - 1 \sim \text{Geo}(p)$

Konkret: unabhängige Folge von Münzwürfen, X_n stid $\sim \text{Bin}(1, p)$

⁷punktweises Maximum der X_i an den Trägerpunkten

Setze $B = \{1\}$. $P(X_n \in \{1\}) = P(X_n = 1) = p$.

$\{S = k\}$: Beim k -ten Wurf tritt erstmalig eine 1 ("Kopf, Treffer") auf

Setze $X = S - 1 =$ "Wartezeit bis zum ersten Treffer". Dann $X \sim Geo(p)$

Satz 4.16 X_1, \dots, X_n seien stochastisch unabhängige ZV und $I, J \subseteq \{1, \dots, n\}$, $I \cap J = \emptyset$. Dann sind $(X_i)_{i \in I}$ und $(X_j)_{j \in J}$ stochastisch unabhängige ZV. Sind f, g meßbare Abbildungen (mit entsprechenden Bild-Meßräumen), so sind $f((X_i)_{i \in I})$ und $g((X_j)_{j \in J})$ stochastisch unabhängig.

Beweis: Mathar & Pfeiffer, Lemma 2.1.6 und Lemma 2.1.7, Seite 74

Beispiel 4.17 X_1, X_2, X_3, X_4 stochastisch unabhängig $\implies X_1 + X_2, X_3 + X_4$ stochastisch unabhängig

5 Transformationen von ZV/Verteilungen

Im folgenden: allgemeine Hilfsmittel zur Berechnung der Verteilung von Funktionen von Zufallsvariablen

Satz 5.1 (Transformationen für Dichten)

$X = (X_1, \dots, X_n)$ sei absolut-stetiger Zufallsvektor auf dem W'raum $(\Omega, \mathfrak{A}, P)$ mit Dichte f_X . Gelte $f_X(x_1, \dots, x_n) = 0$ für alle $(x_1, \dots, x_n) \in M^c$ für eine offene Menge $M \subseteq \mathbb{R}^n$. $T : (\mathbb{R}^n, \mathfrak{B}^n) \rightarrow (\mathbb{R}^n, \mathfrak{B}^n)$ sei eine meßbare Abbildung (Zufallsvektor, $T^{-1}(B) \in \mathfrak{B}^n \quad \forall B \in \mathfrak{B}^n$) mit

- (i) $\tilde{T} = T|_M$ ist injektiv (Restriktion von T auf M)
- (ii) \tilde{T} ist stetig differenzierbar auf M
- (iii) $\det \left(\left(\frac{\partial \tilde{T}_i}{\partial X_j} \right)_{1 \leq i, j \leq n} \right) \neq 0$ auf M (Funktionsdeterminante)

Dann ist $Y = \tilde{T}(X)$ absolut-stetig mit Dichte

$$\begin{aligned} f_Y(y_1, \dots, y_n) &= \frac{f_X(\tilde{T}^{-1}(y_1, \dots, y_n))}{\left| \det \left(\left(\frac{\partial \tilde{T}_i}{\partial x_j} \right)_{1 \leq i, j \leq n} \Big|_{\tilde{T}^{-1}(y_1, \dots, y_n)} \right) \right|} \cdot \mathbb{1}_{\tilde{T}(M)}(y_1, \dots, y_n) \\ &= \left| \det \left(\left(\frac{\partial \tilde{T}_i^{-1}}{\partial y_j} \right)_{1 \leq i, j \leq n} \right) \right| \cdot f_X(\tilde{T}^{-1}(y_1, \dots, y_n)) \cdot \mathbb{1}_{\tilde{T}(M)}(y_1, \dots, y_n) \end{aligned}$$

Beweis: Krickeberg (63)

Beispiel 5.2

$X = (X_1, X_2)$ gleichverteilt auf $Q = (0, 1)^2$ mit Dichte $f_X(x_1, x_2) = \mathbb{1}_Q(x_1, x_2)$, d.h. X_1, X_2 stochastisch unabhängig, $X_i \sim R(0, 1)$, $i = 1, 2$.

$T(X_1, X_2) = (\sqrt{x_1} \cos(2\pi x_2), \sqrt{x_1} \sin(2\pi x_2))$ mit $(x_1, x_2) \in Q$

$$\begin{aligned} \det \left(\left(\frac{\partial \tilde{T}_i}{\partial y_j} \right)_{1 \leq i, j \leq n} \right) &= \det \begin{pmatrix} \frac{1}{2\sqrt{x_1}} \cos(2\pi x_2) & -2\pi \sqrt{x_1} \sin(2\pi x_2) \\ \frac{1}{2\sqrt{x_1}} \sin(2\pi x_2) & 2\pi \sqrt{x_1} \cos(2\pi x_2) \end{pmatrix} \\ &= \pi \cos^2(2\pi x_2) + \pi \sin^2(2\pi x_2) = \pi \underbrace{(\cos^2(2\pi x_2) + \sin^2(2\pi x_2))}_{=1} = \pi \end{aligned}$$

$Y = T(X)$ besitzt nach Satz 5.1 eine Dichte $f_Y(y_1, y_2) = \frac{1}{\pi} \mathbb{1}_{T(Q)}(y_1, y_2)$ ⁸ mit $\hat{K} = T(Q) =$ "Einheitskreis ohne die positive X -Achse"

Also: $Y = T(X)$ ist gleichverteilt auf dem Einheitskreis. (Vergleiche Beispiel 4.7)

⁸ $f_X(T^{-1}(y_1, y_2)) = \mathbb{1}_Q(T^{-1}(y_1, y_2)) = \mathbb{1}_{T(Q)}(y_1, y_2)$

Beispiel 5.3 (Rayleigh-Verteilung) X, Y stid $\sim N(0, \sigma^2)$, also gemeinsame

Dichte $f_{(X,Y)}(x, y) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \cdot \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{y^2}{2\sigma^2}}$ mit $(x, y) \in \mathbb{R}^2$

Transformation in Polarkoordinaten

$(r, \varphi) = T(X, Y) : \mathbb{R}^2 \setminus \{0\} \rightarrow (0, \infty) \times (0, 2\pi)$ mit $r = \sqrt{x^2 + y^2}$ und

$$\varphi = \begin{cases} \arctan\left(\frac{y}{x}\right) & , y > 0 \\ \pi + \arctan\left(\frac{y}{x}\right) & , y < 0 \end{cases}, \text{ wobei } \arctan(\pm\infty) = \frac{\pi}{2}.$$

$(x, y) = T^{-1}(r, \varphi) = (r \cos \varphi, r \sin \varphi)$

$$\det \left(\left(\frac{\partial T_i^{-1}}{\partial z_j} \right)_{1 \leq i, j \leq 2} \right) = \det \begin{pmatrix} \cos \varphi & -r \sin \varphi \\ \sin \varphi & r \cos \varphi \end{pmatrix} = r(\cos^2 \varphi + \sin^2 \varphi) = r$$

$(R, \Phi) = T(X, Y)$ besitzt nach Satz 5.1 eine Dichte $f_{(R,\Phi)}(r, \varphi)$

$$= r \frac{1}{2\pi\sigma^2} e^{-\frac{r^2 \cos^2 \varphi + r^2 \sin^2 \varphi}{2\sigma^2}} \mathbb{1}_{(0,\infty)}(r) \mathbb{1}_{(0,2\pi)}(\varphi) = \underbrace{\frac{r}{\sigma^2} e^{-\frac{r^2}{2\sigma^2}} \mathbb{1}_{(0,\infty)}(r)}_{\text{Rayleigh-Verteilung}} \cdot \underbrace{\frac{1}{2\pi} \mathbb{1}_{(0,2\pi)}(\varphi)}_{\text{Gleichverteilung}}$$

Also: R, Φ sind stochastisch unabhängig mit $f_R(r) = \frac{r}{\sigma^2} e^{-\frac{r^2}{2\sigma^2}} \mathbb{1}_{(0,\infty)}(r)$,
 $R \sim \text{Ray}(\sigma^2)$ **Rayleigh-Verteilung** und $f_\Phi(\varphi) = \frac{1}{2\pi} \mathbb{1}_{(0,2\pi)}(\varphi)$, $\Phi \sim R(0, 2\pi)$.

Lemma 5.4 $X = (X_1, X_2)$ Zufallsvektor, absolut-stetig mit Dichte $f_X(x_1, x_2)$.
 Dann ist $Y = X_1 + X_2$ absolut-stetig mit Dichte $f_Y(y) = \int_{-\infty}^{\infty} f_X(t, y-t) dt$,
 $y \in \mathbb{R}$.

Beweis: Mit Satz 5.1: $T(X_1, X_2) = (X_1, X_1 + X_2)^9$, $T^{-1}(Y_1, Y_2) = (Y_1, Y_2 - Y_1)$.

$$\det \left(\frac{\partial T_i}{\partial x_j} \right) = \det \begin{pmatrix} \frac{\partial T_1}{\partial x_1} & \frac{\partial T_1}{\partial x_2} \\ \frac{\partial T_2}{\partial x_1} & \frac{\partial T_2}{\partial x_2} \end{pmatrix} = \det \begin{pmatrix} 1 & 0 \\ 1 & 1 \end{pmatrix} = 1$$

$f_{T(X)}(y_1, y_2) \stackrel{\text{Satz 5.1}}{=} f_X(y_1, y_2 - y_1)$.

Es folgt: $f_Y(y) = \int_{-\infty}^{\infty} f_X(y_1, y - y_1) dy_1$. (2te Randverteilung)

Speziell in Lemma 5.4: Wenn X_1, X_2 stochastisch unabhängig

$\implies f_{(X_1, X_2)} = f_{X_1}(x_1) \cdot f_{X_2}(x_2)$. Dann ist

$$f_{(X_1+X_2)}(y) = \int_{-\infty}^{\infty} f_{X_1}(t) \cdot f_{X_2}(y-t) dt, y \in \mathbb{R}$$

Bei stochastisch unabhängigen ZV X_1, X_2 heißt die Verteilung von $X_1 + X_2$ **Faltung** (convolution) der Verteilung von X_1 und X_2 .

Bezeichnung: $P^{X_1+X_2} = P^{X_1} * P^{X_2}$ (Nur möglich, wenn X_1, X_2 s.u.!!)

Beispiel 5.5

a) X_1, X_2 stochastisch unabhängig, $X_1 \sim \Gamma(\alpha, \lambda)$, $X_2 \sim \Gamma(\beta, \lambda)$, $\alpha, \beta, \lambda > 0$.

Es gilt: $X_1 + X_2 \sim \Gamma(\alpha + \beta, \lambda)$, d.h. $\Gamma(\alpha, \lambda) * \Gamma(\beta, \lambda) = \Gamma(\alpha + \beta, \lambda)$

Beweis: Übung 8 Aufgabe 31 a

⁹Trick: Transformation T auf zwei Dimensionen "aufblasen", damit Satz 5.1 anwendbar wird

- b) X_1, X_2 stochastisch unabhängig, $X_1 \sim N(\mu_1, \sigma_1^2)$, $X_2 \sim N(\mu_2, \sigma_2^2)$,
 $\mu_1, \mu_2 \in \mathbb{R}$, $\sigma_1, \sigma_2 > 0$. Dann gilt: $X_1 + X_2 \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$, d.h.
 $N(\mu_1, \sigma_1^2) * N(\mu_2, \sigma_2^2) = N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$.

Beweis:

$$\int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}\sigma_1} e^{-\frac{(t-\mu_1)^2}{2\sigma_1^2}} \frac{1}{\sqrt{2\pi}\sigma_2} e^{-\frac{(y-t-\mu_2)^2}{2\sigma_2^2}} dt = \dots = \frac{1}{\sqrt{2\pi}\sqrt{\sigma_1^2 + \sigma_2^2}} e^{-\frac{(y-\mu_1-\mu_2)^2}{2(\sigma_1^2 + \sigma_2^2)}}$$

- c) $X \sim N(0, 1)$. Dann gilt: $X^2 \sim \Gamma(\frac{1}{2}, \frac{1}{2})$.

Beweis: Sei $X > 0$. $P(X^2 \leq x) = P(-\sqrt{x} \leq X \leq \sqrt{x}) = \int_{-\sqrt{x}}^{\sqrt{x}} \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$

Substituiere: $u = t^2$, also $t = \sqrt{u} \implies dt = \frac{1}{2\sqrt{u}} du$ (Ableitung nach u)

$$\stackrel{\text{Symmetrie}}{=} 2 \int_0^x \frac{1}{\sqrt{2\pi}} e^{-\frac{u}{2}} \frac{1}{2\sqrt{u}} du$$

$$\text{Dichte von } X^2 \text{ also: } f_{X^2} = \begin{cases} \frac{1}{\sqrt{2\pi}} x^{-\frac{1}{2}} e^{-\frac{x}{2}} = \underbrace{\frac{(\frac{1}{2})^{\frac{1}{2}}}{\Gamma(\frac{1}{2})} x^{-\frac{1}{2}} e^{-\frac{x}{2}}}_{\text{Dichte einer } \Gamma(\frac{1}{2}, \frac{1}{2})\text{-Vert.}} & , x \geq 0 \\ 0 & , \text{sonst} \end{cases}$$

Seien X_1, \dots, X_n stid $\sim N(0, 1)$. Da $X_i^2 \sim \Gamma(\frac{1}{2}, \frac{1}{2})$ ist, gilt nach a):

$$X_1^2 + \dots + X_n^2 \sim \Gamma(\frac{n}{2}, \frac{1}{2}).$$

$\Gamma(\frac{n}{2}, \frac{1}{2})$ heißt χ^2 -Verteilung mit n Freiheitsgraden. Bezeichnung: χ_n^2

$$\text{Dichte: } f(x) = \frac{1}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})} x^{\frac{n}{2}-1} e^{-\frac{x}{2}} \mathbb{1}_{(0, \infty)}(x)$$

Mit Beispiel 5.3: Sei $Y \sim \chi_2^2 = \Gamma(1, \frac{1}{2}) \implies X = \sqrt{Y} \sim \text{Ray}(1)$

- d) (siehe Beispiel 4.14) X_1, \dots, X_n stid $\sim \text{Exp}(\lambda) = \Gamma(1, \lambda)$, $\lambda > 0$.
 Mit a): $S_n = X_1 + \dots + X_n \sim \Gamma(n, \lambda)$ (Erlang-Verteilung mit Par. n, λ)

Interpretation:


X_i = "Bedienzeiten eines Servers", stid $\sim \text{Exp}(\lambda)$

S_n = "Gesamtbedienzeit für n Anforderungen"

Umgekehrte Fragestellung: $t \geq 0$. Mit welcher Wahrscheinlichkeit werden im Intervall $[0, t]$ genau n Anforderungen bedient?

