


# Statistik III

## Modul P7: Grundlagen der Statistik I

### Vorlesung P7.1: Wahrscheinlichkeitstheorie und Inferenz I



**Prof. Dr. Torsten Hothorn**  
Institut für Statistik  
Ludwig-Maximilians-Universität München  
L<sup>A</sup>T<sub>E</sub>X-Satz von Dipl.-Stat. Esther Herberich  
Korrekturen von Dipl.-Math. Michael Kobl, MSc. und  
den Hörern der Vorlesungen in den WS 07/08 – 11/12.

20. März 2012



# Inhaltsverzeichnis

<b>1</b>	<b>Ereignisse als Mengen</b>	<b>4</b>
1.1	Mengenoperationen . . . . .	4
1.2	Folgen von Mengen . . . . .	5
1.3	Interpretationen . . . . .	6
1.4	Gesetzmäßigkeiten . . . . .	6
1.5	Kombinatorik . . . . .	7
<b>2</b>	<b>Grundlagen der Maßtheorie</b>	<b>12</b>
2.1	Mengensysteme . . . . .	12
2.2	Meßbare Abbildungen . . . . .	18
2.3	Maße und deren Eigenschaften . . . . .	21
2.4	Das Lebesgue-Maß . . . . .	25
<b>3</b>	<b>Das Lebesgue-Integral</b>	<b>28</b>
3.1	Integral für Treppenfunktionen . . . . .	28
3.2	Integral nicht-negativer Funktionen . . . . .	30
3.3	Integrierbare Funktionen . . . . .	34
3.4	Ungleichungen . . . . .	38
3.5	Maße und Dichten . . . . .	42
<b>4</b>	<b>Wahrscheinlichkeitsmaße</b>	<b>44</b>
4.1	Wahrscheinlichkeit als normiertes Maß . . . . .	44
4.2	Diskrete Wahrscheinlichkeitsmaße . . . . .	45
4.3	Stetige Verteilungen . . . . .	48
4.4	Dichten . . . . .	50
<b>5</b>	<b>Zufallsvariablen</b>	<b>55</b>
5.1	Zufallsvariable und deren Verteilung . . . . .	55
5.2	Erwartungswert und Varianz . . . . .	56
5.3	Funktionen von Zufallsvariablen . . . . .	59
5.4	Momente und momenterzeugende Funktionen . . . . .	60

---

<b>6</b>	<b>Bedingte Wahrscheinlichkeit und Unabhängigkeit</b>	<b>66</b>
6.1	Bedingte Wahrscheinlichkeit . . . . .	66
6.2	Unabhängigkeit . . . . .	70
<b>7</b>	<b>Mehrdimensionale Verteilungen</b>	<b>72</b>
7.1	Mehrdimensionale Verteilungen . . . . .	72
7.2	Transformationssatz für Dichten . . . . .	73
7.3	Unabhängigkeit von Zufallsvariablen . . . . .	80
7.4	Einige Ungleichungen . . . . .	84
7.5	Der mehrdimensionale Erwartungswert und die Kovarianzmatrix . . . . .	86
<b>8</b>	<b>Einige spezielle Verteilungen und deren Eigenschaften</b>	<b>90</b>
8.1	Diskrete Verteilungen . . . . .	90
8.2	Die univariate Normalverteilung . . . . .	97
8.3	Die $k$ -dimensionale Normalverteilung . . . . .	100
8.4	Gamma- und $\chi^2$ -Verteilung . . . . .	102
8.5	$t$ - und $F$ -Verteilung . . . . .	106
<b>9</b>	<b>Konvergenz und Wahrscheinlichkeit</b>	<b>109</b>
9.1	Konvergenzarten . . . . .	109
9.2	Konvergenz in Wahrscheinlichkeit . . . . .	115
9.3	Konvergenz in Verteilung . . . . .	117

# Einleitung

Die Vorlesung basiert im wesentlichen auf folgenden Quellen: [Meintrup and Schäffler \(2005\)](#), [Lehmann \(2001\)](#) und [Pfanzagl \(1991\)](#). Weiterhin empfehlenswert ist [Schmidt \(2009\)](#) sowie [Trench \(2010\)](#).

Aus Statistik I/II bekannt:

a)  $\mathbb{P} : \{A | A \subset \Omega\} \rightarrow [0, 1]$  "Wahrscheinlichkeit" mit Axiomen (K1), (K2), (K3) von Kolmogorov.

b)  $\mathbb{P}(A) = \frac{|A|}{|\Omega|}$  "Laplace-Wahrscheinlichkeit"

c)  $X : \Omega \rightarrow \mathbb{R}$  mit  $X^{-1}(A') = \{\omega | X(\omega) \in A'\} \in \mathcal{A}$   
wobei  $A'$  ein "zulässiges" Ereignis und  $\mathcal{A}$  eine "zulässige" Menge von Ereignissen.

d)  $F(x) = \sum_{i: x_i \leq x} f(x_i)$  diskrete Verteilungsfunktion  
 $F(x) = \int_{-\infty}^x f(t) dt$  stetige Verteilungsfunktion

e) Gesetz der großen Zahlen:

$$\mathbb{P} \left( \left| \left( \frac{1}{n} \sum_{i=1}^n X_i \right) - E(X_i) \right| \leq c \right) \rightarrow 1 \text{ für } n \rightarrow \infty$$

wobei  $X_1, \dots, X_n$  iid

f) Zentraler Grenzwertsatz:

$$\sum_{i=1}^n X_i \stackrel{a}{\sim} N(n\mu, n\sigma^2), \mu = \mathbb{E}(X_i), \sigma^2 = \mathbb{V}(X_i)$$

wobei  $X_1, \dots, X_n$  iid

g) Zweidimensionale Normalverteilung

Fragen:

a) Kann eine Wahrscheinlichkeit immer auf der Potenzmenge  $\mathcal{P}(\Omega) = \{A | A \in \Omega\}$  definiert werden?

- b) Was genau passiert bei  $|A| = \infty, |\Omega| = \infty$ ?
- c) Was meint eigentlich "zulässig"?
- d) Gibt es eine einheitliche Theorie für diskrete und stetige Zufallsvariablen und somit *eine* Definition von Dichte, Verteilungsfunktion, Erwartungswert, Momenten,...?
- e) Beweis? Brauchen wir iid?
- f) Beweis? Was meint  $X \stackrel{a}{\sim} N(\mu, \sigma^2)$  eigentlich genau? Brauchen wir iid?
- g) Gibt es eine  $k$ -dimensionale Normalverteilung,  $k > 2$ ?

Statistik III liefert die Antworten auf diese Fragen!

# Kapitel 1

## Ereignisse als Mengen

### 1.1 Mengenoperationen

Bezeichnungen:

- $\Omega \neq \emptyset$  heißt Basismenge oder Ergebnisraum.
- Eine Menge  $A \subseteq \Omega$  heißt Ereignis.
- $\omega_i \in \Omega = \{\omega_1, \omega_2, \dots\}$  heißt Elementarereignis oder Ergebnis.
- $\mathcal{P}(\Omega) = \{A \mid A \subset \Omega\}$ , also die Menge aller Teilmengen der Basismenge  $\Omega$ , heißt Potenzmenge.
- $\mathcal{F} \subseteq \mathcal{P}(\Omega)$ , also eine Menge von Teilmengen von  $\Omega$ , heißt Mengensystem.

*Bemerkung.* Zum Elementarereignis  $\omega_i \underbrace{\in}_{\text{Element}} \Omega$  ist  $\{\omega_i\} \underbrace{\subset}_{\text{Teilmenge}} \Omega$  ein Ereignis.

Zur Schreibweise:  $\mathcal{F}, \mathcal{A}, \mathcal{E}$  Mengensysteme und  $A, B$  Mengen.

#### **Definition 1.1 (Mengenoperationen)**

Seien  $A, B, A_i \subset \Omega, i \in I$ .

Gleichheit:	$A = B \quad :\Leftrightarrow \quad \forall \omega \in \Omega : \quad \omega \in A \Leftrightarrow \omega \in B$
Teilmenge:	$A \subseteq B \quad :\Leftrightarrow \quad \forall \omega \in \Omega : \quad \omega \in A \Rightarrow \omega \in B$
Schnitt:	$A \cap B \quad := \{ \omega \in \Omega   (\omega \in A) \wedge (\omega \in B) \}$ $\bigcap_{i \in I} A_i := \{ \omega \in \Omega   \forall i \in I : \omega \in A_i \}$
Vereinigung:	$A \cup B \quad := \{ \omega \in \Omega   (\omega \in A) \vee (\omega \in B) \}$ $\bigcup_{i \in I} A_i := \{ \omega \in \Omega   \exists i \in I : \omega \in A_i \}$ $\bigcup_{i \in I} A_i := \{ \omega \in \Omega   \exists i \in I : \omega \in A_i, A_i \cap A_j = \emptyset \text{ f\"ur } i \neq j \}$
Differenz:	$A \setminus B := \{ \omega \in \Omega   (\omega \in A) \wedge (\omega \notin B) \}$
Komplement:	$\bar{A} := \{ \omega \in \Omega   \omega \notin A \}$
Symmetrische Differenz:	$A \triangle B := (A \setminus B) \cup (B \setminus A) = (A \cup B) \setminus (A \cap B)$
Mächtigkeit:	$ A  := \text{Anzahl Elemente von } A$
Kardinalität:	$ \mathbb{N}  = \aleph_0$ $ \mathcal{P}(\Omega)  = 2^{ \Omega }$
Kartesisches Produkt:	$A \times B := \{ (a, b)   a \in A \wedge b \in B \}$ $\prod_{i \in I} A_i := \{ (a_1, a_2, \dots, a_{ I })   a_i \in A_i \forall i \in I \}$ $A^k = \prod_{i=1, \dots, k} A = \{ (a_1, \dots, a_k)   a_i \in A, i = 1, \dots, k \}$

## 1.2 Folgen von Mengen

$(A_n)_{n \in \mathbb{N}}$

$A_n \uparrow A :\Leftrightarrow A_1 \subset A_2 \subset A_3 \subset \dots$  und  $\bigcup_{i=1}^{\infty} A_i = A$

$A_n \downarrow A :\Leftrightarrow A_1 \supset A_2 \supset A_3 \supset \dots$  und  $\bigcap_{i=1}^{\infty} A_i = A$

$\liminf A_n := \bigcup_{n=1}^{\infty} \bigcap_{m \geq n} A_m$  enthält Elemente, die in fast allen  $A_n$  enthalten sind.

$\limsup A_n := \bigcap_{n=1}^{\infty} \bigcup_{m \geq n} A_m$  enthält Elemente, in unendlich vielen  $A_n$  enthalten sind.

$A = \lim_{n \rightarrow \infty} A_n \iff \liminf A_n = \limsup A_n$

Bemerkung: "fast alle" ... bis auf endlich viele



## 1.3 Interpretationen

$A \subset \Omega$	...	"A tritt ein", "erscheint", "wird realisiert"
$\bar{A} \subset \Omega$	...	"A tritt nicht ein"
$A_1 \cup A_2$	...	" $A_1$ oder $A_2$ treten ein"
$\bigcup_{i \in I} A_i$	...	"mindestens eines der $A_i$ tritt ein"
$A_1 \cap A_2$	...	" $A_1$ und $A_2$ treten ein"
$\bigcap_{i \in I} A_i$	...	"alle $A_i$ treten ein"
$A_1 \cup A_2 = \emptyset$	...	" $A_1$ und $A_2$ treten nicht gleichzeitig ein", "sind unvereinbar"
$A_1 \triangle A_2$	...	"Entweder $A_1$ oder $A_2$ tritt ein"
$A_1 = A_2$	...	" $A_1$ und $A_2$ beschreiben das gleiche Ereignis"
$\Omega$	...	"Das sichere Ereignis"
$\bar{\Omega}$	...	"Das unmögliche Ereignis"

## 1.4 Gesetzmäßigkeiten

$A, B, C \subset \Omega$ .

Reflexivität:	$A \subseteq A$
Asymmetrie:	$A \subseteq B$ und $B \subseteq A \Rightarrow A = B$
Transitivität:	$A \subseteq B$ und $B \subseteq C \Rightarrow A \subseteq C$ $\Rightarrow \mathcal{P}(\Omega)$ ist bezüglich $\subseteq$ partiell geordnet.
Kommutativgesetz:	$A \cup B = B \cup A$ $A \cap B = B \cap A$
Assoziativgesetz:	$(A \cup B) \cup C = A \cup (B \cup C)$ $(A \cap B) \cap C = A \cap (B \cap C)$
De Morgansche Regeln:	$\overline{A \cup B} = \bar{A} \cap \bar{B}$ $\overline{A \cap B} = \bar{A} \cup \bar{B}$
Mächtigkeiten:	
Gleichmächtigkeit:	$ A  =  B  \iff \exists f : A \rightarrow B$ bijektiv
Addition von Mächtigkeiten:	$A \cap B = \emptyset \iff  A  +  B  =  A \cup B $

**Augustus de Morgan (27. Juni 1806 bis 18. März 1871).** Geboren in Indien, seit 1828 Professor für Mathematik am University College London. Gemeinsam mit George Boole Begründer der formalen Logik. Lehrer von Ada Lovelace (einzige eheliche Tochter Lord Byrons), der ersten Programmiererin (die Sprache 'Ada' ist nach ihr benannt).