Definition 5.6 $\{X_n\}_{n \in \mathbb{N}}$ sei Folge von stochastisch unabhängigen ZV,


$X_i \sim \text{Exp}(\lambda)$, $i \in \mathbb{N}$, $\lambda > 0$.



$N(t) = \max\{n \in \mathbb{N}_0 \mid \sum_{i=1}^n X_i \leq t\} = |\{n \in \mathbb{N} \mid \sum_{i=1}^n X_i \leq t\}|$, heißt **Poisson-Prozess**

mit Parameter $\lambda > 0$. Bezeichnung: $PP(\lambda)$

Graphisch:



Sprechweisen:

Die X_n heißen **Zwischenankunftszeiten** (interarrival times)/**Verweilzeiten** (sojourn times). Die $S_n = \sum_{i=1}^n X_i$ heißen **Ankunftszeiten** (arrival times).

Lemma 5.7 Für alle $t \geq 0$ besitzt $N(t)$ eine Poissonverteilung mit Parameter λt , d.h. $N(t) \sim Poi(\lambda t)$, $P(N(t) = k) = e^{-\lambda t} \frac{(\lambda t)^k}{k!}$, $k \in \mathbb{N}$.

Interpretation: Wie ist die W'keit, daß genau k Kunden bis zum Zeitpunkt t komplett bedient werden?

Beweis:

$$k = 0 : P(N(t) = 0) = P(X_1 > t) = 1 - (1 - e^{-\lambda t}) = e^{-\lambda t} = e^{-\lambda t} \cdot \frac{(\lambda t)^0}{0!}$$

$$\begin{aligned} k \geq 1 : P(N(t) = k) &= P\left(\sum_{i=1}^k X_i \leq t, \sum_{i=1}^{k+1} X_i > t\right) = P(\{S_k \leq t\} \cap \{S_{k+1} > t\}) \\ &= P(\{S_k \leq t\} \setminus \{S_{k+1} \leq t\}) = P(\{S_k \leq t\}) - P(\{S_{k+1} \leq t\}) \\ &\quad (\text{wegen der Monotonie von } P) \quad \boxed{S_k \sim \text{Erl}(k, \lambda), S_{k+1} \sim \text{Erl}(k+1, \lambda)} \\ &= \frac{\lambda^k}{(k-1)!} \int_0^t x^{k-1} e^{-\lambda x} dx - \frac{\lambda^{k+1}}{k!} \int_0^t x^k e^{-\lambda x} dx \\ &= \frac{\lambda^k}{(k-1)!} \left(\int_0^t x^{k-1} e^{-\lambda x} dx - \frac{\lambda}{k} \int_0^t x^k e^{-\lambda x} dx \right) \\ &= \frac{\lambda^k}{(k-1)!} \left(\underbrace{\int_0^t x^{k-1} e^{-\lambda x} dx}_{u'} \underbrace{e^{-\lambda x}}_v + \int_0^t \underbrace{\frac{x^k}{k}}_u \underbrace{(-\lambda e^{-\lambda x})}_{v'} dx \right) \quad \boxed{\int_a^b uv' = uv \Big|_a^b - \int_a^b u'v} \\ &= \frac{\lambda^k}{(k-1)!} \frac{x^k}{k} e^{-\lambda x} \Big|_0^t = \frac{\lambda^k}{k!} t^k e^{-\lambda t} = e^{-\lambda t} \frac{(\lambda t)^k}{k!} \end{aligned}$$

Es gilt sogar für $N_{(s,t]} = N(t) - N(s)$ mit $0 \leq s \leq t$, genannt **Zuwachs in** $(s, t]$:

- $N_{(s,t]} \sim Poi(\lambda(t-s))$
- $N_{(s_i, t_i]}$ mit $i \in \mathbb{N}$ sind stochastisch unabhängig $Poi(\lambda(t_i - s_i))$ -verteilt, falls die Intervalle $(s_i, t_i]$ paarweise disjunkt sind, d.h. die Zuwächse eines Poissonprozesses sind stochastisch unabhängige poissonverteilte ZV.

Im folgenden: Summen von diskreten ZV.

Lemma 5.8 X_1, X_2 stochastisch unabhängig, diskret mit Träger \mathbb{N}_0 , Zähldichten f_{X_1}, f_{X_2} . Dann besitzt $X_1 + X_2$ die Zähldichte $f_{X_1+X_2}(k) = \sum_{i=0}^k f_{X_1}(i) \cdot f_{X_2}(k-i)$, $k \in \mathbb{N}_0$.

$$\begin{aligned} \text{Beweis: } P(X_1 + X_2 = k) &= P\left(\bigcup_{i=0}^k (\{X_1 = i\} \cap \{X_2 = k-i\})\right) \\ &= \sum_{i=0}^k P(X_1 = i, X_2 = k-i) = \sum_{i=0}^k \underbrace{P(X_1 = i)}_{f_{X_1}(i)} \underbrace{P(X_2 = k-i)}_{f_{X_2}(k-i)} \end{aligned}$$

Beispiel 5.9 X_1, \dots, X_n stid $\sim \text{Geo}(p)$, $0 < p < 1$.

Dann gilt $P\left(\sum_{i=1}^n X_i = k\right) = \binom{n+k-1}{k} (1-p)^k p^n = \binom{n+k-1}{n-1} (1-p)^k p^n$, $k \in \mathbb{N}_0$.

Diese Verteilung heißt **negative Binomialverteilung**, Bezeichnung: $\overline{\text{Bin}}(n, p)$.

Also: $\underbrace{\text{Geo}(p) * \dots * \text{Geo}(p)}_{n \text{ mal}} = \overline{\text{Bin}}(n, p)$.

Beweis: Übung 8, Aufgabe 31 d)

$X_1 + \dots + X_n =$ Wartezeit bis zum n -ten Treffer (ohne die Treffer mitzuzählen).

Lemma 5.10

a) $\text{Bin}(n_1, p) * \text{Bin}(n_2, p) = \text{Bin}(n_1 + n_2, p)$, $n_1, n_2 \in \mathbb{N}$, $0 \leq p \leq 1$, insbesondere $\underbrace{\text{Bin}(1, p) * \dots * \text{Bin}(1, p)}_{n \text{ mal}} = \text{Bin}(n, p)$

b) $\overline{\text{Bin}}(n_1, p) * \overline{\text{Bin}}(n_2, p) = \overline{\text{Bin}}(n_1 + n_2, p)$, $n_1, n_2 \in \mathbb{N}$, $0 < p < 1$

c) $\text{Poi}(\lambda_1) * \text{Poi}(\lambda_2) = \text{Poi}(\lambda_1 + \lambda_2)$

Diese drei Verteilungen sind **faltungstabil**.

Beweis: Übung 8, Aufgabe 31

Lemma 5.11 X_1, X_2 stochastisch unabhängig, absolut-stetig mit Dichten f_{X_1}, f_{X_2} , $f_{X_i}(x) = 0$, falls $x \leq 0$ für $i = 1, 2$. Dann gilt:

a) $Y = X_1 \cdot X_2$ ist absolut-stetig mit Dichte

$$f_Y(y) = \int_0^{\infty} \frac{1}{t} f_{X_1}\left(\frac{y}{t}\right) f_{X_2}(t) dt \mathbb{1}_{(0, \infty)}(y)$$

b) $Z = \frac{X_1}{X_2}$ ist absolut-stetig mit Dichte

$$f_Z(y) = \int_0^{\infty} t f_{X_1}(yt) f_{X_2}(t) dt \mathbb{1}_{(0, \infty)}(y)$$

Beweis: Transformationssatz für Dichten mit $T(X, Y) = (Y, X \cdot Y)$ bzw. $T(X, Y) = (Y, \frac{X}{Y})$ (siehe Übung 9 Aufgabe 34).

6 Erwartungswerte und Momente von ZV

Motivierendes Beispiel

a) Spiel: Symmetrischer Würfel

Modell: ZV X auf W -raum $(\Omega, \mathfrak{A}, P)$, $P(X = i) = \frac{1}{6}$ für $i = 1, \dots, 6$.

- Auszahlung = Augenzahl in Euro

Frage: "Mittlere", erwartete Auszahlung (= Einsatz beim Spiel)

$$E(X) = \frac{1}{6} \cdot 1 + \dots + \frac{1}{6} \cdot 6 = \frac{1}{6}(1 + \dots + 6) = \frac{21}{6} = 3,5$$

- Auszahlung = Augenzahl zum Quadrat (in Euro)

$$g(X) = X^2 \quad E(X) = \frac{1}{6} \cdot 1^2 + \dots + \frac{1}{6} \cdot 6^2 = \frac{1}{6}(1^2 + \dots + 6^2) = 15\frac{1}{6}$$

b) Roulette (Petersburger Paradoxon) (Nikolaus Bernoulli, 1695-1726)

Strategie: Beim n -ten Spiel setze 2^n DM auf "Rot", $n \in \mathbb{N}_0$.

Bei Gewinn \Rightarrow Stop Bei Verlust $\Rightarrow n \rightarrow n + 1$

Erstmalig "Rot" beim n -ten Spiel bedeutet:

$$\begin{aligned} \text{Gesamteinsatz : } 1 + 2 + \dots + 2^n &= 2^{n+1} - 1 \\ \text{Auszahlung : } & \frac{2^{n+1}}{2} \\ \text{Gewinn : } & 1 \end{aligned}$$

Sichere Gewinnstrategie?

Modell: $\{X_n\}_{n \in \mathbb{N}_0}$ stid, $X_n \sim \text{Bin}(1, \frac{1}{2})$, wobei $\{X_n = 1\}$: "Rot" im Spiel n .

$S = \min\{n \in \mathbb{N}_0 \mid X_n = 1\}$: Zeitpunkt von erstmalig "Rot"

$S \sim \text{Geo}(\frac{1}{2})$, $P(S = k) = (1 - p)^k p$, $k \in \mathbb{N}_0$.

Auszahlung: $A = 1$, falls $S < \infty$,

$$P(A = 1) = P(S < \infty) = \sum_{k=0}^{\infty} P(S = k) = 1$$

Erwartete Auszahlung: $E(A) = 1 \cdot P(A = 1) = 1$

Ist eine sichere Gewinnstrategie, erfordert aber unendliches Kapital und unendliche Zeit.

Annahme: Maximales Kapital = $2^L - 1$ DM \implies höchstens $L - 1$ Spiele spielbar

Auszahlung: $A = 1 \iff S \leq L - 1$ und $A = -(2^L - 1) \iff S \geq L$

$$P(A = 1) = P(S \leq L - 1) = \sum_{k=0}^{L-1} \frac{1}{2^{k+1}} = 1 - \frac{1}{2^L}$$

$$P(A = -(2^L - 1)) = P(S \geq L) = 1 - P(A = 1) = \frac{1}{2^L}$$

$$\text{Erwartete Auszahlung: } E(A) = 1 \cdot (1 - \frac{1}{2^L}) - (2^L - 1) \frac{1}{2^L} = 0$$

In beiden Beispielen: $E(X) = \sum_i i \cdot P(X = i)$, bzw. $E(g(X)) = \sum_i g(i) \cdot P(X = i)$

für Trägerpunkte i .

Beachte bei der Erweiterung von E auf ∞ viele Trägerpunkte oder absolut-stetige ZV, daß \sum bzw. \int wohldefiniert sind.

Definition 6.1 (Erwartungswert von ZV) g sei eine reellwertige Funktion.

- a) X sei eine diskrete ZV mit Träger $T = \{x_1, x_2, \dots\} \subset \mathbb{R}$ und Zähldichte f . Falls $\sum_{i=1}^{\infty} |g(x_i)|f(x_i) < \infty$, so heißt $E(g(X)) = \sum_{i=1}^{\infty} g(x_i)f(x_i) = \sum_{i=1}^{\infty} g(x_i)P(X = x_i)$ **Erwartungswert** von $g(X)$.
- b) X sei absolut-stetig mit Dichte f . Falls $\int_{-\infty}^{\infty} |g(x)|f(x)dx < \infty$, so heißt $E(g(X)) = \int_{-\infty}^{\infty} g(x)f(x)dx$ **Erwartungswert** von $g(X)$.