[http://de.wikipedia.org/wiki/Augustus\\_De\\_Morgan](http://de.wikipedia.org/wiki/Augustus_De_Morgan)

**Satz 1.2 (Multiplikation von Mächtigkeiten)**

$$|A \times B| = |A| \cdot |B|$$

*Beweis.*

$$A = \{a_1, \dots, a_m\}, B = \{b_1, \dots, b_n\}, |A| = m, |B| = n$$

$$A \times B = \{\{a_1\} \times B \cup \{a_2\} \times B \cup \dots \cup \{a_m\} \times B\}$$

$$|\{a_i\} \times B| = n$$

$$(\{a_i\} \times B) \cap (\{a_j\} \times B) = \emptyset \text{ für } i \neq j$$

$$\begin{aligned} \Rightarrow |A \times B| &= \left| \bigcup_{i=1}^m \{a_i\} \times B \right| \\ &= \sum_{i=1}^m |\{a_i\} \times B| \\ &= |A| \cdot |B| \end{aligned}$$

□

## 1.5 Kombinatorik

Betrachte Indexmengen, also Teilmengen von  $\{1, \dots, n\}$ ,  $n, k \in \mathbb{N}$ :

**Definition 1.3 (Variationen (Beachtung der Reihenfolge))**

- mit Wiederholung

$$V_{k,n}^W = \{x = (x_1, \dots, x_k) \mid x_i \in \{1, \dots, n\}^k\}$$

- ohne Wiederholung

$$V_{k,n}^{oW} = \{x = (x_1, \dots, x_k) \mid x_i \in \{1, \dots, n\}^k; x_i \neq x_j \forall i \neq j\}$$

**Definition 1.4 (Kombinationen (ohne Beachtung der Reihenfolge))**

- mit Wiederholung

$$K_{k,n}^W = \{x = (x_1, \dots, x_k) \mid x_i \in \{1, \dots, n\}^k; 1 \leq x_1 \leq \dots \leq x_k \leq n\}$$

- ohne Wiederholung

$$K_{k,n}^{oW} = \{x = (x_1, \dots, x_k) \mid x_i \in \{1, \dots, n\}^k; 1 \leq x_1 < \dots < x_k \leq n\}$$

**Beispiel 1.1**

Variation:  $(1, 3, 27, 2) \neq (1, 27, 3, 2)$

Kombination:  $(1, 3, 27, 2) = (1, 27, 3, 2)$

*Bemerkung.*  $V_{n,n}^{oW}$  ist die Menge aller Permutationen der Zahlen  $\{1, \dots, n\}$

## Satz 1.5

- a)  $|V_{k,n}^W| = n^k$   
 b)  $|V_{k,n}^{oW}| = \frac{n!}{(n-k)!} \quad (k \leq n)$   
 c)  $|K_{k,n}^W| = \binom{n+k-1}{k}$   
 d)  $|K_{k,n}^{oW}| = \binom{n}{k} \quad (k \leq n)$

*Beweis.*

- a) **(IA)**  $|V_{1,n}^W| = n$   
**(IV)** Sei  $|V_{k-1,n}^W| = n^{k-1}$   
**(IS)**  $|V_{k,n}^W| = |\{(x_1, \dots, x_{k-1}, y) | x \in V_{k-1,n}^W, y \in \{1, \dots, n\}\}| = n^{k-1}n = n^k$  (Satz 1.2)
- b) **(IA)**  $|V_{1,n}^{oW}| = n = \frac{n!}{(n-1)!}$   
**(IV)**  $|V_{k-1,n}^{oW}| = \frac{n!}{(n-(k-1))!}$   
 $|V_{k,n}^{oW}| = |\{(x_1, \dots, x_{k-1}, y) | x \in V_{k-1,n}^{oW}, y \in \{1, \dots, n\} \setminus \{x_1, \dots, x_{k-1}\}\}|$   
 $= \frac{n!}{(n-(k-1))!} \cdot (n-(k-1))$   
**(IS)**  $= \frac{n!}{(n-k+1)!} \cdot (n-k+1)$   
 $= \frac{n!}{(n-k)!}$   
 $|V_{n,n}^{oW}| = n! \text{ (\# Permutationen von } \{1, \dots, n\})$
- d) Sei  $x \in K_{k,n}^{oW}$ . Sei  $\pi \in V_{k,k}^{oW}$  eine Permutation von  $1, \dots, k$  und  $\pi(x)$  eine Permutation  
 von  $x$ .  
 $V_{k,n}^{oW} = \bigcup_{x \in K_{k,n}^{oW}} \{\pi(x) | \pi \in V_{k,k}^{oW}\}$   
 $|V_{k,n}^{oW}| = \left| \bigcup_{x \in K_{k,n}^{oW}} \{\pi(x) | \pi \in V_{k,k}^{oW}\} \right|$   
 $= \sum_{x \in K_{k,n}^{oW}} |\{\pi(x) | \pi \in V_{k,k}^{oW}\}|$   
 $= \sum_{x \in K_{k,n}^{oW}} |V_{k,k}^{oW}| = c \cdot k! \stackrel{!}{=} \frac{n!}{(n-k)!} \stackrel{b)}{=} |V_{k,n}^{oW}|$   
 $\Leftrightarrow c \cdot k! = \frac{n!}{(n-k)!}$   
 $\Leftrightarrow c = \frac{n!}{(n-k)!k!} = \binom{n}{k}$

- c)  $f : K_{k,n}^W \rightarrow K_{k,n+k-1}^{oW}$  bijektiv  
 $x \mapsto f(x) = y = (x_1, x_2 + 1, \dots, x_k + (k-1))$   
 $f^{-1}(y) = (y_1, y_2 - 1, \dots, y_k - (k-1)) = x \in K_{k,n}^W$   
 $|K_{k,n}^W| = |K_{k,n+k-1}^{oW}| = \binom{n+k-1}{k}$

□

**Satz 1.6**

- a) Eine  $n$ -elementige Menge  $A = \{a_1, \dots, a_n\}$  besitzt genau  $\binom{n}{k}$   $k$ -elementige Teilmengen ohne Wiederholung und ohne Beachtung der Reihenfolge.
- b) Seien  $j_1, \dots, j_k \in \mathbb{N}_0$ ;  $\sum_{i=1}^k j_i = n$ .  
 Es gibt genau  $\binom{n}{j_1, j_2, \dots, j_k} = \frac{n!}{j_1! j_2! \dots j_k!}$  Möglichkeiten,  $\{1, \dots, n\}$  in eine Folge von Mengen  $M_1, \dots, M_k$ ;  $M_i \subset \{1, \dots, n\}$ ,  $|M_i| = j_i$  ohne Wiederholung und ohne Beachtung der Reihenfolge aufzuteilen.

*Beweis.*

- a)  $f : K_{k,n}^{oW} \rightarrow \{A_k \mid A_k \subset \{a_1, \dots, a_n\}, |A_k| = k\}$   
 $x \mapsto f(x) = \{a_{x_1}, a_{x_2}, \dots, a_{x_k}\}$  bijektiv  
 $\Rightarrow |\{A_k \mid |A_k| = k\}| = |K_{k,n}^{oW}| = \binom{n}{k}$
- b) Induktion nach  $k$

$$\text{(IA)} \quad k = 2; \quad j_2 = n - j_1$$

$$\stackrel{a)}{\Rightarrow} \binom{n}{j_1} = \frac{n!}{(n-j_1)! j_1!} = \binom{n}{j_1, j_2}$$

$$\text{(IV)} \quad \text{Sei } l_1 = j_1, l_2 = j_2, \dots, l_{k-1} = j_{k-1} + j_k$$

Dann gibt es  $\binom{n}{l_1, \dots, l_{k-1}}$  Möglichkeiten einer Aufteilung in  $M_1, \dots, M_{k-1}$  mit  $|M_i| = l_i$ ,  $|M_{k-1}| = j_{k-1} + j_k$ .

$$\text{(IS)} \quad M_{k-1} \text{ kann auf } \binom{l_{k-1}}{j_{k-1}} = \binom{l_{k-1}}{j_{k-1}, j_k} \text{ Arten aufgeteilt werden.}$$

$$\Rightarrow \binom{n}{l_1, \dots, l_{k-1}} \cdot \binom{l_{k-1}}{j_{k-1}, j_k} = \frac{n!}{j_1! j_2! \dots j_{k-2}! (j_{k-1} + j_k)!} \cdot \frac{(j_{k-1} + j_k)!}{j_{k-1}! j_k!} = \binom{n}{j_1, \dots, j_k}$$

□

**Beispiel 1.2 (Urnenmodell)**

$N$  Kugeln,  $K$  weiß,  $N - K$  rot. Ziehe  $n$  Kugeln a) mit b) ohne Zurücklegen. Wie groß ist die Laplace-Wahrscheinlichkeit ( $\mathbb{P}(A) = \frac{|A|}{|\Omega|} = \frac{\# \text{günstige}}{\# \text{mögliche}} \text{ Ergebnisse}$ ) von Experimenten, bei denen genau  $k$  weiße Kugeln in der Stichprobe vom Umfang  $n$  enthalten sind?

a) Ziehen mit Zurücklegen:

Nummeriere Kugeln  $\underbrace{1, \dots, K}_{\text{weiß}}, \underbrace{K+1, \dots, N}_{\text{rot}}$

$\Omega = V_{n,N}^W$ , d.h., die Elementarereignisse sind alle  $n$  Nummern der Kugeln, welche potentiell aus den  $N$  Kugeln gezogen werden können.

$A_k = \{x \in V_{n,N}^W \mid \sum_{i=1}^n I(x_i \leq K) = k\}$  ...  $k$  weiße Kugeln

Sei  $B \subset \{1, \dots, n\}$  eine Indexmenge ohne Wiederholungen mit  $|B| = k$ .

$A_k^{(B)} := \{x \in A_k \mid x_i \leq K \Leftrightarrow i \in B\}$  ... genau  $k$  Kugeln mit Nummern  $i \in B$  sind weiß (Achtung:  $i \in \{1, \dots, n\}$  ohne Wiederholung, aber  $x_i \in \{1, \dots, N\}$  mit Wiederholung).

$$A_k = \bigcup_B A_k^{(B)}$$

$$|A_k^{(B)}| = |A_k^{\{\{1, \dots, k\}\}}| = \underbrace{K \cdot K \cdot \dots \cdot K}_{k \text{ weiß}} \cdot \underbrace{(N-K) \cdot (N-K) \cdot \dots \cdot (N-K)}_{(n-k) \text{ rot}}$$

Es gibt  $\binom{n}{k}$  Mengen  $B$  ( $j_1 = k, j_2 = n - k$ )

$$\Rightarrow |A_k| = \sum_B |A_k^{(B)}| = \binom{n}{k} K^k (N-K)^{n-k}$$

$$\mathbb{P}(A_k) = \frac{\binom{n}{k} K^k (N-K)^{n-k}}{N^n (=|\Omega|)} = \binom{n}{k} p^k (1-p)^{n-k} \text{ mit } p = \frac{K}{N}$$

vgl. Binomialverteilung

b) Ziehen ohne Zurücklegen:

$$\Omega = K_{n,N}^{\circ W}; \quad |\Omega| = \binom{N}{n}$$

$$\underbrace{x_1, \dots, x_k}_{\text{weiß}} \in K_{k,K}^{\circ W}, \quad \underbrace{x_{k+1}, \dots, x_n}_{\text{rot}} \in K_{n-k, N-K}^{\circ W}$$

$$\Rightarrow \mathbb{P}(A_k) = \frac{|K_{k,K}^{\circ W}| \cdot |K_{n-k, N-K}^{\circ W}|}{\binom{N}{n} (=|\Omega|)} = \frac{\binom{K}{k} \binom{N-K}{n-k}}{\binom{N}{n}} \text{ mit } A_k \text{ aus a)}$$

vgl. Hypergeometrische Verteilung

### Beispiel 1.3 (Geburtstagsparadoxon)

Wie groß ist die Wahrscheinlichkeit, daß in einer Gruppe von  $k$  Personen mindestens zwei am gleichen Tag Geburtstag haben?

$$\Omega = \{x = (x_1, \dots, x_k) \mid x \in \{1, \dots, 365\}^k\} = V_{k,365}^W$$

Annahmen:

- keine Schaltjahre
- keine Zwillinge / Mehrlinge
- jeder Geburtstag ist gleich wahrscheinlich

Unterschiedliche Geburtstage

$$U = \{x \in \Omega \mid x_i \neq x_j \forall i \neq j\} = V_{k,365}^{\circ W}$$

$$|\Omega| = 365^k, \quad |U| = \frac{365!}{(365-k)!}$$

$$\mathbb{P}(\text{"mindestens zwei gleiche G'tage"}) = \mathbb{P}(\bar{U}) = 1 - \mathbb{P}(U) = 1 - \frac{|U|}{|\Omega|} = 1 - \frac{365!}{(365-k)!365^k} = 1 - \frac{364 \cdot \dots \cdot (365-k+1)}{365^{k-1}}$$

$$k = 10 \quad \mathbb{P}(\bar{U}) = 0.12$$

$$k = 20 \quad \mathbb{P}(\bar{U}) = 0.41$$

$$k = 23 \quad \mathbb{P}(\bar{U}) = 0.51$$

$$k = 30 \quad \mathbb{P}(\bar{U}) = 0.71$$

$$k = 40 \quad \mathbb{P}(\bar{U}) = 0.89$$

$$k = 50 \quad \mathbb{P}(\bar{U}) = 0.97$$

# Kapitel 2

## Grundlagen der Maßtheorie

### 2.1 Mengensysteme

#### Definition 2.1 ( $\pi$ -System)

Ein Mengensystem  $\mathcal{F} \subset \mathcal{P}(\Omega)$  heißt durchschnittsstabil, wenn gilt:

$$A, B \in \mathcal{F} \Rightarrow A \cap B \in \mathcal{F}.$$

$\mathcal{F}$  heißt dann auch  $\pi$ -System.

#### Definition 2.2 ( $\sigma$ -Algebra)

Ein Mengensystem  $\mathcal{F} \subset \mathcal{P}(\Omega)$  heißt  $\sigma$ -Algebra über  $\Omega$ , falls gilt:

(S1)  $\Omega \in \mathcal{F}$  (Basismenge)

(S2)  $A \in \mathcal{F} \Rightarrow \bar{A} \in \mathcal{F}$  (Komplement)

(S3)  $A_i \in \mathcal{F}, i \in \mathbb{N} \Rightarrow \bigcup_{i=1}^{\infty} A_i \in \mathcal{F}$  (abzählbare Vereinigung)

#### Beispiel 2.1 (kleinste und größte $\sigma$ -Algebra)

Kleinste  $\sigma$ -Algebra:  $\{\emptyset, \Omega\}$

Größte  $\sigma$ -Algebra:  $\mathcal{P}(\Omega)$

#### Beispiel 2.2

Sei  $\Omega$  überabzählbar und  $A \in \mathcal{F}$  genau dann, wenn  $A$  oder  $\bar{A}$  abzählbar sind. Dann ist  $\mathcal{F}$  eine  $\sigma$ -Algebra.

#### Definition 2.3 (erzeugte $\sigma$ -Algebra)

Ist  $A \subset \Omega$ , so heißt die Menge

$$\sigma(A) = \{\emptyset, A, \bar{A}, \Omega\}$$

die von  $A$  erzeugte  $\sigma$ -Algebra und ist die kleinste  $\sigma$ -Algebra, die  $A$  enthält.

**Satz 2.4 (Schnitt von  $\sigma$ -Algebren)**

Sei  $I \neq \emptyset$  eine beliebige Indexmenge und  $\mathcal{F}_i$  eine  $\sigma$ -Algebra über  $\Omega$  für alle  $i \in I$ . Dann ist auch

$$\mathcal{F} := \bigcap_{i \in I} \mathcal{F}_i$$

eine  $\sigma$ -Algebra über  $\Omega$ .

*Beweis.*

Nach Def. 2.2:

$$(S2) \quad A \in \mathcal{F} \Rightarrow A \in \mathcal{F}_i \quad \forall i \in I \stackrel{(S2)}{\Rightarrow} \bar{A} \in \mathcal{F}_i \quad \forall i \in I \Rightarrow \bar{A} \in \mathcal{F}.$$

(S1) analog

(S3) analog

□

**Definition 2.5 (Erzeuger)**

Sei  $\mathcal{E} \subset \mathcal{P}(\Omega)$  ein Mengensystem und  $\Sigma$  die Menge aller  $\sigma$ -Algebren über  $\Omega$ , die  $\mathcal{E}$  enthalten. Dann wird die  $\sigma$ -Algebra

$$\sigma(\mathcal{E}) := \bigcap_{\mathcal{F} \in \Sigma} \mathcal{F}$$

als die von  $\mathcal{E}$  erzeugte  $\sigma$ -Algebra  $\sigma(\mathcal{E})$  bezeichnet. Gilt umgekehrt für eine  $\sigma$ -Algebra  $\mathcal{A}$

$$\sigma(\mathcal{E}) = \mathcal{A}$$

so heißt  $\mathcal{E}$  Erzeuger von  $\mathcal{A}$ .

**Beispiel 2.3** • Sei  $A \subset \Omega$ ,  $\mathcal{E} = \{A\}$  (ein Mengensystem bestehend aus einer Menge).

Dann ist

$$\sigma(\mathcal{E}) = \sigma(A) = \{\emptyset, A, \bar{A}, \Omega\}.$$

• Sei  $\Omega = \{1, 2, \dots, 7\}$  und  $\mathcal{E} = \{\{1, 2\}, \{6\}\}$ . Dann ist

$$\sigma(\mathcal{E}) = \{\emptyset, \{1, 2\}, \underbrace{\{3, 4, 5, 6, 7\}}_{\overline{\{1,2\}}}, \{6\}, \underbrace{\{1, 2, 3, 4, 5, 7\}}_{\overline{\{6\}}}, \underbrace{\{1, 2, 6\}}_{\overline{\{1,2\} \cup \{6\}}}, \underbrace{\{3, 4, 5, 7\}}_{\overline{\{1,2\} \cup \{6\}}}, \Omega\}.$$

• Sei  $\mathcal{A}$  eine  $\sigma$ -Algebra über  $\Omega$ . Dann ist  $\sigma(\mathcal{A}) = \mathcal{A}$ .

Sei jetzt  $\Omega = \mathbb{R}^n$  und  $]a, b[ := \{x \in \mathbb{R} \mid a < x < b\}$  ein offenes, beschränktes Intervall.

**Definition 2.6 (Borelsche  $\sigma$ -Algebra, Borelsche Mengen)**

Sei  $\Omega = \mathbb{R}$  und

$$\mathcal{O} = \{]a, b[ \mid a, b \in \mathbb{R}, a < b\}$$



das Mengensystem der offenen Intervalle von  $\mathbb{R}$ . Dann heißt

$$\mathcal{B}(\mathbb{R}) := \sigma(\mathcal{O})$$

die Borelsche  $\sigma$ -Algebra über  $\mathbb{R}$ ; ihre Elemente  $A \in \mathcal{B}(\mathbb{R})$  heißen Borelsche Mengen. Für  $\Omega = \mathbb{R}^n$  setzen wir

$$\mathcal{O}^n = \{U \subset \mathbb{R}^n \mid U \text{ offen}\} \text{ und } \mathcal{B}^n := \mathcal{B}(\mathbb{R}^n) = \sigma(\mathcal{O}^n)$$

**Émile Borel (7. Januar 1871 bis 3. Februar 1956).** 1893 Dozent in Lille, 1894 Dissertation (Einführung der Borelmengen). Von 1924–1936 Mitglied der franz. Nationalversammlung und 1925 Marineminister. Mitglied der Resistance und Mitglied der Ehrenlegion. Ein Mondkrater ist nach ihm benannt.

[http://de.wikipedia.org/wiki/%C3%89mile\\_Borel](http://de.wikipedia.org/wiki/%C3%89mile_Borel)

### Satz 2.7 (Eigenschaften von $\mathcal{B}$ )

- i)  $\emptyset \in \mathcal{B}, \mathbb{R} \in \mathcal{B}$
- ii)  $\forall a, b \in \mathbb{R}, a < b :$   
 $[a, b] \in \mathcal{B}, [a, b[ \in \mathcal{B}, ]a, b] \in \mathcal{B}$
- iii)  $\{c\} \in \mathcal{B} \quad \forall c \in \mathbb{R}$
- iv)  $\mathbb{N} \in \mathcal{B}, \mathbb{Q} \in \mathcal{B}, \bar{\mathbb{Q}} \in \mathcal{B}$

*Beweis.*

$$\text{i) } \mathcal{B} \text{ ist } \sigma\text{-Algebra} \begin{array}{l} \stackrel{(S1)}{\Rightarrow} \Omega = \mathbb{R} \in \mathcal{B} \\ \stackrel{(S2)}{\Rightarrow} \bar{\Omega} = \emptyset \in \mathcal{B} \end{array}$$

$$\text{ii) } ]a, b[ = \underbrace{\bigcap_{m=1}^{\infty} \left] a, b + \frac{1}{m} \right[}_{\in \mathcal{O} \subset \mathcal{B}} \in \mathcal{B}$$

(S3) abzählb. Vereinigung und abzählb. Schnitt (vgl. Übung)  $\in \mathcal{B}$

$$[a, b[ = \underbrace{\bigcap_{m=1}^{\infty} \left[ a - \frac{1}{m}, b \right[}_{\in \mathcal{O} \subset \mathcal{B}} \in \mathcal{B}$$

(S3) abzählb. Vereinigung und abzählb. Schnitt (vgl. Übung)  $\in \mathcal{B}$

$$[a, b] = \underbrace{\underbrace{\left] -\infty, a \right[ \cup \left] b, \infty \right[}_{\in \mathcal{O} \subset \mathcal{B}}}_{\text{abzählb. Vereinigung} \in \mathcal{B}} \in \mathcal{B}$$

Komplement  $\in \mathcal{B}$

$$\text{iii) } \{c\} = \underbrace{\bigcap_{m=1}^{\infty} \left[ c, c + \frac{1}{m} \right]}_{\substack{\in \mathcal{B} \text{ nach ii) \\ \text{abzählb. Schnitt (vgl. Übung)} \in \mathcal{B}}} \in \mathcal{B}$$

$$\text{iv) } \mathbb{N} = \underbrace{\bigcup_{i=1}^{\infty} \{i\}}_{\substack{\in \mathcal{B} \text{ nach iii) \\ \text{abzählb. Vereinigung} \in \mathcal{B}}} \in \mathcal{B}$$

ebenso für  $\mathbb{Q}$ ...

□

**Definition 2.8 ( $\lambda$ -System)**

Ein Mengensystem  $\mathcal{D} \subset \mathcal{P}(\Omega)$  heißt  $\lambda$ -System über  $\Omega$ , falls

$$\text{(L1) } \Omega \in \mathcal{D}$$

$$\text{(L2) } A, B \in \mathcal{D} \text{ mit } A \subset B \Rightarrow B \setminus A \in \mathcal{D}$$

$$\text{(L3) } A_i \uparrow A \Rightarrow A \in \mathcal{D}, \quad A = \bigcup_{i=1}^{\infty} A_i$$

**Lemma 2.9**

Ist  $\mathcal{D}$  ein durchschnittsstabiles  $\lambda$ -System, so ist  $\mathcal{D}$  eine  $\sigma$ -Algebra.

*Beweis.*

$$\text{(S1) } \Leftrightarrow \text{(L1)}$$

$$\text{(S2) } \text{Sei } B = \Omega \text{ und } A \in \mathcal{D} \text{ beliebig } \stackrel{\text{(L2)}}{\Rightarrow} \bar{A} = \Omega \setminus A \in \mathcal{D}$$

$$\text{(S3) } A, B \in \mathcal{D} \Rightarrow A \cup B = \overbrace{\underbrace{\bar{A}}_{\in \mathcal{D}} \cap \underbrace{\bar{B}}_{\in \mathcal{D}}}^{\pi\text{-System nach Vor.}} \in \mathcal{D}$$

$$\text{Sei } B_n = \underbrace{\bigcup_{i=1}^n A_i}_{\text{endliche Vereinigung}} \in \mathcal{D} \text{ für } A_i \in \mathcal{D}, i = 1, \dots$$

$$B_n \subset B_{n+1} \subset B_{n+2} \subset \dots \text{ und somit } B_n \uparrow \underbrace{\bigcup_{i=1}^{\infty} A_i}_{\text{(S3)✓}} \in \mathcal{D} \text{ (L3)}$$

□

**Satz 2.10 ( $\lambda$ - $\pi$ -System)**

Sei  $\mathcal{E}$  ein  $\pi$ -System und  $\mathcal{D}$  ein  $\lambda$ -System mit  $\mathcal{E} \subset \mathcal{D}$ . Dann gilt

$$\sigma(\mathcal{E}) \subset \mathcal{D}$$

*Beweis.*

Der Schnitt von  $\lambda$ -Systemen ist wieder ein  $\lambda$ -System (vgl. Satz 2.4) und somit definieren wir in Analogie zu Definition 2.3 das von  $\mathcal{E}$  erzeugte  $\lambda$ -System als

$$\lambda(\mathcal{E}) = \bigcap_{\mathcal{F} \in \Sigma} \mathcal{F}$$

wobei  $\Sigma = \{\mathcal{F} \mid \mathcal{F} \text{ ist } \lambda\text{-System mit } \mathcal{E} \subset \mathcal{F}\}$  das Mengensystem aller  $\lambda$ -Systeme sei, welche  $\mathcal{E}$  enthalten. Sei o.B.d.A  $\mathcal{D} = \lambda(\mathcal{E})$ .