Insbesondere $g(X) = X$:

$$E(X) = \sum_{i=1}^{\infty} x_i P(X = x_i) \text{ bei diskreten ZV}$$

$$E(X) = \int_{-\infty}^{\infty} x P(X = x) \text{ bei abs.-stetigen ZV}$$

$$E(X^2) = \sum_{i=1}^{\infty} x_i^2 P(X = x_i)$$

$$E(X^2) = \int_{-\infty}^{\infty} x^2 P(X = x)$$

Für beliebige ZV kann der Erwartungswert mit Hilfe der Verteilungsfunktion wie folgt berechnet werden.

Lemma 6.2 X sei ZV mit Verteilungsfunktion F . Falls $\int_{-\infty}^0 F(x)dx < \infty$ und $\int_0^{\infty} 1 - F(x)dx < \infty$, so gilt:

$$E(X) = - \int_{-\infty}^0 F(x)dx + \int_0^{\infty} 1 - F(x)dx$$

Beweis: Nur für den Fall differenzierbarer Verteilungsfunktion F . ($F'(x) = f(x)$ ist dann eine Dichte.)

$$\int_{-\infty}^0 \underbrace{F(x)}_u \cdot \underbrace{1}_{v'} dx = F(x) \cdot x \Big|_{-\infty}^0 - \int_{-\infty}^0 x \cdot f(x) dx = - \int_{-\infty}^0 x \cdot f(x) dx$$

$$\int_0^{\infty} \underbrace{(1 - F(x))}_u \cdot \underbrace{1}_{v'} dx = (1 - F(x)) \cdot x \Big|_0^{\infty} - \int_0^{\infty} x \cdot f(x) dx = \int_0^{\infty} x \cdot f(x) dx$$

$$\text{Also: } E(X) = \int_{-\infty}^0 x \cdot f(x) dx + \int_0^{\infty} x \cdot f(x) dx = - \int_{-\infty}^0 F(x) dx + \int_0^{\infty} (1 - F(x)) dx$$

Beispiel 6.3

- a) Geometrische Verteilung, $X \sim Geo(p)$, $P(X = k) = f(k) = (1 - p)^k p$, $k \in \mathbb{N}_0$, $0 < p \leq 1$.

$$\begin{aligned} E(X) &= \sum_{k=0}^{\infty} k(1-p)^k p = \sum_{k=1}^{\infty} k(1-p)^k p = \sum_{k=0}^{\infty} (k+1)(1-p)^{k+1} p \\ &= (1-p) \underbrace{\sum_{k=0}^{\infty} k(1-p)^k p}_{E(X)} + (1-p) \underbrace{\sum_{k=0}^{\infty} (1-p)^k p}_1 = (1-p)E(X) + 1 - p \end{aligned}$$

$$\text{Also: } p \underbrace{\sum_{k=0}^{\infty} k(1-p)^k p}_{E(X)} = 1 - p \implies E(X) = \frac{1-p}{p}, \quad 0 < p \leq 1.$$

b) Exponentialverteilung, $X \sim \text{Exp}(\lambda)$, $f(x) = \lambda e^{-\lambda x}$, $x \geq 0$, $\lambda > 0$.

$$E(X) = \int_0^{\infty} \underbrace{x}_u \underbrace{\lambda e^{-\lambda x}}_{v'} dx = \underbrace{-x e^{-\lambda x}}_0^{\infty} + \int_0^{\infty} e^{-\lambda x} dx = -\frac{1}{\lambda} e^{-\lambda x} \Big|_0^{\infty} = \frac{1}{\lambda}$$

0, da $\lim_{x \rightarrow \infty} \frac{x}{e^x} = 0$

Also: $E(X) = \frac{1}{\lambda}$, falls $X \sim \text{Exp}(\lambda)$.

c) Normalverteilung, $X \sim N(\mu, \sigma^2)$, $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$, $x \in \mathbb{R}$, $\mu \in \mathbb{R}$, $\sigma > 0$.

Ersetze im 2. Schritt x durch $x + \mu$

$$\begin{aligned} E(X) &= \int_{-\infty}^{\infty} x \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} dx = \frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} (x + \mu) e^{-\frac{x^2}{2\sigma^2}} dx \\ &= \frac{1}{\sqrt{2\pi}\sigma} \underbrace{\int_{-\infty}^{\infty} x e^{-\frac{x^2}{2\sigma^2}} dx}_0, \text{ wegen Sym. zum Ursprung} + \mu \underbrace{\frac{1}{\sqrt{2\pi}\sigma} \int_{-\infty}^{\infty} e^{-\frac{x^2}{2\sigma^2}} dx}_1 = \mu \end{aligned}$$


Also: $E(X) = \mu$, falls $X \sim N(\mu, \sigma^2)$.

Lemma 6.4 X sei diskrete ZV mit Träger \mathbb{N}_0 . Dann gilt:

$$E(X) = \sum_{k=1}^{\infty} P(X \geq k) = \sum_{k=0}^{\infty} P(X > k)$$

Beweis: Mit Lemma 6.2:

$$\begin{aligned} E(X) &= \int_0^{\infty} (1 - F(x)) dx \\ &= \sum_{k=0}^{\infty} P(X > k) \\ &= \sum_{k=1}^{\infty} P(X \geq k). \end{aligned}$$



Satz 6.5 (Eigenschaften des Erwartungswerts)

(auftretende Erwartungswerte sollen existieren)

- $E(aX + bY) = aE(X) + bE(Y) \quad \forall a, b \in \mathbb{R}$
- $X \leq Y \implies E(X) \leq E(Y) \quad (\text{Monotonie})$
- Für $X = \mathbb{1}_A$, $A \in \mathfrak{A}$, gilt: $E(X) = E(\mathbb{1}_A) = P(A)$
- $P(|X| > c) \leq \frac{E(|X|)}{c} \quad \forall c > 0 \quad (\text{Markoff-Ungleichung})$
- X, Y stochastisch unabhängig $\implies E(X \cdot Y) = E(X) \cdot E(Y)$

Erwartungswerte von Funktionen von Zufallsvektoren (transformierte Zufallsvektoren) werden wie folgt berechnet.

Satz 6.6 (X_1, \dots, X_n) sei Zufallsvektor, $g: \mathbb{R}^n \rightarrow \mathbb{R}$ meßbare Funktion.

- a) (X_1, \dots, X_n) sei diskret mit Träger $T = \{t_1, t_2, \dots\} \subset \mathbb{R}^n$ und Zähldichte f . Falls $\sum_{i=1}^{\infty} |g(t_i)|f(t_i) < \infty$, so gilt $E(g(X_1, \dots, X_n)) = \sum_{i=1}^{\infty} g(t_i)f(t_i)$.

$$\text{Also: } E(X \cdot Y) = \sum_{i=1}^{\infty} \sum_{j=1}^{\infty} x_i \cdot y_j \cdot f_{(X,Y)}(x_i, y_j)$$

- b) (X_1, \dots, X_n) sei absolut-stetig mit Dichte f . Falls $\int \dots \int |g(x_1, \dots, x_n)|f(x_1, \dots, x_n)dx_1 \dots dx_n < \infty$, so gilt $E(g(X_1, \dots, X_n)) = \int \dots \int g(x_1, \dots, x_n)f(x_1, \dots, x_n)dx_1 \dots dx_n$.

$$\text{Also: } E(X \cdot Y) = \int \int x \cdot y \cdot f_{(X,Y)}(x, y)dx dy$$

Beweis: von Satz 6.5

$$\begin{aligned} \text{a) Für absolut-stetige ZV: } E(aX + bY) &\stackrel{6.6b}{=} \int \int (ax + by)f_{(X,Y)}(x, y)dx dy \\ &= a \int \int x f_{(X,Y)}(x, y)dx dy + b \int \int y f_{(X,Y)}(x, y)dx dy \\ &= a \underbrace{\int x f_X(x)dx}_{E(X)} + b \underbrace{\int y f_Y(y)dy}_{E(Y)} = aE(X) + bE(Y) \end{aligned}$$

$$\text{c) } \mathbb{1}_A(w) = \begin{cases} 1 & , w \in A \\ 0 & , w \notin A \end{cases}$$

$$E(\mathbb{1}_A) = 1 \cdot P(A) + 0 \cdot P(A^c) = P(A)$$

$$\text{d) } \forall c > 0: c \cdot \mathbb{1}_{\{|x|>c\}}(x) = \begin{cases} c & , |x| > c \\ 0 & , |x| \leq c \end{cases} \leq |x|$$

$$E(c \cdot \mathbb{1}_{\{|x|>c\}}) = c \cdot P(|x| > c) \leq E(|X|)$$

$$\text{Also } P(|x| > c) \leq \frac{E(|X|)}{c} \quad \forall c > 0.$$

- e) Für diskrete ZV: X, Y stochastisch unabhängig

$$E(X \cdot Y) = \sum_{i,j} x_i y_j f_{(X,Y)}(x_i, y_j) = \sum_{i,j} x_i y_j f_X(x_i) f_Y(y_j)$$

$$= \underbrace{\left(\sum_i x_i f_X(x_i) \right)}_{E(X)} \underbrace{\left(\sum_j y_j f_Y(y_j) \right)}_{E(Y)} = E(X) \cdot E(Y)$$

Definition 6.7 X, Y seien ZV. X und Y heißen **unkorreliert** (uncorrelated), wenn $E(X \cdot Y) = E(X) \cdot E(Y)$.

Also mit Satz 6.5: X, Y stochastisch unabhängig $\implies X, Y$ unkorreliert.

Die Umkehrung hiervon ist im Allgemeinen falsch, siehe Übung.¹⁰

Transformationen von besonderer Bedeutung sind $g(X) = X^k$ mit $k \in \mathbb{N}_0$ und $g(X, Y) = (X - E(X))(Y - E(Y))$.

Definition 6.8 X, Y seien ZV. Alle auftretenden Erwartungswerte sollen existieren.

¹⁰Gilt aber bei der Normalverteilung.

- a) $E(X^k)$ mit $k \in \mathbb{N}_0$ heißt **k -tes Moment** (moment) von X .
- b) $E((X - E(X))^k)$ heißt **k -tes zentrales Moment** (central moment).
 Insbesondere $k = 2$:
 $E((X - E(X))^2) = V(X) = Var(X)$ heißt **Varianz von X** (variance).
 $\sqrt{V(X)}$ heißt **Standardabweichung von X** (standard deviation).
- c) $Cov(X, Y) = E((X - E(X))(Y - E(Y)))$ heißt **Kovarianz von X und Y** (covariance).
 $Corr(X, Y) = \frac{Cov(X, Y)}{\sqrt{Var(X)}\sqrt{Var(Y)}}$ heißt **Korrelation von X und Y** (correlation).

Lemma 6.9 X, Y, X_1, \dots, X_n seien ZV. Auftretende Momente (Erwartungswerte) sollen existieren.

- a) $Cov(X, Y) = E(X \cdot Y) - E(X) \cdot E(Y)$
 $Cov(X, X) = Var(X)$
 $Var(X) = E(X^2) - (E(X))^2$
- b) $Var(aX + b) = a^2 Var(X) \quad \forall a, b \in \mathbb{R}$
- c) $Var(\sum_{i=1}^n X_i) = \sum_{i=1}^n Var(X_i) + 2 \sum_{i < j} Cov(X_i, X_j)$
 $Var(\sum_{i=1}^n X_i) = \sum_{i=1}^n Var(X_i)$, falls X_1, \dots, X_n paarweise unkorreliert
- d) $|Cov(X, Y)| \leq \sqrt{Var(X)Var(Y)}$ **Cauchy-Schwarz-Ungleichung**
 Insbesondere folgt: $|Corr(X, Y)| \leq 1$.

Beweis:

- $Cov(X, X) = E[(X - E(X))(X - E(X))] = E[(X - E(X))^2] = Var(X)$
 $Cov(X, Y) = E[(X - E(X))(Y - E(Y))] = E[X \cdot Y - X \cdot E(Y) - Y \cdot E(X) + E(X)E(Y)] = E(X \cdot Y) - E(Y)E(X) - E(X)E(Y) + E(X)E(Y) = E(X \cdot Y) - E(X)E(Y)$
 $Var(X) = Cov(X, X) = E(X^2) - E(X)^2$
- $Var(aX + b) = E[((aX + b) - E(aX + b))^2] = E[(aX + b - aE(X) - b)^2] = a^2 E[(X - E(X))^2] = a^2 Var(X)$
- $Var(\sum_{i=1}^n X_i) = E\left[\left(\sum_{i=1}^n X_i\right)^2\right] - E\left[\sum_{i=1}^n X_i\right]^2 = \sum_{i,j} E(X_i X_j) - \sum_{i,j} E(X_i)E(X_j)$
 $= \sum_i Var(X_i) + 2 \sum_{i < j} [E(X_i X_j) - E(X_i)E(X_j)]$
 $= \sum_i Var(X_i) + 2 \sum_{i < j} Cov(X_i, X_j)$
- Hier bei Existenz von Dichten:
 $|E(X, Y)| = \left| \int \int X \cdot Y f(x, y) dx dy \right| \leq \int \int |x| |y| f(x, y) dx dy$

$$\begin{aligned} & \stackrel{\text{Cauchy-Schwarz}}{\leq} \sqrt{(\int \int x^2 f(x, y) dx dy)(\int \int y^2 f(x, y) dx dy)} \\ & = \sqrt{(\int x^2 f_X(x) dx)(\int y^2 f_Y(y) dy)} = \sqrt{E(X^2)E(Y^2)} \end{aligned}$$

Behauptung durch Ersetzen von X durch $X - E(X)$ und Y durch $Y - E(Y)$.