Zu zeigen ist, daß  $\mathcal{D}$  eine  $\sigma$ -Algebra ist, wozu es nach Lemma 2.9 genügt, die Durchschnittsstabilität von  $\mathcal{D}$  zu zeigen. Betrachte also

$$\mathcal{D}_2 = \{A \in \mathcal{D} \mid A \cap B \in \mathcal{D} \quad \forall B \in \mathcal{D}\}$$

und zeige, daß  $\mathcal{D} = \mathcal{D}_2$ .

Schritt 1: Betrachte

$$\mathcal{D}_1 = \{A \in \mathcal{D} \mid A \cap E \in \mathcal{D} \quad \forall E \in \mathcal{E}\}$$

Für  $\mathcal{D}_1$  gilt:

- $\mathcal{E} \subset \mathcal{D}_1$  (denn für alle  $A \in \mathcal{E}$  gilt  $A \in \mathcal{D}_1$ )
- $\mathcal{D}_1$  ist  $\lambda$ -System:

$$\text{(L1)} \quad \Omega \cap E = E \in \mathcal{E} \subset \mathcal{D}_1 \Rightarrow \Omega \in \mathcal{D}_1 \quad \forall E \in \mathcal{E}$$

$$\text{(L2)} \quad A, B \in \mathcal{D}_1, \text{ dann gilt auch } (B \setminus A) \cap E \subset B \cap E \in \mathcal{D} \Rightarrow B \setminus A \in \mathcal{D}_1.$$

$$\text{(L3)} \quad \text{geschenkt}$$

und somit ist  $\mathcal{D}_1$  ein  $\lambda$ -System, welches  $\mathcal{E}$  enthält  $\iff \mathcal{D}_1 \in \Sigma$  und damit wegen

$$\lambda(\mathcal{E}) = \bigcap_{\mathcal{F} \in \Sigma} \mathcal{F}$$

ist  $\mathcal{D} = \mathcal{D}_1$ .

Schritt 2: Betrachte  $\mathcal{D}_2$ . Es gilt:

- $\mathcal{E} \subset \mathcal{D}_1 = \mathcal{D} \Rightarrow \mathcal{E} \subset \mathcal{D}_2$
- $\mathcal{D}_2$  ist  $\lambda$ -System (wie oben)

und somit ist  $\mathcal{D}_2$  auch ein  $\lambda$ -System, welches  $\mathcal{E}$  enthält  $\iff \mathcal{D}_2 \in \Sigma$  und damit wegen

$$\lambda(\mathcal{E}) = \bigcap_{\mathcal{F} \in \Sigma} \mathcal{F}$$

ist  $\mathcal{D} = \mathcal{D}_2$  durchschnittsstabil und also eine  $\sigma$ -Algebra, die  $\mathcal{E}$  enthält.  $\square$

Sei  $f : \Omega_1 \rightarrow \Omega_2$  eine Abbildung, so ist das Bild einer Menge  $A \subset \Omega_1$

$$f(A) := \{f(\omega) \in \Omega_2 \mid \omega \in A\}$$

und das Urbild einer Menge  $B \subset \Omega_2$

$$f^{-1}(B) := \{\omega \in \Omega_1 \mid f(\omega) \in B\}.$$

Es gilt für beliebige  $B, B_i \in \Omega_2, i \in I$  ("Operationstreue")

$$\begin{aligned} f^{-1}\left(\bigcup_{i \in I} B_i\right) &= \left\{ \omega \in \Omega_1 \mid f(\omega) \in \bigcup_{i \in I} B_i \right\} \\ &= \bigcup_{i \in I} \{\omega \in \Omega_1 \mid f(\omega) \in B_i\} \\ &= \bigcup_{i \in I} f^{-1}(B_i) \\ f^{-1}\left(\bigcap_{i \in I} B_i\right) &= \bigcap_{i \in I} f^{-1}(B_i) \\ f^{-1}(\bar{B}) &= \{\omega \in \Omega_1 \mid f(\omega) \in \bar{B}\} \\ &= \Omega_1 \setminus \{\omega \in \Omega_1 \mid f(\omega) \in B\} \\ &= \Omega_1 \setminus f^{-1}(B) = \overline{f^{-1}(B)} \end{aligned}$$

*Bemerkung.*  $f^{-1}$  heißt auch Urbildfunktion. Ist  $f$  bijektiv (dies ist genau dann der Fall, wenn  $f^{-1}(\omega_2)$  genau ein Element  $\omega_1 \in \Omega_1$  enthält für alle Elemente  $\omega_2 \in \Omega_2$ ), so heißt  $f$  auch Umkehrfunktion oder inverse Funktion.

### Definition 2.11

Sei  $\mathcal{F} \subset \mathcal{P}(\Omega)$  ein Mengensystem:

$$f^{-1}(\mathcal{F}) = \{f^{-1}(B) \mid B \in \mathcal{F}\}.$$

### Satz 2.12

Sei  $\mathcal{F}_i$  eine  $\sigma$ -Algebra über  $\Omega_i, i = 1, 2$ . Ist  $f : \Omega_1 \rightarrow \Omega_2$  eine Abbildung, so ist  $f^{-1}(\mathcal{F}_2)$  eine  $\sigma$ -Algebra über  $\Omega_1$  und  $\{B \subset \Omega_2 \mid f^{-1}(B) \in \mathcal{F}_1\}$  eine  $\sigma$ -Algebra über  $\Omega_2$ .

*Beweis.*

(S1), (S2), (S3) folgen aus der Operationstreu, etwa z.B.

$$\begin{aligned} \text{(S2)} \quad A \in f^{-1}(\mathcal{F}_2) &\Leftrightarrow A = f^{-1}(B), B \in \mathcal{F}_2 \\ &\Rightarrow \bar{B} \in \mathcal{F}_2 \\ &\Rightarrow \bar{A} = \overline{f^{-1}(B)} = f^{-1}(\bar{B}) \in f^{-1}(\mathcal{F}_2) \end{aligned}$$

□

### Beispiel 2.4 (Spur- $\sigma$ -Algebra)

Sei  $\mathcal{F}$  eine  $\sigma$ -Algebra über  $\Omega$  und  $A \subset \Omega$  und sei  $f : A \rightarrow \Omega$ ,  $f(a) = a$ . Die  $\sigma$ -Algebra  $f^{-1}(\mathcal{F}) = \{A \cap B \mid B \in \mathcal{F}\}$  heißt Spur- $\sigma$ -Algebra von  $A$ , wird mit  $\mathcal{F}|A$  bezeichnet und ist eine  $\sigma$ -Algebra über  $A$  (folgt aus Satz 2.12).

## 2.2 Meßbare Abbildungen

### Definition 2.13 (meßbar)

Sei  $\mathcal{F}$  eine  $\sigma$ -Algebra über  $\Omega$  und  $A \in \mathcal{F}$ . Dann heißt  $A$  meßbar bezüglich  $\mathcal{F}$ .

### Definition 2.14 (Meßraum)

Sei  $\mathcal{F}$  eine  $\sigma$ -Algebra über  $\Omega$ . Das Tupel  $(\Omega, \mathcal{F})$  heißt Meßraum.

### Definition 2.15 (meßbare Abbildung)

Seien  $(\Omega_1, \mathcal{F}_1)$  und  $(\Omega_2, \mathcal{F}_2)$  zwei Meßräume. Eine Abbildung  $f : \Omega_1 \rightarrow \Omega_2$  heißt  $\mathcal{F}_1$ - $\mathcal{F}_2$ -meßbar, falls

$$f^{-1}(\mathcal{F}_2) \subset \mathcal{F}_1$$

. Von einer meßbaren Abbildung  $f$  spricht man, falls die involvierten  $\sigma$ -Algebren eindeutig bekannt sind.

### Satz 2.16

Seien  $(\Omega_i, \mathcal{F}_i)$ ,  $i = 1, 2$  zwei Meßräume, wobei  $\mathcal{F}_2 = \sigma(\mathcal{E})$  von einem Mengensystem  $\mathcal{E}$  erzeugt ist. Die Abbildung  $f : \Omega_1 \rightarrow \Omega_2$  ist genau dann  $\mathcal{F}_1$ - $\mathcal{F}_2$ -meßbar, wenn

$$f^{-1}(\mathcal{E}) \subset \mathcal{F}_1$$

.

*Beweis.*

" $\Rightarrow$ "  $f$   $\mathcal{F}_1$ - $\mathcal{F}_2$ -meßbar

$$\begin{aligned} &\Leftrightarrow f^{-1}(\mathcal{F}_2) = \{f^{-1}(B) \mid B \in \mathcal{F}_2\} \subset \mathcal{F}_1 \\ &\stackrel{\mathcal{E} \subset \sigma(\mathcal{E}) = \mathcal{F}_2}{\Rightarrow} f^{-1}(\mathcal{E}) = \{f^{-1}(B) \mid B \in \mathcal{E}\} \subset \mathcal{F}_1 \end{aligned}$$

" $\Leftarrow$ "  $\{B \subset \Omega_2 \mid f^{-1}(B) \in \mathcal{F}_1\}$  ist  $\sigma$ -Algebra über  $\Omega_2$  (Satz 2.12).

Wegen  $f^{-1}(\mathcal{E}) \subset \mathcal{F}_1$  ist  $\mathcal{E} \subset \{B \subset \Omega_2 \mid f^{-1}(B) \in \mathcal{F}_1\}$

und somit auch  $\sigma(\mathcal{E}) = \mathcal{F}_2 \subset \{B \subset \Omega_2 \mid f^{-1}(B) \in \mathcal{F}_1\}$ , denn  $\sigma(\mathcal{E})$  ist der Schnitt aller  $\sigma$ -Algebren, die  $\mathcal{E}$  enthalten.

□

### Beispiel 2.5

Sei  $(\Omega, \mathcal{F})$  Meßraum, dann ist  $f : \Omega \rightarrow \mathbb{R}$  genau dann meßbar, wenn

$$f^{-1}(] - \infty, c]) = \{\omega \in \Omega \mid f(\omega) \leq c\} \in \mathcal{F} \quad \forall c \in \mathbb{R},$$

denn  $] - \infty, c]$  bildet ein Erzeugendensystem von  $\mathcal{B}$  (folgt aus Satz 2.7).

### Beispiel 2.6 (stetige Abbildungen)

$$f : \mathbb{R} \rightarrow \mathbb{R} \text{ stetig} \Leftrightarrow f^{-1}(O) \in \mathcal{O} \quad \forall O \in \mathcal{O}$$

$\mathcal{O}$  ist Erzeuger von  $\mathcal{B} = \sigma(\mathcal{O})$  (Def. 2.6) und somit ist  $f$   $\mathcal{B}$ - $\mathcal{B}$ -meßbar.

### Beispiel 2.7 (Indikatorfunktion)

Sei  $(\Omega, \mathcal{F})$  Meßraum und  $A \subset \Omega$ .

$$I_A : \Omega \rightarrow \mathbb{R}$$

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

$$I_A^{-1} \in \{\emptyset, \Omega, A, \bar{A}\} \subset \mathcal{F} \Leftrightarrow A \in \mathcal{F}$$

d.h.  $I_A$  ist genau dann  $\mathcal{F}$ - $\mathcal{B}$ -meßbar, wenn  $A \in \mathcal{F}$ . Deshalb heißt  $A$  meßbar, wenn  $A \in \mathcal{F}$  gilt (Def. 2.13)

### Satz 2.17 (Meßbarkeit der Komposition)

Sind  $(\Omega_i, \mathcal{F}_i)$ ,  $i = 1, 2, 3$  Meßräume und  $f : \Omega_1 \rightarrow \Omega_2$  und  $g : \Omega_2 \rightarrow \Omega_3$  meßbar. Dann ist auch  $g \circ f : \Omega_1 \rightarrow \Omega_3$  meßbar.

*Beweis.*

$$f^{-1}(\mathcal{F}_2) \subset \mathcal{F}_1 \text{ und } g^{-1}(\mathcal{F}_3) \subset \mathcal{F}_2 \Rightarrow$$

$$f^{-1}(\underbrace{g^{-1}(\mathcal{F}_3)}_{\subset \mathcal{F}_2}) \subset \mathcal{F}_1 \Leftrightarrow (g \circ f)^{-1}(\mathcal{F}_3) \subset \mathcal{F}_1$$

□

*Bemerkung.* Sei  $(\Omega, \mathcal{F})$  ein Meßraum und  $f = (f_1, \dots, f_n) : \Omega \rightarrow \mathbb{R}^n$  und  $\mathcal{B}^n$  die Borelsche  $\sigma$ -Algebra über  $\mathbb{R}^n$  (später). Dann ist  $f$   $\mathcal{F}$ - $\mathcal{B}^n$ -meßbar, wenn  $f_i$ ,  $i = 1, \dots, n$   $\mathcal{F}$ - $\mathcal{B}$ -meßbar sind; siehe Satz 1.28 in [Meintrup and Schäffler \(2005\)](#).

### Satz 2.18

Es sei  $(\Omega, \mathcal{F})$  ein Meßraum,  $f, g : \Omega \rightarrow \mathbb{R}$  meßbare Funktionen und  $\alpha, \beta \in \mathbb{R}$ . Dann sind die Funktionen

- a)  $\alpha f + \beta g$   
 b)  $f \cdot g$   
 c)  $f/g$  falls  $g(\omega) \neq 0 \quad \forall \omega \in \Omega$

ebenfalls meßbar.

*Beweis.*

$$h : \Omega \rightarrow \mathbb{R}^2 \\ \omega \mapsto h(\omega) = (f(\omega), g(\omega)) \text{ meßbar (siehe letzte Bemerkung)}$$

a)

$$l : \mathbb{R}^2 \rightarrow \mathbb{R} \\ (x, y) \mapsto l(x, y) = \alpha x + \beta y \text{ stetig und somit meßbar}$$

also ist  $l \circ h = \alpha f + \beta g$  mit Satz 2.17 meßbar

- b)  $l(x, y) = x \cdot y$  meßbar weil stetig, weiter wie in a)  
 c)  $l(x, y) = x/y$  meßbar weil stetig, weiter wie in a)

□

*Bemerkung.* Eine Funktion  $f : \Omega \rightarrow \mathbb{R}$  heißt reellwertig. Eine Funktion  $f : \Omega \rightarrow \mathbb{R} \cup \{-\infty, \infty\} =: \bar{\mathbb{R}}$  heißt numerisch. Ist  $(\Omega, \mathcal{F})$  ein Meßraum, so heißt  $f$   $\mathcal{F}$ - $\bar{\mathcal{B}}$ -meßbar, wenn  $\{\omega \in \Omega | f(\omega) \leq c\} \in \mathcal{F} \quad \forall c \in \mathbb{R}$  bei  $\bar{\mathcal{B}} = \sigma(\mathcal{B} \cup \{\infty\} \cup \{-\infty\})$

Schreibweise:

$$\{f \leq c\} := \{\omega \in \Omega | f(\omega) \leq c\}$$

$$\{f < c\} \quad \quad \quad \vdots$$

$$\{f = c\} \quad \quad \quad \vdots$$

### Satz 2.19

Sei  $(\Omega, \mathcal{F})$  ein Meßraum und  $(f_n)_{n \in \mathbb{N}}$  eine Folge meßbarer numerischer Funktionen

$$f_n : \Omega \rightarrow \bar{\mathbb{R}}, n \in \mathbb{N}.$$

Dann sind  $\sup_n f_n$ ,  $\inf_n f_n$ ,  $\limsup_n f_n$  und  $\liminf_n f_n$  meßbar.

*Beweis.*

$\sup_n f_n :$

$$(\sup_n f_n)^{-1}((-\infty, c]) = \{\omega \in \Omega \mid \sup_n f_n(\omega) \leq c\} = \underbrace{\bigcap_{n=1}^{\infty} \{\omega \in \Omega \mid f_n(\omega) \leq c\}}_{\text{nach Voraussetzung}} \in \mathcal{F}$$

abzählb. Schnitt in  $\mathcal{F}$  enthalten, weil  $\mathcal{F}$   $\sigma$ -Algebra

$\inf_n f_n = -\sup_n (-f_n)$  Komposition  $\Rightarrow$  meßbar nach Satz 2.17, denn

$$-\sup_n (-f_n) = (a \circ \sup_n \circ a)(f_n) \text{ mit } a(f) = -f \quad \forall f \in M$$

$\limsup_n f_n = \inf_{n \geq 1} (\sup_{k \geq n} f_k)$  meßbar nach Satz 2.17

$\liminf_n f_n = \sup_{n \geq 1} (\inf_{k \geq n} f_k)$  meßbar nach Satz 2.17 □

### Satz 2.20

Ist  $(\Omega, \mathcal{F})$  ein Meßraum und  $f : \Omega \rightarrow \bar{\mathbb{R}}$  eine meßbare numerische Funktion. Dann sind auch

- a)  $f^+ := \max(f, 0)$     Positivteil
- b)  $f^- := \max(-f, 0)$     Negativteil
- c)  $|f| := f^+ + f^-$     Betrag

meßbar. (Bemerkung:  $f = f^+ - f^-$ )

*Beweis.*

- a) Betrachte die Folge  $(0, f, f, \dots)$   
 $\sup_n f_n = \max(0, f) = f^+$  ist meßbar
- b) Betrachte die Folge  $(0, -f, -f, \dots)$   
 $\sup_n f_n = \max(0, -f) = f^-$  ist meßbar
- c)  $|f| = f^+ + f^-$  ist meßbar (Satz 2.18)

□

## 2.3 Maße und deren Eigenschaften

### Definition 2.21 (( $\sigma$ -endliches, endliches, normiertes) Maß)

Sei  $(\Omega, \mathcal{F})$  ein Meßraum. Eine Funktion  $\mu : \mathcal{F} \rightarrow \bar{\mathbb{R}}$  heißt Maß auf  $\mathcal{F}$ , falls die folgenden Bedingungen erfüllt sind

(M1)  $\mu(\emptyset) = 0$



(M2)  $\mu(A) \geq 0 \quad \forall A \in \mathcal{F}$

(M3) für jede Folge disjunkter Mengen  $(A_n)_{n \in \mathbb{N}} \in \mathcal{F}$  gilt

$$\mu \left( \bigcup_{n=1}^{\infty} A_n \right) = \sum_{n=1}^{\infty} \mu(A_n) \quad (\sigma\text{-Additivität})$$

Gibt es eine Folge  $(A_n)$  von Mengen aus  $\mathcal{F}$  mit  $\bigcup_{n=1}^{\infty} A_n = \Omega$  und  $\mu(A_n) < \infty \quad \forall n \in \mathbb{N}$ , so heißt  $\mu$   $\sigma$ -endlich. Ist  $\mu(\Omega) < \infty$ , so heißt  $\mu$  endlich. Ist  $\mu(\Omega) = 1$ , so heißt  $\mu$  normiertes Maß.

*Bemerkung.* Es ist der Verdienst von [Kolmogorov \(1933\)](#), das Wahrscheinlichkeitsmaß als normiertes Maß eingeführt zu haben.

**Andrej Nikolaevic Kolmogorov (25. April 1903 bis 20. Oktober 1987).** Studium der Mathematik, Geschichte und Metallurgie in Moskau, seit 1931 Professor für Mathematik. 1933 “Grundbegriffe der Wahrscheinlichkeitsrechnung”, betreute insgesamt 79 Doktoranden. [http://de.wikipedia.org/wiki/Andrei\\_Nikolajewitsch\\_Kolmogorow](http://de.wikipedia.org/wiki/Andrei_Nikolajewitsch_Kolmogorow)

### Definition 2.22 (Maßraum)

Ist  $(\Omega, \mathcal{F})$  ein Meßraum und  $\mu : \mathcal{F} \rightarrow \bar{\mathbb{R}}$  ein Maß, so heißt das Tripel  $(\Omega, \mathcal{F}, \mu)$  Maßraum.

### Beispiel 2.8 (Dirac-Maß)

$$\delta_\omega : \mathcal{F} \rightarrow \mathbb{R} \quad \text{mit} \quad \delta_\omega(A) = I_A(\omega)$$

**Paul Adrien Maurice Dirac (8. August 1902 bis 20. Oktober 1984).** Mitbegründer der Quantenphysik und war 1925 zusammen mit Schrödinger Nobelpreisträger für Physik.

[http://de.wikipedia.org/wiki/Paul\\_Dirac](http://de.wikipedia.org/wiki/Paul_Dirac)

### Beispiel 2.9 (Zählmaß)

$$\mu_Z : \mathcal{F} \rightarrow \bar{\mathbb{R}} \quad \mu_Z(A) := \begin{cases} |A| & \text{falls } A \text{ endlich} \\ \infty & \text{sonst} \end{cases}$$

*Bemerkung.* Sei  $A \in \mathcal{F}$  fest und höchstens abzählbar, dann ist  $\mu_Z|_A(B) = |A \cap B|$  ein  $\sigma$ -endliches Maß und heißt reduziertes Zählmaß.

### Beispiel 2.10

Sei  $\Omega$  überabzählbar und  $A \in \mathcal{F}$  genau dann, wenn  $A$  oder  $\bar{A}$  abzählbar ist  $\Rightarrow \mathcal{F}$  ist  $\sigma$ -Algebra (Beispiel 2.2)

$$\mu : \mathcal{F} \rightarrow \bar{\mathbb{R}} \quad \mu(A) := \begin{cases} 0 & A \text{ abzählbar} \\ \infty & \text{sonst} \end{cases}$$

Dann ist  $(\Omega, \mathcal{F}, \mu)$  Maßraum.

**Satz 2.23 (Eigenschaften des Maßes)**

Sei  $(\Omega, \mathcal{F}, \mu)$  ein Maßraum und  $A, B, A_n \in \mathcal{F}, n \in \mathbb{N}$ . Dann gilt

- i) endliche Additivität:  $A \cap B = \emptyset \Rightarrow \mu(A \cup B) = \mu(A) + \mu(B)$
- ii) Subadditivität:  $A \subset B$  und  $\mu(A) < \infty \Rightarrow \mu(B \setminus A) = \mu(B) - \mu(A)$
- iii) Monotonie:  $A \subset B \Rightarrow \mu(A) \leq \mu(B)$
- iv) Sub- $\sigma$ -Additivität:

$$\mu\left(\bigcup_{n=1}^{\infty} A_n\right) \leq \sum_{n=1}^{\infty} \mu(A_n)$$

*Beweis.*

- i) Betrachte Folge  $A, B, \emptyset, \emptyset, \dots \stackrel{(M3)}{\Rightarrow}$  i)
- ii)/iii)  $B = A \dot{\cup} (B \setminus A) \stackrel{(M3)}{\Rightarrow}$   
 $\mu(B) = \underbrace{\mu(A)}_{\geq 0} + \underbrace{\mu(B \setminus A)}_{\geq 0 \text{ nach (M2)}} \geq \mu(A) \Leftrightarrow$  iii) und  
 $\mu(B \setminus A) = \mu(B) - \mu(A) \Leftrightarrow$  ii) falls  $\mu(A) < \infty$
- iv)  $\bigcup_{n=1}^{\infty} A_n = \bigcup_{n=1}^{\infty} \left( A_n \setminus \bigcup_{k=1}^{n-1} A_k \right)$   
 $\stackrel{(M3)}{\Rightarrow} \mu\left(\bigcup_{n=1}^{\infty} A_n\right) = \sum_{n=1}^{\infty} \mu\left( A_n \setminus \bigcup_{k=1}^{n-1} A_k \right)$   
 $\stackrel{\text{ii)}}{\leq} \sum_{n=1}^{\infty} \mu(A_n)$

□

**Satz 2.24 (Stetigkeit des Maßes  $\mu$ )**

Sei  $(\Omega, \mathcal{F}, \mu)$  ein Maßraum und  $A, A_n \in \mathcal{F}, n \in \mathbb{N}$ . Dann gilt

- i) Stetigkeit von unten:  $A_n \uparrow A \Rightarrow \mu(A_n) \uparrow \mu(A)$
- ii) Stetigkeit von oben:  $A_n \downarrow A$  und  $\mu(A_1) < \infty \Rightarrow \mu(A_n) \downarrow \mu(A)$

*Beweis.*

i) Sei  $A_0 := \emptyset$ .  $A_n \uparrow A$  meint  $A_1 \subset A_2 \subset \dots$  und  $\bigcup_{n=1}^{\infty} A_n = A$

Also ist  $A = \bigcup_{n=1}^{\infty} A_n \setminus A_{n-1}$  eine disjunkte Vereinigung

$$\begin{aligned} \Rightarrow \mu(A) &\stackrel{(M3)}{=} \sum_{k=1}^{\infty} \mu(A_k \setminus A_{k-1}) \\ &= \lim_{n \rightarrow \infty} \mu \left( \bigcup_{k=1}^n A_k \setminus A_{k-1} \right) \\ &= \lim_{n \rightarrow \infty} \mu(A_n) \end{aligned}$$

ii)  $A \subset A_n \subset A_1 \stackrel{\text{Monotonie}}{\Rightarrow} \mu(A) < \infty$   
 $\mu(A_n) < \infty \quad \forall n \in \mathbb{N}$

Wegen  $A_n \downarrow A$  gilt  $A_1 \setminus A_n \uparrow A_1 \setminus A$  und somit

$$\begin{aligned} \mu(A_1 \setminus A_n) &= \mu(A_1) - \mu(A_n) &= \mu(A_1 \setminus A_n) \uparrow \mu(A_1 \setminus A) = \\ &= \mu(A_1) - \mu(A) \Rightarrow \mu(A_n) \downarrow \mu(A) \end{aligned}$$

□

### Satz 2.25 (Maeindeutigkeitsatz)

Es seien  $\mu$  und  $\nu$  zwei Mae auf einem Meraum  $(\Omega, \mathcal{F})$  und  $\mathcal{E}$  ein durchschnittsstabiler Erzeuger von  $\mathcal{F}$  mit folgenden Eigenschaften:

i)  $\mu(E) = \nu(E) \quad \forall E \in \mathcal{E}$

ii) Es gibt eine Folge  $(E_n), n \in \mathbb{N}$ , disjunkter Mengen aus  $\mathcal{E}$  mit  $\mu(E_n) = \nu(E_n) < \infty$  und

$$\bigcup_{n=1}^{\infty} E_n = \Omega.$$

Dann sind beide Mae identisch:  $\mu = \nu$ .