Interpretation der Größen aus Lemma 6.9

$E(X)$: mittlerer Wert

$Var(X)$: mittlere quadratische Abweichung vom Erwartungswert.
Maßzahl für die Streuung

$Cov(X, Y)$: Korrekturterm bei der Varianzberechn. von Summen von ZV.
 $Var(X, Y) = Var(X) + Var(Y) + 2Cov(X, Y)$

$Corr(X, Y)$: Maßzahl für den linearen Zusammenhang zwischen ZV.
Es gilt: $\exists a, b \in \mathbb{R} : P(X = aY + b) = 1 \Leftrightarrow |Corr(X, Y)| = 1$.

Satz 6.10 $G_{X_1}(z), G_{X_2}(z)$ seien erzeugende Funktionen von stochastisch unabhängigen diskreten ZV X_1, X_2 , bzw. $L_{X_1}(s), L_{X_2}(s)$ die Laplace-Transformierten von stochastisch unabhängigen absolut-stetigen ZV $X_1, X_2 \geq 0$. Dann gilt:

$$\begin{aligned} G_{X_1+X_2}(z) &= G_{X_1}(z)G_{X_2}(z) \quad \text{für } |z| \leq 1, \text{ bzw.} \\ L_{X_1+X_2}(s) &= L_{X_1}(s)L_{X_2}(s) \quad \text{für } s \geq 0. \end{aligned}$$

Beweis:

Es gilt: $G_X(z) = \sum_{k=0}^{\infty} p_k z^k = E(z^X)$ und $L_X(s) = \int_0^{\infty} e^{sx} f(x) dx = E(e^{-sX})$.

Also: $G_{X_1+X_2}(z) = E(z^{X_1+X_2}) = E(\underbrace{z^{X_1}}_{s.u.} \underbrace{z^{X_2}}_{s.u.}) = E(z^{X_1})E(z^{X_2})$

$= G_{X_1}(z)G_{X_2}(z)$ für $|z| \leq 1$.

$L_{X_1+X_2}(s) = E(e^{-s(X_1+X_2)}) = E(\underbrace{e^{-sX_1}}_{s.u.} \underbrace{e^{-sX_2}}_{s.u.}) = E(e^{-sX_1})E(e^{-sX_2})$

$= L_{X_1}(s)L_{X_2}(s)$ für $s \geq 0$.

Beispiel 6.11

- a) $X \sim Bin(n, p)$. Dann $G_X(z) = (1 - p + pz)^n$ für $|z| \leq 1$.
 $X_1 \sim Bin(n_1, p), X_2 \sim Bin(n_2, p)$ stochastisch unabhängig.
 $\implies G_{X_1+X_2}(z) = (1 - p + pz)^{n_1} (1 - p + pz)^{n_2} = (1 - p + pz)^{n_1+n_2}$ ist die erzeugende Funktion einer $Bin(n_1 + n_2, p)$ -Verteilung.

- b) $X_1 \sim Exp(\lambda), L_{X_1}(s) = \frac{s}{s+\lambda}$ für $s \geq 0$.
 $X_2 \sim Exp(\mu), L_{X_2}(s) = \frac{s}{s+\mu}$ für $s \geq 0$.

$$L_{X_1+X_2}(s) = \frac{s}{s+\lambda} \frac{s}{s+\mu} = \frac{\mu}{\mu-\lambda} \frac{\lambda}{s+\lambda} \frac{\lambda}{\lambda-\mu} \frac{\mu}{s+\mu} \quad (*)$$

$$\text{Die Dichte } f(x) = \left(\frac{\mu}{\mu-\lambda} \lambda e^{-\lambda x} + \frac{\lambda}{\lambda-\mu} \mu e^{-\mu x} \right) \mathbb{1}_{0, \infty}(x) \quad (**)$$

hat als Laplace-Transformierte (*). $X_1 + X_2$ hat die Dichte (**).

Satz 6.12 (Transformierte und Momente)

- a) $G(z) = \sum_{k=0}^{\infty} P(X=k)z^k$ sei erzeugende Funktion einer diskreten ZV X mit Träger \mathbb{N}_0 . Dann gilt:

$$E(X) = G'(1) \text{ und } \underbrace{E[X(X-1)\dots(X-k+1)]}_{k\text{-tes faktorielles Moment}} = G^{(k)}(1).$$

Also: $E(X^2) = G'(1) + G''(1)$. Damit: $Var(X) = G'(1) + G''(1) - G'(1)^2$

Beachte: $G^{(i)}(1) = \lim_{z \rightarrow 1^-} G^{(i)}(z)$, falls $G(z)$ nicht ex. für $z > 1$.

- b) $L(s) = \int_0^{\infty} e^{-sx} f(x) dx$ sei Laplace-Transformierte einer absolut-stetigen ZV $X \geq 0$ mit Dichte f . Dann gilt: $E(X) = -L'(0)$ und $E(X^k) = (-1)^k L^{(k)}(0)$.

Damit: $Var(X) = L''(0) - L'(0)^2$

Beweis: Nur eine intuitive "Idee", kein echter Beweis. Nur für a) $E(X)$

$$G'(z) = \sum_{k=0}^n p_k k z^{k-1} \text{ für } |z| < 1 \text{ (durch gliedweises Differenzieren)}$$

Also: $G'(1) = \sum_{k=0}^n p_k k = E(X)$.

Satz 6.13 (Berechnung von Momenten)

- a) $X \sim Bin(n, p)$ mit $0 \leq p \leq 1$.

Berechnung des Erwartungswertes:

1) $E(X) = \sum_{k=0}^n k \binom{n}{k} p^k (1-p)^{n-k} = \dots = np$

2) $X \sim \sum_{i=1}^n X_i$ mit $X_i \text{ stid} \sim Bin(1, p)$ und $E(X_i) = 1 \cdot p + 0 \cdot (1-p) = p$

$$E(X) = E\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n E(X_i) = \sum_{i=1}^n p = np$$

Dieser Trick läßt sich bei faltungsstabilen Verteilungen anwenden!

3) Erzeugende Funktion $G(z) = (1-p+pz)^n$ und $G'(z) = n(1-p+pz)^{n-1}p$. Also: $G'(1) = np = E(X)$.

$Var(X)$ wie in 2):

$$Var(X) = Var\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n Var(X_i) = \sum_{i=1}^n p(1-p) = np(1-p)$$

$Var(X_i) = E(X_i^2) - E(X_i)^2 = E(X_1^2) - p^2 = p - p^2 = p(1-p)$
 $E(X_i^2) = 1^2p + 0^2(1-p) = p$

- b) $X \sim Exp(\lambda)$ mit $\lambda > 0$. $L_X(s) = \frac{\lambda}{s+\lambda}$ und $L_X^{(k)}(s) = (-1)^k k! \frac{\lambda}{(s+\lambda)^{k+1}}$

$$L_X^{(k)}(0) = (-1)^k k! \lambda^{-k}$$

Also: $E(X^k) = k! \lambda^{-k}$, $E(X) = \frac{1}{\lambda}$ und $E(X^2) = \frac{2}{\lambda^2}$

$$Var(X) = E(X^2) - E(X)^2 = \frac{2}{\lambda^2} - \frac{1}{\lambda^2} = \frac{1}{\lambda^2}$$

c) $X \sim N(0, 1)$, d.h. normalverteilt mit $\mu = 0$ und $\sigma^2 = 1$. Dann $E(X) = 0$.

$$E(X^2) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x^2 e^{-\frac{x^2}{2}} dx \stackrel{\text{Symmetrie}}{=} \frac{2}{\sqrt{2\pi}} \int_0^{\infty} x^2 e^{-\frac{x^2}{2}} dx$$

Substitution: $\frac{x^2}{2} = y$ und $dx = \frac{dy}{\sqrt{2y}}$

$$= \frac{2}{\sqrt{2\pi}} \int_0^{\infty} 2ye^{-y} \frac{1}{\sqrt{2y}} dy = \frac{2}{\sqrt{\pi}} \int_0^{\infty} \frac{\sqrt{2}}{\sqrt{2}} \frac{y}{\sqrt{y}} e^{-y} dy = \underbrace{\frac{2}{\sqrt{\pi}} \int_0^{\infty} y^{\frac{1}{2}} e^{-y} dy}_{= 1} = 1$$

Integral über die Dichte einer $\Gamma(\frac{3}{2}, 1)$ -Verteilung

Es folgt: $Var(X) = E(X^2) - E(X)^2 = 1 - 0 = 1$ (Varianz einer Standard-Normalverteilung ist 1)

$Y = \sigma X + \mu$ besitzt die Dichte $f_Y(y) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(y-\mu)^2}{2\sigma^2}}$, d.h. $Y \sim N(\mu, \sigma^2)$.

Also $E(Y) = E(\sigma X + \mu) = \sigma^2 \underbrace{Var(X)}_1 = \sigma^2$

Also: Bei $N(\mu, \sigma^2)$ ist μ der Erwartungswert und σ^2 die Varianz.

7 Bedingte Verteilungen und Erwartungswerte

- a) X, Y diskrete ZV mit Träger T_X, T_Y , gemeinsamer Zähldichte $f_{(X,Y)}(x, y) = P(X=x, Y=y)$ für $(x, y) \in T_X \times T_Y$. Definiere die **bedingte Zähldichte von X unter $Y = y$** (analog zu Definition 2.14) durch

$$f_{X|Y}(x|y) = \begin{cases} \frac{P(X=x, Y=y)}{P(Y=y)} = \frac{f_{(X,Y)}(x,y)}{f_Y(y)} & , \text{ falls } f_Y(y) > 0 \\ f_X(x) \text{ (oder bel. andere Zähldichte)} & , \text{ falls } f_Y(y) = 0 \end{cases}$$

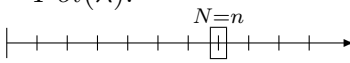
Beachte: $f_{X|Y}(x|y)$ ist eine Zähldichte für alle $y \in T_Y$ mit y fest.

Die zugehörige Vert. heißt **bedingte Verteilung von X unter $Y = y$** , also $P(X \in A|Y=y) = P^{X|Y=y}(A) = \sum_{x \in A} f_{X|Y}(x|y)$ mit $A \in \mathfrak{A}$ und $y \in T_Y$.

Der Satz von der totalen Wahrscheinlichkeit (Satz 2.15) liefert

$$f_X(x) = P(X=x) = \sum_{y \in T_Y} f_{X|Y}(x|y) f_Y(y) \text{ mit } x \in T_X. \quad (*)$$

Beispiel 7.1 Sei $f_{X|N}(k|n) = \binom{n}{k} p^k (1-p)^{n-k}$ für $k = 0, \dots, n$, also $P^{X|N=n} = \text{Bin}(n, p)$ und $N \sim \text{Poi}(\lambda)$.

Zweistufiges Experiment: 

$$P(X=k) = \sum_{n=0}^{\infty} P(X=k|N=n) P(N=n) \quad \boxed{\text{Es ist } \binom{n}{k} = 0 \text{ für } k > n}$$

$$\begin{aligned} &= \sum_{n=k}^{\infty} P(X=k|N=n) P(N=n) = \sum_{n=k}^{\infty} \frac{n!}{(n-k)!k!} p^k (1-p)^{n-k} e^{-\lambda} \frac{\lambda^n}{n!} \\ &= e^{-\lambda} \frac{\lambda^k p^k}{k!} \underbrace{\sum_{n=k}^{\infty} \frac{(\lambda(1-p))^{n-k}}{(n-k)!}}_{e^{\lambda(1-p)}} = e^{-\lambda} \frac{\lambda^k p^k}{k!} e^{\lambda(1-p)} = \frac{(\lambda p)^k}{k!} e^{-\lambda p} \sim \text{Poi}(\lambda p), \end{aligned}$$

d.h. $X \sim \text{Poi}(\lambda p)$.

Betrachte den Erwartungswert der bedingten Verteilung:

$$E(g(X)|Y=y) = \sum_{x \in T_X} g(x) f_{X|Y}(x|y) \text{ für } y \in T_Y$$

heißt **bedingter Erwartungswert von $g(X)$ unter $Y = y$** (falls existent).

Berechnung des Erwartungswertes mit den bedingten E-Werten wie folgt:

$$\begin{aligned} E(g(X)) &= \sum_{x \in T_X} g(x) f_X(x) = \sum_{x \in T_X} g(x) \sum_{y \in T_Y} f_{X|Y}(x|y) f_Y(y) \\ &= \sum_{y \in T_Y} \underbrace{\sum_{x \in T_X} g(x) f_{X|Y}(x|y) f_Y(y)}_{E(g(X)|Y=y)} = \sum_{y \in T_Y} E(g(X)|Y=y) f_Y(y) \end{aligned}$$

- b) X, Y absolut-stetige ZV mit gemeinsamer Dichte $f_{(X,Y)}(x, y)$.
Definiere die **bedingte Dichte von X unter $Y = y$** durch

$$f_{X|Y}(x|y) = \begin{cases} \frac{f_{(X,Y)}(x,y)}{f_Y(y)} & , \text{ falls } f_Y(y) > 0 \\ f_X(x) \text{ (oder bel. andere Zähldichte)} & , \text{ falls } f_Y(y) = 0 \end{cases}$$

Beachte: $f_{X|Y}(x|y)$ ist eine Dichte für alle $y \in \mathbb{R}$.