*Beweis.*

Betrachte zu jedem  $n \in \mathbb{N}$  das Mengensystem

$$\mathcal{D}(E_n) := \{A \in \mathcal{F} \mid \mu(A \cap E_n) = \nu(A \cap E_n)\}$$

$\mathcal{D}(E_n)$  ist ein  $\lambda$ -System, weil

(L1)  $\Omega \in \mathcal{D}(E_n) : \mu(\Omega \cap E_n) = \mu(E_n) = \nu(E_n) = \nu(\Omega \cap E_n) \quad \checkmark$

(L2)  $A, B \in \mathcal{D}(E_n), A \subset B \Rightarrow$

$$\begin{aligned} \mu(B \setminus A \cap E_n) &\stackrel{\text{Subtraktivitt}}{=} \mu(B) - \mu(A \cap E_n) \\ &= \nu(B) - \nu(A \cap E_n) \\ &= \nu((B \setminus A) \cap E_n) \\ \Rightarrow B \setminus A &\in \mathcal{D}(E_n) \quad \checkmark \end{aligned}$$

$$\begin{aligned}
(\mathbf{L3}) \quad A_i \in \mathcal{D}(E_n), A_i \uparrow A = \bigcup_{i=1}^{\infty} A_i \\
\mu(A \cap E_n) &= \mu\left(\left(\bigcup_i A_i\right) \cap E_n\right) \\
&= \mu\left(\bigcup_i (A_i \cap E_n)\right) \\
&\stackrel{\sigma\text{-Add.}}{=} \sum_i \mu(A_i \cap E_n) \\
&= \sum_i \nu(A_i \cap E_n) \\
&= \nu(A \cap E_n) \quad \checkmark
\end{aligned}$$

$\mathcal{E} \subset \mathcal{D}(E_n)$  durchschnittsstabil

$$\begin{aligned}
&\stackrel{\lambda\text{-}\pi\text{-Lemma}}{\Rightarrow} \sigma(\mathcal{E}) = \mathcal{F} \subset \mathcal{D}(E_n) \quad \forall n \in \mathbb{N} \\
&\Rightarrow \mu(A \cap E_n) = \nu(A \cap E_n) \quad \forall A \in \mathcal{F}, n \in \mathbb{N}
\end{aligned}$$

$A = \bigcup_{i=1}^{\infty} (A \cap E_i)$  ist disjunkte Zerlegung von  $A$  für alle  $A \in \mathcal{F}$  und also ist

$$\mu(A) = \nu(A) \quad \forall A \in \mathcal{F} \Leftrightarrow \mu = \nu$$

□

### Definition 2.26 (Nullmenge)

Ist  $(\Omega, \mathcal{F}, \mu)$  ein Maßraum und  $A \in \mathcal{F}$  mit  $\mu(A) = 0$ , so heißt  $A$   $(\mu)$ -Nullmenge.

### Definition 2.27 (vollständiges Maß, Vervollständigung)

Es sei  $(\Omega, \mathcal{F}, \mu)$  ein Maßraum. Ein Maß  $\mu$  heißt vollständig, wenn gilt:

$$\begin{aligned}
&A \in \mathcal{F}, \mu(A) = 0 \text{ und } B \subset A \\
&\Rightarrow B \in \mathcal{F}.
\end{aligned}$$

Die  $\sigma$ -Algebra  $\mathcal{F}_0 := \{A \cup N \mid A \in \mathcal{F}, N \text{ Teilmenge einer } \mu\text{-Nullmenge}\}$  heißt Vervollständigung von  $\mathcal{F}$ .

*Bemerkung.* Durch  $\mu_0(A \cup N) := \mu(A)$ ,  $A \cup N \in \mathcal{F}_0$  entsteht ein neuer Maßraum  $(\Omega, \mathcal{F}_0, \mu_0)$  mit einem vollständigen Maß  $\mu_0$ .

## 2.4 Das Lebesgue-Maß

### Satz 2.28 (Existenz und Eindeutigkeit des Lebesgue-Maßes)

In jeder Dimension  $n \in \mathbb{N}$  gibt es genau ein Maß

$$\lambda^n : \mathcal{B}^n \rightarrow [0, \infty[,$$

sodaß für jedes  $n$ -dimensionale Intervall  $]a, b[ = ]a_1, b_1[ \times \dots \times ]a_n, b_n[ \subset \mathbb{R}^n$  gilt:

$$\lambda^n(]a, b[) = \prod_{i=1}^n (b_i - a_i)$$

$\lambda^n$  heißt ( $n$ -dimensionales) Lebesgue-Maß. Weiterhin gibt es zu jeder rechtsseitig stetigen, monoton wachsenden Funktion  $F : \mathbb{R} \rightarrow \mathbb{R}$  genau ein Maß

$$\lambda_F : \mathcal{B} \rightarrow \overline{\mathbb{R}},$$

sodaß für alle  $]a, b] \subset \mathbb{R}$  gilt:

$$\lambda_F(]a, b]) = F(b) - F(a).$$

$\lambda_F$  heißt Lebesgue-Stieltjes-Maß von  $F$ .

*Beweis.*

Siehe Anhang A.1. in [Meintrup and Schäffler \(2005\)](#) □

**Henri Léon Lebesgue (28. Juni 1875 bis 26. Juli 1941).** 1899–1902 Gymnasiallehrer in Nancy, dabei Arbeit am Integralbegriff, 1902 Dissertation, seit 1906 Professor.

[http://de.wikipedia.org/wiki/Henri\\_L%C3%A9on\\_Lebesgue](http://de.wikipedia.org/wiki/Henri_L%C3%A9on_Lebesgue)

**Thomas Jean Stieltjes (29. Dezember 1856 bis 31. Dezember 1894).** Seit 1873 Studium in Delft, dreimal durch Prüfungen gefallen (da er lieber die Arbeiten von Gauss und Jacobi las), danach Arbeit im Observatorium in Leiden, dessen Direktor ihm freie Zeit für mathematische Untersuchungen ließ. 1884 wegen “mangelnder Qualifikation” erfolglose Bewerbung auf eine Professur in Groningen.

[http://en.wikipedia.org/wiki/Thomas\\_Joannes\\_Stieltjes](http://en.wikipedia.org/wiki/Thomas_Joannes_Stieltjes)

*Bemerkung.*  $\lambda := \lambda^1$ . Ist  $x \in \mathbb{R}$ , so gilt

$$\lambda(\{x\}) \stackrel{\text{Satz 2.24}}{=} \lim_{n \rightarrow \infty} \lambda\left(\left]x - \frac{1}{n}, x\right]\right) = \lim_{n \rightarrow \infty} x - \left(x - \frac{1}{n}\right) = \lim_{n \rightarrow \infty} \frac{1}{n} = 0$$

$\lambda(A) = 0$  für jede abzählbare Teilmenge  $A \subset \mathbb{R}$ , z.B.  $\lambda(\mathbb{N}) = 0$  wegen  $\sigma$ -Additivität

$$\lambda(\mathbb{N}) = \lambda\left(\bigcup_{i \in \mathbb{N}} \{i\}\right) = \sum_{i \in \mathbb{N}} \underbrace{\lambda(\{i\})}_{=0}$$

$$\lambda(\mathbb{R}) \geq \lambda(]0, n]) = n \quad \forall n \in \mathbb{N}$$

$$\Rightarrow \lambda(\mathbb{R}) = \infty$$

**Satz 2.29 (Translationsinvarianz des Lebesgue-Maßes)**

$$\lambda^n(A) = \lambda^n(A + v) \quad \forall v \in \mathbb{R}^n \quad A = ]a, b]$$

*Beweis.*

$$\begin{aligned} \lambda^n(A + v) &= \prod_{i=1}^n (b_i + v_i) - (a_i + v_i) \\ &= \prod_{i=1}^n b_i - a_i = \lambda^n(A) \end{aligned}$$

□

**Definition 2.30 (Bildmaß)**

Ist  $(\Omega_1, \mathcal{F}_1, \mu)$  ein Maßraum und  $(\Omega_2, \mathcal{F}_2)$  Meßraum und  $f : \Omega_1 \rightarrow \Omega_2$  meßbar, so heißt

$$\mu_f : \mathcal{F}_2 \rightarrow [0, \infty[$$

$$B \mapsto \mu_f(B) = \mu(f^{-1}(B))$$

das Bildmaß  $\mu_f$  von  $\mu$  unter  $f$  und  $(\Omega_2, \mathcal{F}_2, \mu_f)$  Maßraum.

**Beispiel 2.11**

$(\mathbb{R}, \mathcal{B}, \lambda)$  und  $(\mathbb{R}, \mathcal{B})$

$$f : \mathbb{R} \rightarrow \mathbb{R}, \quad x \mapsto x + a$$

$$\lambda_f(A) = \lambda(f^{-1}(A)) = \lambda(A - a) = \lambda(A) \quad \forall A \in \mathcal{B} \text{ und } \lambda_f \text{ ist Maß auf } (\mathbb{R}, \mathcal{B}).$$

*Bemerkung.*  $\lambda^n|_A(B) = \lambda^n(A \cap B)$  mit  $A \in \mathcal{B}^n$  ist ein Maß auf  $(\mathbb{R}^n, \mathcal{B}^n)$  und heißt Spurmaß.

# Kapitel 3

## Das Lebesgue-Integral

### 3.1 Integral für Treppenfunktionen

Sei  $(\Omega, \mathcal{F}, \mu)$  ein Maßraum und  $f : \Omega \rightarrow \mathbb{R}$  eine  $\mathcal{F}$ - $\mathcal{B}$ -meßbare Funktion. Sei weiterhin  $M := \{f \mid f : \Omega \rightarrow \mathbb{R}, f \text{ meßbar}\}$  die Menge der meßbaren numerischen Funktionen und  $M^+ := \{f \mid f \in M, f \geq 0\}$  die nicht-negativen Funktionen aus  $M$ .

#### Definition 3.1 (Treppenfunktion)

Ist  $(\Omega, \mathcal{F}, \mu)$  ein Maßraum und  $f : \Omega \rightarrow \mathbb{R}$  eine  $\mathcal{F}$ - $\mathcal{B}$ -meßbare Funktion mit endlichem Bild  $f(\Omega) = \{y_1, \dots, y_n\}$ , so läßt sich  $f$  für ein  $n \in \mathbb{N}$  und  $A_i \in \mathcal{F}, i = 1, \dots, n$ , darstellen als

$$f = y_1 I_{A_1} + \dots + y_n I_{A_n} = \sum_{i=1}^n y_i I_{A_i}$$

und heißt Treppenfunktion. Desweiteren sei  $T := \{f \mid f : \Omega \rightarrow \mathbb{R}, f \text{ Treppenfunktion}\}$  und  $T^+ := \{f \mid f \in T, f \geq 0\}$  die Menge der (nicht-negativen) Treppenfunktionen.

*Bemerkung.*  $f \in T^+$  läßt sich darstellen als

$$f = \sum_{i=1}^n y_i I_{A_i} \quad y_i \geq 0 \quad \forall i = 1, \dots, n$$

#### Definition 3.2 (Lebesgue-Integral für Treppenfunktionen)

Das Integral für  $f \in T^+$

$$\int f \, d\mu := y_1 \mu(A_1) + \dots + y_n \mu(A_n)$$

heißt Lebesgue-Integral von  $f$  nach  $\mu$ .

*Bemerkung.* Besitzt  $f \in T^+$  eine weitere Darstellung der Gestalt

$$f = \sum_{i=1}^m z_i I_{B_i} \quad \text{mit } B_i \in \mathcal{F}, z_i \geq 0 \quad \forall i = 1, \dots, m$$

so gilt:

$$\sum_{i=1}^n y_i \mu(A_i) = \sum_{i=1}^m z_i \mu(B_i)$$

(Übergang auf  $C_{ij} = A_i \cap B_j$ )




Abbildung 3.1: Zwei Treppenfunktionen stellen dieselbe Funktion dar.

Daher ist  $\int f d\mu$  wohldefiniert.

*Bemerkung.* Die Indikatorfunktion  $I_A$  ist die einfachste Treppenfunktion mit Integral

$$\int I_A d\mu = \mu(A)$$

**Satz 3.3 (Eigenschaften des Integrals)** i) Linearität: Für  $f, g \in T^+$  und  $\alpha, \beta \geq 0$  gilt

$$\int (\alpha f + \beta g) d\mu = \alpha \int f d\mu + \beta \int g d\mu.$$

ii) Monotonie: Sind  $f, g \in T^+$  und  $f \leq g$ , so folgt

$$\int f d\mu \leq \int g d\mu.$$

*Beweis.*

$$\begin{aligned} \text{i) } \int (\alpha f + \beta g) d\mu &= \int \alpha \underbrace{\sum_{i=1}^n y_i I_{A_i}}_f + \beta \underbrace{\sum_{j=1}^m z_j I_{B_j}}_g d\mu \\ &= \alpha \sum y_i \mu(A_i) + \beta \sum z_j \mu(B_j) \\ &= \alpha \int f d\mu + \beta \int g d\mu \end{aligned}$$



$$\begin{aligned}
\text{ii) } f &= \sum_{i=1}^n y_i I_{A_i} \quad g = \sum_{i=1}^n z_i I_{A_i} \text{ o.B.d.A.} \\
f \leq g &\Leftrightarrow f(x) \leq g(x) \quad \forall x \in \Omega \\
&\Leftrightarrow y_i \leq z_i \quad \forall i = 1, \dots, n \\
&\Rightarrow \sum_{i=1}^n y_i \mu(A_i) \leq \sum_{i=1}^n z_i \mu(A_i) \\
&\Leftrightarrow \int f \, d\mu \leq \int g \, d\mu
\end{aligned}$$

□

**Beispiel 3.1**

$$\begin{aligned}
f &\equiv 0 \equiv 0 \cdot I_{\mathbb{R}} \\
\int f \, d\lambda &= \int 0 \cdot I_{\mathbb{R}} \, d\lambda = 0 \cdot \lambda(\mathbb{R}) = \underbrace{0 \cdot \infty}_{\text{Konvention}} = 0
\end{aligned}$$

## 3.2 Integral nicht-negativer Funktionen

**Lemma 3.4**

Ist  $f \in M^+$  eine nicht-negative Funktion, so gibt es eine Folge  $(f_n)_{n \in \mathbb{N}} \in T^+$  von nicht-negativen Treppenfunktionen, so daß  $f_n \uparrow f$ .

*Beweis.*

Eine solche Funktion ist z. B.  $f_n : \Omega \rightarrow \mathbb{R}, n \in \mathbb{N}$  mit

$$f_n(x) := \frac{\lfloor 2^n f(x) \rfloor}{2^n} \uparrow f(x) \quad \forall x \in \Omega$$

Etwa  $f = \sin : [0, \pi] \rightarrow \mathbb{R}$  (siehe Abbildung 3.2).

□

**Definition 3.5 (Lebesgue-Integral für nicht-negative Funktionen)**

Sei  $f \in M^+$  und  $(f_n)_{n \in \mathbb{N}} \in T^+$  mit  $f_n \uparrow f$ . Das Lebesgue-Integral von  $f$  nach  $\mu$  ist dann

$$\int f \, d\mu := \lim_{n \rightarrow \infty} \int f_n \, d\mu$$

**Lemma 3.6**

Sei  $f \in M^+$  und  $g \in T^+$  mit  $g \leq f$ . Dann gilt für eine Folge  $(f_n)_{n \in \mathbb{N}} \in T^+$ :

$$f_n \uparrow f \Rightarrow \lim_{n \rightarrow \infty} \int f_n \, d\mu \geq \int g \, d\mu.$$

*Beweis.*

o.B.d.A.  $g = I_A, A \in \mathcal{F}$  (wegen der Linearität)

$$\begin{aligned}
&\Rightarrow f(x) \geq 1 \quad \forall x \in A \\
&\Rightarrow \forall \epsilon > 0 : A_n := \{x \in A \mid f_n(x) \geq 1 - \epsilon\} \uparrow A \text{ wegen } f_n \uparrow f \text{ von unten!} \\
&\Rightarrow f_n \geq (1 - \epsilon) I_{A_n} \quad \forall n \in \mathbb{N}
\end{aligned}$$




Abbildung 3.2: Approximation von  $f = \sin \in M^+$  durch  $f_n \in T^+$  für  $n = 2, 3, 4$ .

Und damit

$$\begin{aligned} \int f_n d\mu &\stackrel{\text{Monotonie}}{\geq} \int (1 - \epsilon) I_{A_n} d\mu \stackrel{\text{Linearität Def.}}{=} (1 - \epsilon) \mu(A_n) \stackrel{\text{Stetigkeit von } \mu}{\uparrow} (1 - \epsilon) \mu(A) \\ &= (1 - \epsilon) \int g d\mu \end{aligned}$$

Für  $\epsilon \rightarrow 0$  folgt die Behauptung. □

### Lemma 3.7

Sind  $(f_n)_{n \in \mathbb{N}}$  und  $(g_n)_{n \in \mathbb{N}}$  zwei monoton wachsende Folgen von Funktionen aus  $T^+$  mit

$$\lim_{n \rightarrow \infty} f_n = \lim_{n \rightarrow \infty} g_n,$$

so gilt:

$$\lim_{n \rightarrow \infty} \int f_n d\mu = \lim_{n \rightarrow \infty} \int g_n d\mu$$

*Beweis.*

Laut Voraussetzung  $\underbrace{g_k}_{\in T^+} \leq \lim_{n \rightarrow \infty} f_n \quad \forall k \in \mathbb{N}$  (Monotonie)

Also  $\int g_k d\mu \stackrel{\text{Lemma 3.6}}{\leq} \lim_{n \rightarrow \infty} \int f_n d\mu \quad \forall k \in \mathbb{N}$

und somit  $\lim_{k \rightarrow \infty} \int g_k d\mu \leq \lim_{n \rightarrow \infty} \int f_n d\mu$ .

Umgekehrt:  $f_k \leq \lim_{n \rightarrow \infty} g_n$  und also  $\lim_{k \rightarrow \infty} \int f_k d\mu \leq \lim_{n \rightarrow \infty} \int g_n d\mu$

Zusammen:  $\lim_{n \rightarrow \infty} \int f_n d\mu = \lim_{n \rightarrow \infty} \int g_n d\mu$  □

### Satz 3.8 (Eigenschaften des Integrals)

Für  $f, g \in M^+$  und  $\alpha, \beta \geq 0$  gilt:

i) Linearität:

$$\int (\alpha f + \beta g) d\mu = \alpha \int f d\mu + \beta \int g d\mu$$

ii) Monotonie: Ist  $f \leq g$  so folgt

$$\int f d\mu \leq \int g d\mu$$

*Beweis.*

Sind  $\underbrace{f_n}_{\in T^+} \uparrow f, \underbrace{g_n}_{\in T^+} \uparrow g$ , so auch  $\alpha f_n + \beta g_n \uparrow \alpha f + \beta g$

i) folgt somit aus Satz 3.3 (i) für  $f_n, g_n$

ii)  $f_n \leq \max(f_n, g_n) \uparrow g$  für  $f \leq g$   
und aus Satz 3.3 (ii) folgt ii) □

### Satz 3.9 (Satz von der monotonen Konvergenz, Satz von Beppo Levi)

Für eine monoton wachsende Folge  $(f_n)_{n \in \mathbb{N}}$  von Funktionen aus  $M^+$  gilt:

$$\lim_{n \rightarrow \infty} \int f_n d\mu = \int \lim_{n \rightarrow \infty} f_n d\mu$$

*Beweis.*

" $\leq$ ":  $f := \lim_{n \rightarrow \infty} f_n \stackrel{\text{Monotonie}}{=} \sup_{n \rightarrow \infty} f_n$  (meßbar)  $f_n \leq f \quad \forall n \in \mathbb{N}$  (Monotonie)

$\Rightarrow \int f_n d\mu \leq \int f d\mu$  (Monotonie des Integrals)

und somit  $\lim_{n \rightarrow \infty} \int f_n d\mu \leq \int f d\mu$

" $\geq$ ": Sei  $(e_n)_{n \in \mathbb{N}} \in T^+; e_n \uparrow f$

$A_n := \{\omega \in \Omega \mid c f_n(\omega) \geq e_k(\omega)\} \uparrow \Omega, \quad c > 1$  beliebig ( $c = 1$  würde bei  $f \in T^+, e_k = f \quad \forall k \in \mathbb{N}$  und  $f_n \leq f = e_k$  nicht reichen),  $k \in \mathbb{N}$  fest

$$cf_n(\omega) \geq e_k(\omega) \cdot I_{A_n}(\omega) \uparrow e_k(\omega)$$

$\Rightarrow$

$$\int e_k d\mu = \lim_{n \rightarrow \infty} \int e_k I_{A_n} d\mu \leq c \lim_{n \rightarrow \infty} \int f_n d\mu$$

Weil  $c$  beliebig ist folgt auch

$$\int e_k d\mu \leq \lim_{n \rightarrow \infty} \int f_n d\mu \quad \forall k \in \mathbb{N}$$

(denn sonst wäre ja  $\int e_k d\mu > \lim_n \int f_n d\mu$  und somit gäbe es auch ein  $c > 1$  mit  $\int e_k d\mu > c \lim_n \int f_n d\mu$  was ein Widerspruch ist) und

$$\int f d\mu = \lim_{k \rightarrow \infty} \int e_k d\mu \leq \lim_{n \rightarrow \infty} \int f_n d\mu.$$

□

**Beppo Levi (14. Mai 1875 bis 28. August 1961).** Italienischer Mathematiker. Studium in Turin, Professor in Piacenza, Cagliari, Parma und Bologna. Nachdem er seiner jüdischen Herkunft wegen Italien 1939 verlassen mußte, baute er an der Universität Rosario in Argentinien ein mathematisches Institut auf.

[http://de.wikipedia.org/wiki/Beppo\\_Levi](http://de.wikipedia.org/wiki/Beppo_Levi)

### Korollar 3.10 (zu Satz 3.9)

Für jede Folge  $(f_n)_{n \in \mathbb{N}}$  von Funktionen aus  $M^+$  gilt:

$$\int \sum_{i=1}^{\infty} f_i d\mu = \sum_{i=1}^{\infty} \int f_i d\mu.$$

*Beweis.*

Wende Satz 3.9 auf  $g_n = \sum_{i=1}^n f_i$  (Partialsommen) an. □

### Satz 3.11 (Lemma von Fatou)

Für jede Folge  $(f_n)_{n \in \mathbb{N}} \in M^+$  gilt:

$$\liminf_{n \rightarrow \infty} \int f_n d\mu \geq \int \liminf_{n \rightarrow \infty} f_n d\mu.$$

*Beweis.*

$$f := \liminf_{n \rightarrow \infty} f_n \quad \text{und} \quad g_n := \inf_{k \geq n} f_k, \quad n \in \mathbb{N}.$$

$$\Rightarrow g_n \uparrow f \quad \text{und} \quad \lim_{n \rightarrow \infty} \int g_n d\mu \stackrel{\text{Satz 3.9}}{=} \int f d\mu.$$

Weiterhin:  $g_n \leq f_k \quad \forall k \geq n \quad (f_n \in M^+)$

$$\Rightarrow \int g_n d\mu \leq \inf_{k \geq n} \int f_k d\mu$$

$$\Rightarrow \underbrace{\lim_{n \rightarrow \infty} \int g_n d\mu}_{= \int f d\mu} \leq \underbrace{\lim_{n \rightarrow \infty} \inf_{k \geq n} \int f_k d\mu}_{= \liminf_{n \rightarrow \infty} \int f_n d\mu}$$

□

**Pierre Joseph Louis Fatou (28. Februar 1878 bis 10. August 1929).** Nach dem Studium 1898–1900 Arbeit im Pariser Observatorium, 1907 Promotion in Mathematik; lieferte Grundlagen der Chaostheorie.

[http://de.wikipedia.org/wiki/Pierre\\_Fatou](http://de.wikipedia.org/wiki/Pierre_Fatou)

### 3.3 Integrierbare Funktionen

Jetzt allgemein  $f : \Omega \rightarrow \bar{\mathbb{R}}$  meßbar.

$$f = \underbrace{f^+}_{\in M^+} - \underbrace{f^-}_{\in M^+}$$

#### Definition 3.12 (quasi-integrierbar, Lebesgue-Integral)

Sei  $f : \Omega \rightarrow \bar{\mathbb{R}}$  eine meßbare numerische Funktion. Die Funktion heißt ( $\mu$ -) quasi-integrierbar, falls  $\int f^+ d\mu < \infty$  oder  $\int f^- d\mu < \infty$ . Ist  $f$  ( $\mu$ -) quasi-integrierbar, so ist durch

$$\int f d\mu := \int f^+ d\mu - \int f^- d\mu$$

das Lebesgue-Integral von  $f$  definiert. Gilt  $\int f^+ d\mu < \infty$  und  $\int f^- d\mu < \infty$ , so heißt  $f$  ( $\mu$ -)integrierbar.

*Bemerkung.*  $|f| = f^+ + f^-$   
 $f$  integrierbar  $\Leftrightarrow |f|$  integrierbar.