Die zugehörige Vert. heißt **bedingte Verteilung von X unter $Y = y$** , also $P(X \in A|Y = y) = P^{X|Y=y}(A) = \int f_{X|Y}(x|y)dx$ mit $A \in \mathfrak{A}$ und $y \in \mathbb{R}$.

Speziell heißt $F_{X|Y=y}(x) = P(X \leq x|Y = y) = \int_{-\infty}^x f_{X|Y}(z|y)dz$ **bedingte Verteilungsfunktion von X unter $Y = y$** .

Wie bei a) (*): $f_X(x) = \int_{-\infty}^{\infty} f_{X|Y}(x|y)f_Y(y)dy$.

Analog zum diskreten Fall heißt $E(g(X)|Y = y) = \int g(X)f_{X|Y}(x|y)dx$ für $y \in \mathbb{R}$ **bedingter Erwartungswert von $g(X)$ unter $Y = y$** .

Wie oben:

$$\begin{aligned} E(g(X)) &= \int g(X)f_X(x)dx = \int g(X) \int f_{X|Y}(x|y)f_Y(y)dydx \\ &= \int \underbrace{\left(\int g(X)f_{X|Y}(x|y)dx \right)}_{E(g(X)|Y=y)} f_Y(y)dy = \int E(g(X)|Y = y)f_Y(y)dy \end{aligned}$$

- c) Gemischte Fälle: absolut-stetig/diskret werden analog behandelt

Beispiel 7.2 (Wartezeit in einem Wartesystem)

N : Anzahl der Kunden in der Warteschlange, $N \sim Geo(p)$

X_n mit $n \in \mathbb{N}$: Bedienzeit des Kunden n , $X_n \text{ stid} \sim Exp(\lambda)$

Gesucht: $W = \sum_{i=1}^{N+1} X_i$ Gesamtwartezeit für neu ankommende Kunden

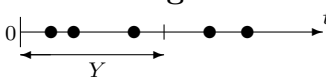
Bekannt: $P^{W|N=n} = Erl(n+1, \lambda)$

Es gilt: $P(W \leq t) = \sum_{n=0}^{\infty} P(W \leq t|N = n)P(N = n)$

$$\begin{aligned} &= \sum_{n=0}^{\infty} \int_0^t \frac{\lambda^{n+1}}{n!} y^{n-1+1} e^{-\lambda y} dy (1-p)^n p = \int_0^t \lambda p e^{-\lambda y} \underbrace{\sum_{n=0}^{\infty} \frac{(\lambda y(1-p))^n}{n!}}_{e^{\lambda y(1-p)}} dy \\ &= \int_0^t \lambda p e^{-\lambda y} e^{\lambda y(1-p)} dy = \int_0^t \underbrace{\lambda p e^{-\lambda p y}}_{\substack{\text{Dichte einer} \\ \text{Exp-Vert.}}} dy = 1 - e^{-\lambda p t} \text{ für } t \geq 0 \end{aligned}$$

Also: $W \sim Exp(\lambda p)$ mit $E(W) = \frac{1}{\lambda p}$

Beispiel 7.3 (Ankünfte eines PP in zufälligen Intervallen)

$N(t)$: $PP(\lambda)$ mit $\lambda > 0$ } s.u. 

$Y \sim Exp(\mu)$ mit $\mu > 0$ }
Gesucht: $N(Y) = \max\{n \in \mathbb{N}_0 | \sum_{i=1}^n X_i \leq Y\}$, wobei $X_i \text{ stid} \sim Exp(\lambda)$.

$N(Y)$ ist Anzahl der Ankünfte im zufälligen Intervall $[0, Y]$.

Bekannt: $P^{N(Y)|Y=t} = Poi(\lambda t)$ für alle $t > 0$.

$$\begin{aligned}
 P(N(Y)=k) &= \int_0^\infty P(N(Y)=k|Y=t)\mu e^{-\mu t} dt = \int_0^\infty \frac{(\lambda t)^k}{k!} e^{-\lambda t} \mu e^{-\mu t} dt \\
 &= \frac{\lambda^k \mu}{k!} \int_0^\infty t^k e^{-(\lambda+\mu)t} dt = \frac{\lambda^k \mu}{k!} \frac{k!}{(\lambda+\mu)^{k+1}} \underbrace{\int_0^\infty \frac{(\lambda+\mu)^{k+1}}{k!} t^k e^{-(\lambda+\mu)t} dt}_{1, \text{ da } \Gamma(k+1, \lambda+\mu)\text{-Verteilung}} \\
 &= \frac{\mu}{\lambda+\mu} \left(\frac{\lambda}{\lambda+\mu} \right)^k \quad (\text{für } k \in \mathbb{N}_0) = \left(1 - \frac{\mu}{\lambda+\mu} \right)^k \frac{\mu}{\lambda+\mu}
 \end{aligned}$$

Also: $N(Y) \sim Geo\left(\frac{\mu}{\lambda+\mu}\right)$

8 Grenzwertsätze

Zur Motivation

- 1) Unendlicher Münzwurf, Wahrscheinlichkeit für Kopf = p (unbekannt)
 Frage: Ist die Münze fair?
 Idee: Werfe die Münze sehr oft in unabhängigen Versuchen.
 $h_n = \frac{\text{Anzahl der Würfe mit Kopf}}{n = \text{Anzahl aller Würfe}}$
 Frage: Konvergiert h_n gegen p für $n \rightarrow \infty$?
- 2) Wartesystem: Anzahl der in einem Zeitraum ankommenden Kunden durch
 $X_i \sim Poi(\lambda)$ (Zeitintervall der Länge 1)
 Anzahl der bis zum Zeitpunkt n ankommenden Kunden durch
 $Y_n = \sum_{i=1}^n X_i \sim Poi(n\lambda)$
 Frage: Welche Verteilung ergibt sich asymptotisch (n groß)?
 Es existieren Konstanten: $a_n, b_n: \frac{Y_n - a_n}{b_n} \overset{\text{asymptotisch}}{\sim} N(0, 1)$
 Gilt die gleiche Aussage, wenn $X_i \sim Bin(k, p)$? \rightarrow Ja!
 Gilt immer, auch wenn die Verteilung der X_i unbekannt.

Zunächst geeignete Konvergenzbegriffe:

Definition 8.1 $\{X_n\}_{n \in \mathbb{N}}$ sei eine Folge von ZV und X sei ZV, alle auf W'-raum $(\Omega, \mathfrak{A}, P)$. Die Folge heißt

- a) **P-fast sicher konvergent** (almost surely, almost everywhere) gegen X , wenn $P(\{w \mid \lim_{n \rightarrow \infty} X_n(w) = X(w)\}) = P(\lim_{n \rightarrow \infty} X_n = X) = 1$.
Bez.: $X_n \xrightarrow{n \rightarrow \infty} X$ P-fast sicher konvergent (P-f.s.), $\lim_{n \rightarrow \infty} X_n = X$ P-f.s.
- b) **P-stochastisch konvergent** (stochastically convergent) gegen X , wenn $\lim_{n \rightarrow \infty} P(|X_n - X| > \varepsilon) = 0$ für alle $\varepsilon > 0$.
Bez.: $X_n \xrightarrow{n \rightarrow \infty} X$ P-stoch., $\lim_{n \rightarrow \infty} X_n = X$ P-stoch.
- c) **schwach konvergent** oder **verteilungskonvergent** (convergent in distribution) gegen X , wenn $\lim_{n \rightarrow \infty} F_n(x) = F(x)$ für alle Stetigkeitspunkte von F , wobei $X_n \sim F_n$ und $X \sim F$. *Bez.:* $X_n \overset{\text{asym.}}{\sim} X, X_n \xrightarrow{\mathcal{D}} X$.

Lemma 8.2 $P(\limsup_{n \rightarrow \infty} \{|X_n - X| > \varepsilon\}) = 0 \iff X_n \xrightarrow{n \rightarrow \infty} X$ P-f.s.

Also $X_n \xrightarrow{n \rightarrow \infty} X$ P-f.s. $\iff P(|X_n - X| > \varepsilon \text{ für } \infty \text{ viele } n) = 0$ für alle $\varepsilon > 0$.

Beweis: " \Leftarrow ": \checkmark

" \Rightarrow ": Für alle $\varepsilon = \frac{1}{k}$: $P(|X_n - X| > \frac{1}{k} \text{ für } \infty \text{ viele } n) = 0$

Es folgt: $P\left(\underbrace{\bigcup_k \left\{w \mid |X_n(w) - X(w)| > \frac{1}{k} \text{ für } \infty \text{ viele } n\right\}}_{=\{w \mid \exists k \forall n_0 \exists n \geq n_0: |X_n(w) - X(w)| > \frac{1}{k}\}}\right) \leq \sum_k P(\dots) = 0$

Aus dem Komplement: $P(\{w | \forall k \exists n_0 \forall n \geq n_0 : |X_n(w) - X(w)| \leq \frac{1}{k}\}) = 1$, d.h. $X_n \rightarrow X$ P -f.s.

Satz 8.3 (Zusammenhänge zwischen Konvergenzarten)

- a) $X_n \rightarrow X$ P -f.s. $\stackrel{(i)}{\implies} X_n \rightarrow X$ P -stoch. $\stackrel{(ii)}{\implies} X_n \xrightarrow{\mathcal{D}} X$ (Umkehrung i.A. falsch)
- b) $\sum_{n=1}^{\infty} P(|X_n - X| > \varepsilon) < \infty$ für alle $\varepsilon > 0 \implies X_n \rightarrow X$ P -f.s.

Beweis:

- a) i) $\forall \varepsilon > 0$ gilt: $0 \leq \lim_{n \rightarrow \infty} P(|X_n - X| > \varepsilon) \leq \lim_{n \rightarrow \infty} P(\bigcup_{m \geq n} \{|X_n - X| > \varepsilon\})$
 $\stackrel{\text{Stetigkeit}}{=} P(\bigcap_{n=1}^{\infty} \bigcup_{m \geq n} \{|X_n - X| > \varepsilon\}) = P(\limsup_{n \rightarrow \infty} \{|X_n - X| > \varepsilon\})$
 $= P(|X_n - X| > \varepsilon \text{ für } \infty \text{ viele } n) = 0$, da $X_n \rightarrow X$ P -f.s. (Vergl. Lem. 8.2)
- ii) Mathar & Pfeiffer, Lemma 2.3.2, Seite 137
- b) Sei $\varepsilon > 0$. Mit dem Borel-Cantelli-Lemma (BCL) und Lemma 8.2:
 $\sum_{n=1}^{\infty} P(|X_n - X| > \varepsilon) < \infty \stackrel{BCL}{\implies} P(\limsup_{n \rightarrow \infty} \{|X_n - X| > \varepsilon\}) = 0 \stackrel{L 8.2}{\implies} \text{Beh.}$

Lemma 8.4 (Tschebyscheff-Ungleichung) (Chebyshev inequality)

X sei ZV mit $Var(X) < \infty$. Dann gilt für alle $\varepsilon > 0$:

$$P(|X - E(X)| > \varepsilon) \leq \frac{Var(X)}{\varepsilon^2}$$

Beweis: Mit Markoff-Ungleichung: $P(|X| > c) \leq \frac{E(|X|)}{c}$ für alle $c > 0$

$$P(|X - E(X)| > \varepsilon) = P((X - E(X))^2 > \varepsilon^2) \leq \frac{E(|X - E(X)|^2)}{\varepsilon^2} = \frac{Var(X)}{\varepsilon^2}$$

Satz 8.5 (Starkes Gesetz großer Zahlen, SGGZ)¹¹

$\{X_n\}_{n \in \mathbb{N}}$ sei eine Folge von paarweise unkorrelierten ZV auf einem W'raum $(\Omega, \mathfrak{A}, P)$ mit $Var(X_n) \leq M < \infty$ für alle $n \in \mathbb{N}$. Dann gilt:

$$\frac{1}{n} \sum_{i=1}^n (X_i - E(X_i)) \xrightarrow{n \rightarrow \infty} 0 \text{ } P\text{-f.s.}$$

Beweis: O.B.d.A. $E(X_i) = 0$ für alle i , X_i paarweise unkorreliert.

Setze $\overline{X_n} = \frac{1}{n} \sum_{i=1}^n X_i$ (arithmetisches Mittel).

Damit: $Var(\overline{X_n}) = Var(\frac{1}{n} \sum_{i=1}^n X_i) = \frac{1}{n^2} \sum_{i=1}^n Var(X_i) \leq \frac{1}{n^2} n \cdot M$

¹¹strong law of large numbers, LLN

Zeige: $\forall \varepsilon > 0: \sum_{i=1}^{\infty} P(|\overline{X}_n| > \varepsilon) < \infty$. Dann $\overline{X}_n \rightarrow 0$ P -f.s. (Satz 8.3 b))

Betrachte zunächst die Teilfolge \overline{X}_{n^2} . Mit der Tschbyscheff-Ungleichung

$$P(|\overline{X}_{n^2}| > \varepsilon) \leq \frac{\text{Var}(\overline{X}_{n^2})}{\varepsilon^2} \leq \frac{1}{n^4 \varepsilon^2} n^2 M = \frac{M}{n^2 \varepsilon^2} \text{ für alle } n \in \mathbb{N}, \varepsilon > 0.$$

Also: $\sum_{i=1}^{\infty} P(|\overline{X}_{n^2}| > \varepsilon) \leq \sum_{i=1}^{\infty} \frac{M}{n^2 \varepsilon^2} = \frac{M}{\varepsilon^2} \sum_{i=1}^{\infty} \frac{1}{n^2} < \infty \implies \overline{X}_{n^2} \rightarrow 0$ P -f.s.

Für die nicht-quadratischen Terme:

Sei $n = n(k)$ definiert durch $n^2 \leq k < (n+1)^2$ für alle $k \in \mathbb{N}$.

$$\text{Var}(k\overline{X}_k - n^2\overline{X}_{n^2}) = \text{Var}\left(k\frac{1}{k} \sum_{i=1}^k X_i - n^2\frac{1}{n^2} \sum_{i=1}^{n^2} X_i\right) = \text{Var}\left(\sum_{i=n^2+1}^k X_i\right) \leq (k-n^2)M$$

Es folgt (Tsch.-Ungl.): $P(|k\overline{X}_k - n^2\overline{X}_{n^2}| \geq \varepsilon n^2) \leq \frac{(k-n^2)M}{\varepsilon^2 n^4}$

Also mit Satz 8.3 b): $\frac{k}{n(k)^2} \overline{X}_k \xrightarrow{k \rightarrow \infty} 0$ P -f.s.

Insgesamt: $\exists F_1 \in \mathfrak{A}$ mit $P(F_1) = 1$ und für alle $w \in F_1: \overline{X}_{n^2} \rightarrow 0$ (für $n \rightarrow \infty$)

$\exists F_2 \in \mathfrak{A}$ mit $P(F_2) = 1$ und für alle $w \in F_2: \frac{k}{n(k)^2} \overline{X}_k - \overline{X}_{n(k)^2} \rightarrow 0$ (für $k \rightarrow \infty$)

$\frac{k}{n(k)^2} \rightarrow 1$ für $k \rightarrow \infty$

Es folgt: $\overline{X}_n \rightarrow 0 \forall w \in F_1 \cap F_2$, wobei

$$P(F_1 \cap F_2) = \underbrace{P(F_1)}_1 + \underbrace{P(F_2)}_1 - \underbrace{P(F_1 \cup F_2)}_1 = 1, \text{ d.h. } \overline{X}_n \rightarrow 0 \text{ } P\text{-f.s.}$$

Bemerkung 8.6

a) Wegen Satz 8.3 (fast sichere Konvergenz impliziert stochastische):

$$\frac{1}{n} \sum_{i=1}^n (X_i - E(X_i)) \xrightarrow{n \rightarrow \infty} 0 \text{ } P\text{-f.s.} \implies \frac{1}{n} \sum_{i=1}^n (X_i - E(X_i)) \xrightarrow{n \rightarrow \infty} 0 \text{ } P\text{-stoch.}$$

Die rechte Aussage heißt **schwaches Gesetz großer Zahlen**

b) Das SGGZ gilt auch, wenn $\{X_n\}_{n \in \mathbb{N}}$ stid und $E(X_1)$ existiert (ohne die Existenz der Varianz zu fordern).

Dann gilt mit $\mu = E(X_1): \frac{1}{n} \sum_{i=1}^n \xrightarrow{n \rightarrow \infty} \mu$ P -f.s.

Beweis: sehr aufwendig..., siehe Shiryayev

Beispiel 8.7 (Anwendung des SGGZ)

$\{X_n\}_{n \in \mathbb{N}}$ sei Folge von stid ZV, $A \in \mathfrak{B}^1$, $P(X_n \in A) = p$ für alle $i \in \mathbb{N}$.

$\sum_{i=1}^n \mathbb{1}_A(X_i)$: Anzahl des Auftretens $\{X_i \in A\}$ bis zum n -ten Versuch.

$Y_i := \mathbb{1}_A(X_i)$ sind stid mit $E(Y_i) = P(X_i \in A) = p$ für alle $i \in \mathbb{N}$

Da: $\frac{1}{n} \sum_{i=1}^n (\mathbb{1}_A(X_i) - p) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_A(X_i) - p \xrightarrow{n \rightarrow \infty} 0$ P -f.s. p nach rechts bringen:

Mit SGGZ: $\frac{1}{n} \sum_{i=1}^n Y_i = \frac{1}{n} \underbrace{\sum_{i=1}^n \mathbb{1}_A(X_i)}_{\text{rel. Häufigkeit des Auftretens von } \{X_i \in A\}} \xrightarrow{n \rightarrow \infty} p$ P -f.s.

rel. Häufigkeit des Auftretens von $\{X_i \in A\}$

Beispiel 8.8 $\{X_n\}_{n \in \mathbb{N}}$ sei stid Folge von ZV. $\mu = EX_i$, $\sigma^2 = Var(X_i)$. Dann

$\frac{1}{n} \sum_{i=1}^n X_i = \overline{X}_n \xrightarrow{n \rightarrow \infty} \mu$ P -f.s. (d.h. \overline{X}_n ist **stark konsistenter Schätzer für μ**)

$\frac{1}{n} \sum_{i=1}^n X_i^2 \xrightarrow{n \rightarrow \infty} E(X_1^2)$ P -f.s. (wegen SGGZ; ersetze X_i durch X_i^2)

$$\frac{1}{n} \sum_{i=1}^n (X_i - \overline{X}_n)^2 = \frac{1}{n} \sum_{i=1}^n (X_i^2 - 2X_i \underbrace{\overline{X}_n}_{\text{fest bzgl. } \Sigma} + \overline{X}_n^2) = \frac{1}{n} \sum_{i=1}^n X_i^2 - \underbrace{\frac{1}{n} 2\overline{X}_n \sum_{i=1}^n X_i}_{2\overline{X}_n^2} + \frac{1}{n} \sum_{i=1}^n \overline{X}_n^2$$

$$= \frac{1}{n} \sum_{i=1}^n X_i^2 - (\overline{X}_n)^2 \rightarrow E(X_1^2) - \mu^2 = Var(X_1) = \sigma^2 \quad (\text{wegen SGGZ})$$

(D.h. $\frac{1}{n} \sum_{i=1}^n (X_i - \overline{X}_n)^2$ ist ein **stark konsistenter Schätzer für σ^2**)

Satz 8.9 (Zentraler Grenzwertsatz, ZGWS, CLT)

$\{X_n\}_{n \in \mathbb{N}}$ sei stid Folge von ZV, $\mu = E(X_n)$, $\sigma^2 = Var(X_n)$ existiere. Dann gilt

$$\frac{1}{\sigma\sqrt{n}} \sum_{i=1}^n (X_i - \mu) \stackrel{asym.}{\sim} N(0, 1) \quad (n \rightarrow \infty), \sigma^2 > 0$$

d.h. $P\left(\frac{1}{\sigma\sqrt{n}} \sum_{i=1}^n (X_i - \mu) \leq z\right) \rightarrow \Phi(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{x^2}{2}} dx \quad \forall z \in \mathbb{R}$

Eine Anwendung hiervon (siehe auch das folgende Beispiel):

$$P\left(\sum_{i=1}^n X_i \leq z\right) = P\left(\frac{\sum_{i=1}^n X_i - n \cdot E(X_n)}{\sqrt{n \cdot Var(X_n)}} \leq \frac{z - n \cdot E(X_n)}{\sqrt{n \cdot Var(X_n)}}\right) \stackrel{ZGWS}{\approx} \Phi\left(\frac{z - n \cdot E(X_n)}{\sqrt{n \cdot Var(X_n)}}\right)$$

Beweis: z.B. Casella & Berger 216 ff.

Für $S_n = \sum_{i=1}^n X_i$ gilt $E(S_n) = n\mu$, $Var(S_n) = n\sigma^2$.

$$\frac{S_n - n\mu}{\sqrt{n\sigma^2}} = \frac{1}{\sqrt{n}\sigma} \sum_{i=1}^n (X_i - \mu) \stackrel{asym.}{\sim} N(0, 1) \quad (n \rightarrow \infty)$$

Dies bezeichnet man als die **standardisierte Summe**, und diese konvergiert nach Verteilung gegen die Standardnormalverteilung $N(0, 1)$.

Beispiel 8.10 $\{X_n\}_{n \in \mathbb{N}}$ stid $\sim Bin(1, p)$, $0 < p < 1$.

Es gilt: $E(X_n) = p$, $Var(X_n) = p(1-p)$

Mit ZGWS: $\frac{\sum_{i=1}^n X_i - np}{\sqrt{np(1-p)}} \stackrel{asym.}{\sim} N(0, 1) \quad (n \rightarrow \infty)$

$$\text{Also: } P\left(\sum_{i=1}^n X_i \leq z\right) \left[= \sum_{k=0}^{\lfloor z \rfloor} \binom{n}{k} p^k (1-p)^{n-k} \quad (\text{sehr aufwendig für große } n) \right]$$

$$= P \left(\underbrace{\frac{\sum_{i=1}^n X_i - np}{\sqrt{np(1-p)}}}_{\underset{\text{asym. } N(0,1)}{\sim}} \leq \frac{z - np}{\sqrt{np(1-p)}} \right) \approx \Phi \left(\frac{z - np}{\sqrt{np(1-p)}} \right), \quad \text{wobei } \Phi(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{x^2}{2}} dx$$

(Approximation ist "brauchbar", falls $n \geq 30$)

Anwendung: Lieferung von n Teilen, W'keit, für Defekt: $p = 0,08$.

Gesucht: W'keit, daß Lieferung mehr als 9% defekte Teile enthält!

$$\begin{aligned} P \left(\sum_{i=1}^n X_i > 0,09n \right) &= 1 - P \left(\sum_{i=1}^n X_i \leq 0,09n \right) \approx 1 - \Phi \left(\frac{0,09n - 0,08n}{\sqrt{n \cdot 0,08(1-0,08)}} \right) \\ &= 1 - \Phi \left(\frac{0,01}{\sqrt{0,08 \cdot 0,92}} \sqrt{n} \right) = 1 - \Phi (0,03686 \sqrt{n}) = \dots \end{aligned}$$

9 Schätzfunktionen und Konfidenzintervalle

Zur Motivation:

- a) Werfe Münze in unabhängigen Versuchen, W'keit für Kopf= p (unbekannt).
Schätze p . Modell: X_1, \dots, X_n stid $\sim Bin(1, p)$

$\hat{p} = \hat{p}(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i \rightarrow p$ P -f.s. (bekannt, SGGZ) ist ein vernünftiger Schätzer für p .

Beachte: $\hat{p}(X_1, \dots, X_n)$ ist eine ZV. Setzt man **Realisationen** x_1, \dots, x_n ein, so erhält man den **Schätzwert** $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$.

- b) X_1, \dots, X_n stid $\sim Exp(\lambda)$. Familie der Exp -Vert., parametrische Familie

$\hat{\vartheta} = \frac{1}{n} \sum_{i=1}^n X_i \rightarrow \frac{1}{\lambda} = E(X_1)$ P -f.s. (SGGZ)

$\hat{\vartheta}$ ist ein Schätzer für $g(\lambda) = \frac{1}{\lambda} = E(X_1)$

- c) In a), b) wird der Erwartungswert durch das arithmetische Mittel geschätzt. Es gibt auch schwierigere Situationen, z.B. M : Anzahl der regelmäßigen Besucher einer Webseite

M unbekannt, schätze M . Wie? Intuitives Verfahren:

- Merke die Adressen von n Besuchern (im Logfile), "markierte Besucher"
- Zu einem späteren Zeitpunkt: Merke m Adressen, bestimme die Anzahl x von bereits markierten Besuchern.

Unter entsprechenden Voraussetzungen sollte $\frac{n}{M} \approx \frac{x}{m}$ (ungefähr gleich) sein. Ein vernünftiger Schätzer für M ist $\lfloor \frac{n \cdot m}{x} \rfloor$.

Kann dieses Vorgehen exakt begründet werden?

9.1 Methoden zur Bestimmung von Schätzern

Definition 9.1 X_1, \dots, X_n seien ZV mit gemeinsamer Verteilung $P_{\vartheta}^{(X_1, \dots, X_n)}$, $\vartheta \in \Theta$ (**Parameterraum**). $g(\vartheta) : \Theta \rightarrow \gamma$ sei eine Funktion.

Jede Abbildung $h(X_1, \dots, X_n)$ mit Werten in γ heißt **statistische Schätzfunktion** oder (**Punkt-**) **Schätzer** ((point) estimator).

Beispiel 9.2

- a) X_1, \dots, X_n stid $\sim N(\mu, \sigma^2)$, $\vartheta = (\mu, \sigma^2)$, $\Theta = \mathbb{R} \times \mathbb{R}^+$

$$g_1(\vartheta) = g_1(\mu, \sigma^2) = \mu, \quad h_1(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i \quad \text{OK} \checkmark$$

$$g_2(\vartheta) = g_2(\mu, \sigma^2) = \sigma^2, \quad h_2(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \quad \text{OK} \checkmark$$

- b) X_1, \dots, X_n stid $\sim \text{Exp}(\lambda)$, $\vartheta = \lambda$, $\Theta = \mathbb{R}^+$
- $$g_1(\lambda) = \frac{1}{\lambda} = E(X_1), \quad h_1(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i \quad \text{OK} \checkmark$$
- $$g_2(\lambda) = \lambda, \quad h_2(X_1, \dots, X_n) = \left(\frac{1}{n} \sum_{i=1}^n X_i \right)^{-1} \quad \text{Vernünftig?}$$

Im Folgenden: Methoden um geeignete Schätzer zu finden.

Definition 9.3 (Maximum-Likelihood-Schätzer)

$f(x_1, \dots, x_n | \vartheta)$ für $\vartheta \in \Theta$ sei eine Zähldichte oder Dichte.

$L(\vartheta | x_1, \dots, x_n) = f(x_1, \dots, x_n | \vartheta)$ (als Funktion von ϑ bei gegebenen x_1, \dots, x_n)

heißt **Likelihood-Funktion**, $\hat{\vartheta}(x_1, \dots, x_n)$ heißt **Maximum-Likelihood-Schätzer** (MLS) (maximum likelihood estimator, MLE), falls

$$L(\hat{\vartheta}(x_1, \dots, x_n) | x_1, \dots, x_n) = \sup_{\vartheta \in \Theta} L(\vartheta | x_1, \dots, x_n) \text{ für alle } x_1, \dots, x_n.$$

$g(\hat{\vartheta})$ heißt MLS von $g(\vartheta)$.

Konzept: $\hat{\vartheta}(x_1, \dots, x_n)$ ist bei gegebenen Beobachtungen x_1, \dots, x_n der "passendste" Parameter; der, der die Beobachtungen "am wahrscheinlichsten" macht.

Bemerkungen:

- a) $\hat{\vartheta}$ zu bestimmen, ist eine Maximierungsaufgabe, die oft durch Differenzieren (und Nullsetzen der 1. Ableitung) gelöst werden kann.
- b) Oft ist es günstiger, statt $L(\vartheta | x)$ die **Log-Likelihood-Funktion** $\log L(\vartheta | x)$ zu betrachten (siehe Beisp. 9.4). Das Maximum von $L(\vartheta | x)$ und $\log L(\vartheta | x)$ liegt an derselben Stelle.

Beispiel 9.4

- a) X_1, \dots, X_n stid $\sim N(\mu, \sigma^2)$. Schätze $\vartheta = (\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}^+$.

$$\begin{aligned} f(x_1, \dots, x_n | \vartheta) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i - \mu)^2}{2\sigma^2}} = \frac{1}{(2\pi\sigma^2)^{\frac{n}{2}}} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2} \\ &= L(\vartheta | x_1, \dots, x_n) \end{aligned}$$

$$\log L(\vartheta | x_1, \dots, x_n) = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

Setze $\tau = \sigma^2$, partielle Ableitung = 0 setzen, auflösen nach μ, τ :

$$(i) \quad \frac{\partial \log L(\vartheta | x_1, \dots, x_n)}{\partial \mu} = \frac{2}{2\sigma^2} \sum_{i=1}^n (x_i - \mu) \stackrel{!}{=} 0$$

$$(ii) \quad \frac{\partial \log L(\vartheta | x_1, \dots, x_n)}{\partial \tau} = -\frac{n}{2} \frac{2\pi}{2\pi\tau} + \frac{1}{2\tau^2} \sum_{i=1}^n (x_i - \mu)^2 \stackrel{!}{=} 0$$

$$\text{Aus i) } \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

$$\text{ii) } -\frac{n}{2\tau} + \frac{1}{2\tau^2} \sum_{i=1}^n (x_i - \bar{x})^2 = 0 \iff \tau = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

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

Insgesamt: $(\hat{\mu}, \hat{\sigma}^2) = (\bar{x}, \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2)$ ist der MLS für (μ, σ^2) .

(Noch zu prüfen, daß das Maximum bei $(\hat{\mu}, \hat{\sigma}^2)$ wirklich angenommen wird.)

b) X_1, \dots, X_n stid $\sim \text{Exp}(\lambda)$. Schätze $\vartheta = \lambda \in \mathbb{R}^+$.

$$f(x_1, \dots, x_n | \lambda) = \prod_{i=1}^n \lambda e^{-\lambda x_i} = \lambda^n e^{-\lambda \sum_{i=1}^n x_i} = L(\lambda | x_1, \dots, x_n) \quad \text{für } x_i > 0$$

$$\log L(\lambda | x_1, \dots, x_n) = n \log \lambda - \lambda \sum_{i=1}^n x_i \quad (\text{Aufgabe: } \max_{\lambda} \log L(\dots))$$

$$\frac{\partial \log L(\lambda | x_1, \dots, x_n)}{\partial \lambda} = \frac{n}{\lambda} - \sum_{i=1}^n x_i \stackrel{!}{=} 0 \iff \frac{n}{\lambda} = \sum_{i=1}^n x_i \iff \lambda = \frac{n}{\sum_{i=1}^n x_i} = \frac{1}{\bar{x}}$$

Also $\hat{\lambda} = \frac{1}{\bar{x}}$ ist ein ML-Schätzer für λ .

(Noch zu zeigen: $\hat{\lambda}$ ist ein Maximum von $L(\lambda | x_1, \dots, x_n)$.)

c) X_1, \dots, X_n stid $\sim \text{Bin}(1, p)$. Schätze $p \in [0, 1]$.

$$f(x_1, \dots, x_n | p) = \prod_{i=1}^n p^{x_i} (1-p)^{1-x_i} = p^{\sum_{i=1}^n x_i} (1-p)^{n - \sum_{i=1}^n x_i}$$

$$= L(p | x_1, \dots, x_n) \quad \text{für } x_i \in \{0, 1\}$$

$$\log L(p | x_1, \dots, x_n) = \left(\sum_{i=1}^n x_i \right) \log p + \left(n - \sum_{i=1}^n x_i \right) \log(1-p)$$

(Aufgabe: Maximum über $p \in [0, 1]$!)

$$\frac{\partial \log L(p | x_1, \dots, x_n)}{\partial p} = \frac{1}{p} \sum_{i=1}^n x_i - \frac{1}{1-p} \left(n - \sum_{i=1}^n x_i \right) \stackrel{!}{=} 0$$

$$\iff \frac{1}{p} \bar{x} - \frac{1}{1-p} (1 - \bar{x}) = 0 \iff p = \bar{x}$$

Also $\hat{p} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$ ist ein ML-Schätzer.

Eine weitere Methode zur Konstruktion von Schätzern: **Bayes-Methode**.

- Modelliere Vorkenntnisse über den Parameter ϑ durch eine Wahrscheinlichkeitsverteilung über Θ , die **a-priori**-Verteilung, beschrieben durch die Zähldichte oder Dichte $\pi(\vartheta)$.
- $f(x|\vartheta)$ für $x = (x_1, \dots, x_n)$ sei die Zähldichte oder Dichte der Verteilung von X_1, \dots, X_n bei Vorliegen von ϑ , aufgefaßt als bedingte Verteilung von (X_1, \dots, X_n) , gegeben ϑ .
- Gegeben die Beobachtungen $x = (x_1, \dots, x_n)$. Die zu $f(\vartheta|x)$ gehörige Verteilung heißt **a-posteriori**-Verteilung von ϑ . $f(\vartheta|x)$ reflektiert den Kenntnisstand über ϑ nach Beobachten von x_1, \dots, x_n .

Gegeben: $f(x, \vartheta)$ und die a-priori-Verteilung $\pi(\vartheta)$

Berechnung von $f(\vartheta|x)$ wie folgt (hier für Dichten):

$$f(x) = \int f(x|\vartheta)\pi(\vartheta)d\vartheta \quad (\text{siehe Kapitel 7})$$

Also:

$$f(\vartheta|x) = \frac{f(x, \vartheta)}{f(x)} = \frac{f(x|\vartheta)\pi(\vartheta)}{\int f(x|\vartheta)\pi(\vartheta)d\vartheta} \quad (\text{Nenner ist normierende Konstante})$$

Ein natürlicher Schätzer für ϑ in der folgenden Definition:

Definition 9.5 Bez. wie oben. Die ZV $\hat{\vartheta}(x)$ besitze die (Zähl-)Dichte $f(\vartheta|x)$. Dann heißt $E(\hat{\vartheta}(x))$ **Bayes-Schätzer** von ϑ .

Bemerkung: Bei Dichten ist $\int \vartheta f(\vartheta|x)d\vartheta$ der Bayes-Schätzer.

Beispiel 9.6 Sei $X \sim \text{Bin}(n, p)$, n fest.

Die a-priori-Verteilung für p sei $\text{Beta}(\alpha, \beta)$ für $\alpha, \beta > 0$ mit Dichte

$$\pi(p) = \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} p^{\alpha-1} (1-p)^{\beta-1} \quad \text{für } 0 \leq p \leq 1.$$

Es gilt: $X \sim \text{Beta}(\alpha, \beta) \implies E(X) = \frac{\alpha}{\alpha+\beta}$

Sei $x \in \{0, 1, \dots, n\}$.

$$\begin{aligned} f(p|x) &= \frac{f(x|p)\pi(p)}{\int f(x|p)\pi(p)dp} = \frac{\binom{n}{x} p^x (1-p)^{n-x} \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} p^{\alpha-1} (1-p)^{\beta-1}}{\int \dots dp} \\ &= \frac{\binom{n}{x} \frac{\Gamma(\alpha+\beta)}{\Gamma(\alpha)\Gamma(\beta)} p^{x+\alpha-1} (1-p)^{n-x+\beta-1}}{\int \dots dp} \end{aligned}$$

Begründung: Da das Ganze eine Dichte ist, und $p^{x+\alpha-1}(1-p)^{n-x+\beta-1}$ Teil einer $\text{Beta}(x+\alpha, n-x+\beta)$ -Verteilung ist, heben sich die Vorfaktoren und der Korrekturterm genau weg, so daß der passende Vorfaktor übrigbleibt.

$$= \frac{\Gamma(n+\alpha+\beta)}{\Gamma(x+\alpha)\Gamma(n-x+\beta)} p^{x+\alpha-1} (1-p)^{n-x+\beta-1}$$

ist die Dichte einer $\text{Beta}(x+\alpha, n-x+\beta)$ -Vert.

Also: $\hat{p}(x) = \frac{x+\alpha}{n+\alpha+\beta}$ ist der Bayes-Schätzer zur a-priori-Verteilung π .

Speziell für $\alpha = \beta = 1$, wobei $\text{Beta}(1, 1) = R(0, 1)$: $\hat{p}(x) = \frac{x+1}{n+2}$

Der ML-Schätzer für p lautet: $\hat{p}_{ML}(x) = \frac{x}{n}$

9.2 Gütekriterien für Schätzer

Definition 9.7 $H = h(X_1, \dots, X_n)$ sei ein Schätzer für $g(\vartheta) \in \mathbb{R}$.

$E_{\vartheta}(H - g(\vartheta))^2 = E_{\vartheta}(h(X_1, \dots, X_n) - g(\vartheta))^2$ heißt **mittlerer quadratischer Fehler** (mean squared error, MSE).

MSE mißt die mittlere quadratische Abweichung vom zu schätzenden Wert $g(\vartheta)$. MSE ist eine Funktion von ϑ . Es gilt:

$$\begin{aligned}
 E_{\vartheta} [(H - g(\vartheta))^2] &= E_{\vartheta} [(H - E_{\vartheta}(H) + E_{\vartheta}(H) - g(\vartheta))^2] \\
 &= E_{\vartheta} \left[(H - E_{\vartheta}(H))^2 + 2(H - E_{\vartheta}(H)) \underbrace{(E_{\vartheta}(H) - g(\vartheta))}_{\text{konst. bzgl. } \vartheta} + \underbrace{(E_{\vartheta}(H) - g(\vartheta))^2}_{\text{konst. bzgl. } \vartheta} \right] \\
 &= E_{\vartheta} [(H - E_{\vartheta}(H))^2] + 2(E_{\vartheta}(H) - g(\vartheta)) \underbrace{E_{\vartheta} [H - E_{\vartheta}(H)]}_0 + (E_{\vartheta}(H) - g(\vartheta))^2 \\
 &= E_{\vartheta} [(H - E_{\vartheta}(H))^2] + (E_{\vartheta}(H) - g(\vartheta))^2 \\
 &= \underbrace{Var_{\vartheta}(H)}_{\text{Präzision}} + \underbrace{(Bias_{\vartheta}(H))^2}_{\text{Schiefe}}
 \end{aligned}$$

Wichtig ist der Fall, daß $Bias_{\vartheta}(H) = 0$.

Definition 9.8 Ein Schätzer heißt **erwartungstreu** (unbiased) für $g(\vartheta)$, wenn $Bias_{\vartheta}(H) = 0$ für alle $\vartheta \in \Theta$, falls also $E_{\vartheta}(H) = g(\vartheta)$ für alle $\vartheta \in \Theta$.

Offensichtlich gilt für erwartungstreue Schätzer:

$$MSE(H) = E_{\vartheta}(H - g(\vartheta))^2 = Var_{\vartheta}(H).$$

Beispiel 9.9 $X_1, \dots, X_n \sim N(\mu, \sigma^2)$, $\vartheta = (\mu, \sigma^2)$.

Sind \bar{X} und $\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ erwartungstreu?

$$\text{a) } \hat{\mu} = H(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$$

$$E_{\vartheta}(\bar{X}) = E_{\vartheta}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E_{\vartheta}(X_i) = \frac{1}{n} n\mu = \mu \quad \forall \vartheta = (\mu, \sigma^2).$$

Also: \bar{X} ist erwartungstreu für μ .

$$\text{b) } \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

$$\left| \begin{array}{l}
 \text{Vorüberlegungen:} \\
 \bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right) \implies E(\bar{X}^2) = Var(\bar{X}) + E(\bar{X})^2 = \frac{\sigma^2}{n} + \mu^2 \\
 Y \sim N(0, 1) \implies E(Y^2) = 1 \quad (\text{siehe Beispiel 6.13 c}) \\
 Y \sim N(0, 1) \implies Z = \sigma Y + \mu \sim N(\mu, \sigma^2) \\
 E(Z^2) = E((\sigma Y + \mu)^2) = \sigma^2 \underbrace{E(Y^2)}_1 + 2\sigma\mu \underbrace{E(Y)}_0 + \mu^2 = \sigma^2 + \mu^2
 \end{array} \right.$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2$$

$$E_{\vartheta}(\hat{\sigma}^2) = \frac{1}{n} \sum_{i=1}^n \underbrace{E(X_i^2)}_{\sigma^2 + \mu^2} - \underbrace{E(\bar{X}^2)}_{\frac{\sigma^2}{n} + \mu^2} = \sigma^2 + \mu^2 - \frac{\sigma^2}{n} + \mu^2 = \frac{n-1}{n} \sigma^2$$

Also: $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$ ist nicht erwartungstreu für σ^2 .

Aber: $\hat{\sigma}^2$ ist **asymptotisch erwartungstreu**, d.h. $\lim_{n \rightarrow \infty} E(\hat{\sigma}^2) = \sigma^2$.

Allerdings: $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ ist erwartungstreu für σ^2 .

Denn: $E(S^2) = E\left(\frac{n}{n-1} S^2\right) = E\left(\frac{n}{n-1} \frac{1}{n} \sum_{i=1}^{n-1} (X_i - \bar{X})^2\right) = \frac{n}{n-1} \frac{n-1}{n} \sigma^2 = \sigma^2$.

Beispiel 9.10 (Gütevergleich von 2 Schätzern) $X \sim \text{Bin}(n, p)$. (n fest)

ML-Schätzer: $\hat{p}_{ML} = \frac{x}{n}$

Bayes-Schätzer zur a-priori-Verteilung $\text{Beta}(\alpha, \beta)$: $\hat{p}_B = \frac{x+\alpha}{n+\alpha+\beta}$ (s. Bsp. 9.6)

Welcher ist besser? Vergleich mit MSE:

$$E_p((\hat{p}_{ML} - p)^2) = \text{Var}(\hat{p}_{ML}) = \text{Var}\left(\frac{1}{n} X\right) = \frac{1}{n^2} np(1-p) = \frac{p(1-p)}{n}$$



$$E_p((\hat{p}_B - p)^2) = \text{Var}(\hat{p}_B) + (\text{Bias}(\hat{p}_B))^2 = \text{Var}\left(\frac{X+\alpha}{n+\alpha+\beta}\right) + \left(E_p\left(\frac{X+\alpha}{n+\alpha+\beta}\right) - p\right)^2$$

$$= \frac{\text{Var}(X)}{n+\alpha+\beta} + \left(\frac{E(X)+\alpha}{n+\alpha+\beta} - p\right)^2 = \frac{np(1-p)}{n+\alpha+\beta} + \left(\frac{np+\alpha}{n+\alpha+\beta} - p\right)^2$$

Wähle α, β so, daß $\text{MSE}(\hat{p}_B)$ konstant, d.h. kein Wert von p wird bei der Schätzung bevorzugt.

Lösung: $\alpha = \beta = \frac{1}{n} \sqrt{n}$

Dann gilt: $\hat{p}_B = \frac{X + \frac{1}{n} \sqrt{n}}{n + \sqrt{n}}$ und $E_p((\hat{p}_B - p)^2) = \frac{n}{4(n + \sqrt{n})^2}$



9.3 Konfidenzintervalle

Punktschätzer: Bestimme das $\hat{\vartheta}$, das möglichst nahe am Parameter ϑ liegt.

Ziel jetzt: Angabe von Schranken, so daß der Parameter ϑ mit vorgegebener W'keit innerhalb der Schranken liegt.

Idee: X_1, \dots, X_n stid $\sim \text{Bin}(1, p)$. Mit schwachem GGZ:

$$P\left(\left|\frac{1}{n} \sum_{i=1}^n X_i - p\right| > \varepsilon\right) \xrightarrow{n \rightarrow \infty} 0 \iff P(\bar{X} - \varepsilon \leq p \leq \bar{X} + \varepsilon) \xrightarrow{n \rightarrow \infty} 1 \quad \forall \varepsilon > 0$$


Für große n wird der Parameter p durch das zufällige Intervall $[\bar{X} - \varepsilon, \bar{X} + \varepsilon]$ mit hoher Wahrscheinlichkeit überdeckt. Nutze die Kenntnisse über die Verteilung von \bar{X} , um ε und $P(\dots)$ zu quantifizieren.

Definition 9.11 X_1, \dots, X_n seien ZV mit gemeinsamer Verteilung $P^{(X_1, \dots, X_n)}$. Ein Intervall der Form $[L(X_1, \dots, X_n), U(X_1, \dots, X_n)]$ heißt **Konfidenzintervall zum Niveau** $1 - \alpha$ für $g(\vartheta)$, falls

$$P_\vartheta(g(\vartheta) \in [L(X_1, \dots, X_n), U(X_1, \dots, X_n)]) \geq 1 - \alpha \text{ für alle } \vartheta \in \Theta.$$

Beispiel 9.12 X_1, \dots, X_n stid $\sim N(\mu, \sigma^2)$, σ^2 fest. Dann $\bar{X} \sim N(\mu, \frac{\sigma^2}{n})$ und $\frac{n\bar{X}-n\mu}{\sqrt{\sigma^2 n}} = \frac{\bar{X}-\mu}{\sqrt{\frac{\sigma^2}{n}}} \sim N(0, 1)$. Bestimme μ so, daß

$$P\left(\left|\frac{\bar{X}-\mu}{\sqrt{\frac{\sigma^2}{n}}}\right| \leq u\right) = 1 - \alpha \quad (*)$$



Wähle $u = u_{1-\frac{\alpha}{2}}$ als $(1 - \alpha)$ -Fraktile der $N(0, 1)$ -Verteilung. Löse (*) nach μ auf:

$$P(|\bar{X} - \mu| \leq \frac{\sigma}{\sqrt{n}} u_{1-\frac{\alpha}{2}}) = P(\bar{X} - \frac{\sigma}{\sqrt{n}} u_{1-\frac{\alpha}{2}} \leq \mu \leq \bar{X} + \frac{\sigma}{\sqrt{n}} u_{1-\frac{\alpha}{2}}) = 1 - \alpha$$

Also: $[\bar{X} - \frac{\sigma}{\sqrt{n}} u_{1-\frac{\alpha}{2}}, \bar{X} + \frac{\sigma}{\sqrt{n}} u_{1-\frac{\alpha}{2}}]$ ist ein $(1 - \alpha)$ -Konfidenzintervall für μ .


Beachte: Die Länge des Konfidenzintervalls

- fällt mit wachsendem n
- wächst mit wachsendem Niveau $1 - \alpha$

Auch einseitige Konfidenzintervalle durch: $P(\frac{\bar{X}-\mu}{\sqrt{\frac{\sigma^2}{n}}} \leq u) = 1 - \alpha$

Wähle $u = u_{1-\alpha}$, dann

$$\begin{aligned} P(\bar{X} - \mu \leq \frac{\sigma}{\sqrt{n}} u_{1-\alpha}) \\ = P(\mu \geq \bar{X} - \frac{\sigma}{\sqrt{n}} u_{1-\alpha}) = 1 - \alpha \end{aligned}$$



Also $[\bar{X} - \frac{\sigma}{\sqrt{n}} u_{1-\alpha}, \infty)$ ist einseitiges $(1 - \alpha)$ -Konfidenzintervall für μ .

Das andere einseitige $(1 - \alpha)$ -Konf.-intervall durch Ansetzen des u_α -Fraktils.

Tabelle:

α	0, 1	0, 05	0, 025	0, 01	0, 005	0, 0025
$1 - \alpha$	0, 9	0, 95	0, 975	0, 99	0, 995	0, 9975
$\mu_{1-\alpha}$	1, 282	1, 645	1, 960	2, 326	2, 576	2, 807

(ausführliche Tabelle in Casella & Berger Seite 608 ff)

Beispiel 9.13 (Approximatives Konfidenzintervall für W'keiten)

$X_1, \dots, X_n \sim Bin(1, p)$. Dann $\frac{\bar{X}-p}{\sqrt{\frac{p(1-p)}{n}}} \stackrel{asym.}{\sim} N(0, 1)$. (s. Bsp. 8.10)

Es gilt: $P\left(\frac{\bar{X}-p}{\sqrt{\frac{p(1-p)}{n}}} \leq u_{1-\frac{\alpha}{2}}\right) \approx 1 - \alpha$, wobei $u_{1-\frac{\alpha}{2}}$ Fraktile der $N(0, 1)$ -Verteilung ist.

$|\bar{X} - p| \leq u_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \iff (\bar{X} - p)^2 = u_{1-\frac{\alpha}{2}}^2 \frac{p(1-p)}{n}$ ist eine quadratische Gleichung in p mit den Lösungen $p_L(\bar{X}) \leq p_U(\bar{X})$.

$[p_L(\bar{X}), p_U(\bar{X})]$ ist ein **approximatives** $(1 - \alpha)$ -**Konfidenzintervall** für p .

Index

- S^2 , 54
- $\Gamma(n)$, 24
- Θ , 49
- α -Quantil, 18
- σ -Additivität, 4
- σ -Algebra, 6
 - n -dimensionale Borelsche, 22
 - Borelsche, 7
 - erzeugte, 7
 - feinste, 6
 - gröbste, 6
- $\hat{\vartheta}$, 49, 50
- \hat{p} , 49
- $\mathbb{1}$, 17

- a-posteriori, 51
- a-priori, 51
- absolut-stetig, 19, 23
- absteigend, 7
- Ankunftszeiten, 31
- arithmetisches Mittel, 45
- aufsteigend, 7

- Bayes-Formel, 10
- Bayes-Methode, 51
- Bayes-Schätzer, 52
- bedingte Verteilung, 10
- bedingte Wahrscheinlichkeit, 10
- Bernoulli-Serie, 14
- Bonferroni-Ungleichung, 8
- Borel-Cantelli-Lemma, 12

- Cauchy-Schwarz-Ungleichung, 37

- Dichte, 19, 23
 - bedingte, 42
 - Beta-Verteilung, 52
- diskret, 14
- diskrete Gleichverteilung, 4

- Eindeutigkeitssatz für VF, 16

- Ereignis, 4
- Ergebnis, 4
- Ergebnismenge, 4
- erste Eintrittszeit in B , 26
- erwartungstreu, 53
 - asymptotisch, 54
- Erwartungswert, 34
 - bedingter, 41, 42
- erzeugende Funktion, 20
 - Geometrische Verteilung, 20
 - Poissonverteilung, 20

- Faltung, 29
- faltungsstabil, 32

- Indikatorfunktion, 17

- Konfidenzintervall
 - approximatives $(1 - \alpha)$ -, 55
 - einseitig, 55
 - zum Niveau $1 - \alpha$, 54
- Korrelation, 37
- Kovarianz, 37

- Laplace-Transformierte, 20
 - Exponentialverteilung, 21
 - Rechtecksverteilung, 21
- Laplace-Verteilung, 4
- Likelihood-Funktion, 50
- Limes, 7
- Limes inferior, 12
- Limes superior, 12
- Log-Likelihood-Funktion, 50

- Markoff-Ungleichung, 35
- Meßbarkeit, 13
- Meßraum, 6
- Median, 18
- Mischung, 24
- mittlerer quadratischer Fehler, 52
- Moment

- k -tes, 37
- k -tes faktorielles, 39
- k -tes zentrales, 37
- P-fast sicher konvergent, 44
- P-stochastisch konvergent, 44
- p.d., 8
- Parameterraum, 49
- Poisson-Prozeß, 30
- Produkt- σ -Algebra, 22
- Produkt-Meßraum, 22
- Pseudoinverse, 18
- Realisationen, 49
- Satz von der totalen W'keit, 10
- Schätzer, 49
 - Maximum-Likelihood-, 50
 - stark konsistenter für μ , 47
 - stark konsistenter für σ^2 , 47
- Schätzwert, 49
- schwach konvergent, 44
- Schwaches Gesetz großer Zahlen, 46
- Siebformel, 8
- Standardabweichung, 37
- standardisierte Summe, 47
- Starkes Gesetz großer Zahlen, 45
- statistische Schätzfunktion, 49
- stid, 25
- stochastisch unabhängig, 10, 24, 25
 - identisch verteilt, 25
- Träger, 14
- Tschebyscheff-Ungleichung, 45
- unkorreliert, 36
- Varianz, 37
- verteilt
 - $\Gamma(\alpha, \lambda)$ -, 26
 - binomial-, 14
 - exponential-, 17
 - gleich-, 16
 - rechteck-, 16
- Verteilung, 13
 - Γ -, 26
 - χ^2 -, 30
 - bedingte, 41, 42
 - Beta-, 52
 - Binomial-, 14
 - Erlang-, 26
 - Exponential-, 19
 - gemeinsame, 23
 - geometrische, 15
 - negative Binomial-, 32
 - Normal-, 19
 - Poisson-, 15
 - Rayleigh-, 29
 - Rechteck-, 19
- Verteilungsfunktion, 16
 - bedingte, 42
- verteilungskonvergent, 44
- Verweilzeiten, 31
- Wahrscheinlichkeitsmaß, 7
- Wahrscheinlichkeitsraum, 7
- Wahrscheinlichkeitsverteilung, 7
- Zähldichte, 15
 - bedingte, 41
- Zentraler Grenzwertsatz, 47
- Zufallsgröße, 13
- Zufallsvariable, 13
- Zufallsvektor, 22
- Zuwachs in $(s, t]$, 31
- Zwischenankunftszeiten, 31