*Bemerkung.*

$$\int_A f d\mu := \int f I_A d\mu$$

#### Satz 3.13

Sind  $f, g : \Omega \rightarrow \bar{\mathbb{R}}$  integrierbare numerische Funktionen und  $\alpha, \beta \in \mathbb{R}$ , so gilt

i) Linearität:  $\alpha f + \beta g$  ist integrierbar und

$$\int (\alpha f + \beta g) d\mu = \alpha \int f d\mu + \beta \int g d\mu$$

ii) Monotonie: Ist  $f \leq g$ , so folgt

$$\int f d\mu \leq \int g d\mu$$

iii) Für jedes  $A \in \mathcal{F}$  gilt

$$\int f d\mu = \int_A f d\mu + \int_{\bar{A}} f d\mu$$

*Beweis.*

i), ii)  $\checkmark$

iii)  $f = fI_A + fI_{\bar{A}}$   $\checkmark$

□

**Satz 3.14 (Satz von der dominierten Konvergenz)**

Seien  $f, g$  sowie  $(f_n), (g_n)$  meßbare numerische Funktionen auf einem Maßraum  $(\Omega, \mathcal{F}, \mu)$  mit  $f_n \rightarrow f, g_n \rightarrow g$  (punktweise) und  $|f_n| \leq g_n \quad \forall n \in \mathbb{N}$ . Sind  $g$  und  $g_n \quad \forall n \in \mathbb{N}$  integrierbar und gilt

$$\lim_{n \rightarrow \infty} \int g_n d\mu = \int g d\mu,$$

so sind  $f$  und  $f_n \quad \forall n \in \mathbb{N}$  integrierbar und es gilt

$$\lim_{n \rightarrow \infty} \int f_n d\mu = \int f d\mu.$$

*Beweis.*

$|f_n| \leq g_n$  und  $\int g_n^+ d\mu < \infty$  und  $\int g^- d\mu < \infty$

$\Rightarrow \int f_n^+ d\mu < \infty$  und  $\int f^- d\mu < \infty \Leftrightarrow f_n$  integrierbar  $\forall n \in \mathbb{N}$ .

$|f| \leq g \Rightarrow f$  integrierbar.

Betrachte die Funktionen  $g_n + f_n \geq 0$  und  $g_n - f_n \geq 0$

$$\begin{aligned} \int g d\mu + \liminf_{n \rightarrow \infty} \int f_n d\mu &= \liminf_{n \rightarrow \infty} \int (g_n + f_n) d\mu \\ &\stackrel{\text{Lemma v- Fatou}}{\geq} \int \liminf_{n \rightarrow \infty} (g_n + f_n) d\mu \\ &= \int g + f d\mu \\ &= \int g d\mu + \int f d\mu \end{aligned}$$

Durch Subtraktion von  $\int g d\mu$  auf beiden Seiten erhalten wir

$$\liminf_{n \rightarrow \infty} \int f_n d\mu \geq \int f d\mu$$

Mit  $g_n - f_n \geq 0$  gilt

$$\begin{aligned}
 \int g \, d\mu + \liminf_{n \rightarrow \infty} \int -f_n \, d\mu &\geq \int g \, d\mu - \int f \, d\mu \\
 \Leftrightarrow \liminf_{n \rightarrow \infty} \int -f_n \, d\mu &\geq - \int f \, d\mu \\
 \Leftrightarrow \lim_{n \rightarrow \infty} \inf_{k \geq n} \int -f_k \, d\mu &\geq - \int f \, d\mu \\
 \Leftrightarrow \lim_{n \rightarrow \infty} - \sup_{k \geq n} \int f_k \, d\mu &\geq - \int f \, d\mu \\
 \Leftrightarrow - \lim_{n \rightarrow \infty} \sup_{k \geq n} \int f_k \, d\mu &\geq - \int f \, d\mu \\
 \Leftrightarrow - \limsup_{n \rightarrow \infty} \int f_n \, d\mu &\geq - \int f \, d\mu \\
 \Leftrightarrow \limsup_{n \rightarrow \infty} \int f_n \, d\mu &\leq \int f \, d\mu
 \end{aligned}$$

zusammen also

$$\begin{aligned}
 \int f \, d\mu &\leq \liminf_{n \rightarrow \infty} \int f_n \, d\mu \leq \limsup_{n \rightarrow \infty} \int f_n \, d\mu \leq \int f \, d\mu \\
 \Leftrightarrow \lim_{n \rightarrow \infty} \int f_n \, d\mu &= \int f \, d\mu
 \end{aligned}$$

□

### Satz 3.15

Für  $f \in M^+$  gilt

$$\int f \, d\mu = 0 \Leftrightarrow \underbrace{\{\omega \in \Omega \mid f(\omega) > 0\}}_{=: \text{Träger von } f} \text{ ist } \mu\text{-Nullmenge}$$

*Beweis.*

$$A := \{\omega \in \Omega \mid f(\omega) > 0\}$$

$$A_n := \{\omega \in \Omega \mid f(\omega) > \frac{1}{n}\} \quad \forall n \in \mathbb{N}$$

$$A_n \uparrow A$$

$$\text{''}\Rightarrow\text{''}: \int f \, d\mu = 0$$

$$\frac{1}{n} I_{A_n} \leq f \quad \forall n \in \mathbb{N}$$

$$0 \leq \underbrace{\frac{1}{n} \mu(A_n)}_{\mu \text{ ist Maß}} = \underbrace{\int \frac{1}{n} I_{A_n} \, d\mu}_{\text{Integral über Indikatorfkt.}} \stackrel{\text{Monotonie}}{\leq} \int f \, d\mu \stackrel{\text{nach Vor.}}{=} 0$$

$\Rightarrow \mu(A_n) = 0 \quad \forall n \in \mathbb{N}$  und aus  $A_n \uparrow A$  folgt  $\mu(A_n) \uparrow \mu(A) = 0$  (Stetigkeit von unten)

$$\begin{aligned} \text{''}\Leftarrow\text{''}: \quad & \mu(A) = 0 \\ & f \leq \infty \cdot I_A \\ & 0 \leq \int f d\mu \leq \int \infty \cdot I_A d\mu = \infty \cdot \mu(A) = 0 \end{aligned}$$

□

**Definition 3.16 ( $\mu$ -fast-überall)**

Die Eigenschaft  $E$  sei für die Elemente  $\omega \in \Omega$  eines Maßraumes  $(\Omega, \mathcal{F}, \mu)$  sinnvoll.  $E$  gilt  $(\mu)$ -fast-überall, wenn  $E$  für alle  $\omega \notin N \subset \Omega$  gilt und  $N$  eine  $\mu$ -Nullmenge ist.

*Bemerkung.* zu Satz 3.15:  $f \in M^+$

$$\int f d\mu = 0 \Leftrightarrow f = 0 \quad \mu\text{-f.ü.}$$

**Satz 3.17 (Riemann & Lebesgue-Integral)**

Sei  $f : \mathbb{R} \rightarrow \mathbb{R}$  meßbar und auf  $[a, b] \subset \mathbb{R}$  Riemann-integrierbar (Ober- und Untersumme konvergieren gegen Integralwert). Dann ist  $f$  Lebesgue-integrierbar und es gilt

$$\underbrace{\int_{[a,b]} f d\lambda}_{\text{Lebesgue}} = \underbrace{\int_a^b f(x) dx}_{\text{Riemann}}$$

*Beweis.*

Satz 2.17 Meintrup and Schäffler (2005)

□

**Berhard Riemann (17. September 1826 bis 20. Juli 1866).** Studium in Göttingen (u.a. bei Gauß) und Berlin, während der Revolution im März 1848 im Studentenkorps in Berlin, Promotion 1851 und Habilitation 1854 in Göttingen. Seit 1857 außerordentlicher Professor in Göttingen.

[http://de.wikipedia.org/wiki/Bernhard\\_Riemann](http://de.wikipedia.org/wiki/Bernhard_Riemann)

*Bemerkung.* Etwas allgemeiner gilt auch

$$\int_I f d\lambda = \int_I f(x) dx, \quad I \subset \mathbb{R}$$

siehe Satz 2.18 Meintrup and Schäffler (2005)

*Bemerkung.* Es gibt Funktionen  $f$ , die Lebesgue-integrierbar aber nicht Riemann-integrierbar sind und vice versa.

**Definition 3.18 (Produktmaßraum)**

Seien  $(\Omega_1, \mathcal{F}_1, \mu)$  und  $(\Omega_2, \mathcal{F}_2, \nu)$  zwei Maßräume. Dann heißt der Maßraum

$$(\Omega_1 \times \Omega_2, \mathcal{F}_1 \otimes \mathcal{F}_2, \mu \otimes \nu)$$



mit Basismenge

$$\Omega_1 \times \Omega_2,$$

Produkt- $\sigma$ -Algebra

$$\mathcal{F}_1 \otimes \mathcal{F}_2 = \sigma(\{A \times B \mid A \in \mathcal{F}_1, B \in \mathcal{F}_2\})$$

(wobei  $\{A \times B \mid A \in \mathcal{F}_1, B \in \mathcal{F}_2\}$  ein durchschnittsstabiler Erzeuger von  $\mathcal{F}_1 \otimes \mathcal{F}_2$  ist) und Produktmaß

$$\mu \otimes \nu(A \times B) = \mu(A) \cdot \nu(B) \quad \forall A \in \mathcal{F}_1, B \in \mathcal{F}_2$$

Produktmaßraum.

**Satz 3.19 (Satz von Fubini)**

Seien  $(\Omega_1, \mathcal{F}_1, \mu)$  und  $(\Omega_2, \mathcal{F}_2, \nu)$  zwei Maßräume mit  $\sigma$ -endlichen Maßen  $\mu$  und  $\nu$ . Ist  $f : \Omega_1 \times \Omega_2 \rightarrow \mathbb{R}$  eine nicht-negative,  $(\mathcal{F}_1 \otimes \mathcal{F}_2)$ - $\mathcal{B}$ -meßbare Funktion oder eine  $(\mu \otimes \nu)$ -integrierbare Funktion, so gilt

$$\begin{aligned} \int f d(\mu \otimes \nu) &= \int \left( \int f(\omega_1, \omega_2) d\mu(\omega_1) \right) d\nu(\omega_2) \\ &= \int \left( \int f(\omega_1, \omega_2) d\nu(\omega_2) \right) d\mu(\omega_1) \end{aligned}$$

(Vertauschung der Reihenfolge der Integration).

*Beweis.*

Satz 2.24 Meintrup and Schäffler (2005) □

**Guido Fubini (19. Januar 1879 bis 6. Juni 1943).** Studium und Promotion in Pisa, 1908 Professor in Turin. Emigrierte 1939 in die U.S.A., lehrte bis zu seinem Tod in New York.

<http://www-history.mcs.st-andrews.ac.uk/Biographies/Fubini.html>

*Bemerkung.* Die Definition 3.18 und der Satz von Fubini erstreckt sich in gleicher Weise auf Produktmaßräume

$$\left( \prod_{i=1}^n \Omega_i, \bigotimes_{i=1}^n \mathcal{F}_i, \bigotimes_{i=1}^n \mu_i \right)$$

basierend auf den Maßräumen  $(\Omega_i, \mathcal{F}_i, \mu_i), i = 1, \dots, n$ .

## 3.4 Ungleichungen

$f : \Omega \rightarrow \mathbb{R}$   $\mathcal{F}$ - $\mathcal{B}$ -meßbar auf  $(\Omega, \mathcal{F}, \mu)$

$$\|f\|_p := \left( \int |f|^p d\mu \right)^{1/p} \in [0, \infty[ \quad \text{„}p\text{-Norm“}$$

**Satz 3.20 (Ungleichung von Hölder)**

Es sei  $1 < p, q < \infty$  mit  $\frac{1}{p} + \frac{1}{q} = 1$ . Dann gilt für zwei meßbare Funktionen  $f, g : \Omega \rightarrow \mathbb{R}$ :

$$\|f \cdot g\|_1 \leq \|f\|_p \cdot \|g\|_q.$$

*Beweis.*

- $\|f\|_p = 0$  oder  $\|g\|_q = 0 \Rightarrow f \cdot g = 0$   $\mu$ -f.ü.  $\checkmark$
- $(\|f\|_p = \infty$  oder  $\|g\|_q = \infty)$  und  $\|f\|_p \|g\|_q > 0$   $\checkmark$
- $0 < \|f\|_p, \|g\|_q < \infty$ :

Sei  $x, y \geq 0$ ,  $\alpha, \beta \geq 0$  mit  $\alpha + \beta = 1$ . Dann gilt

$$x^\alpha y^\beta \leq \alpha x + \beta y \quad \text{denn}$$

$$\ln(x^\alpha y^\beta) = \alpha \ln x + \beta \ln y \stackrel{\text{Konkavität}}{\leq} \ln(\alpha x + \beta y)$$

$$\Rightarrow x := \frac{|f|^p}{\|f\|_p^p}; \quad y := \frac{|g|^q}{\|g\|_q^q}; \quad \alpha = \frac{1}{p}, \quad \beta = \frac{1}{q}$$

$$\frac{|f| |g|}{\|f\|_p \|g\|_q} \leq \frac{1}{p} \frac{|f|^p}{\|f\|_p^p} + \frac{1}{q} \frac{|g|^q}{\|g\|_q^q}$$

$$\Rightarrow \int \frac{|f| |g|}{\|f\|_p \|g\|_q} d\mu \leq \frac{1}{p} \cdot \frac{1}{\|f\|_p^p} \underbrace{\int |f|^p d\mu}_{=\|f\|_p^p} + \frac{1}{q} \cdot \frac{1}{\|g\|_q^q} \underbrace{\int |g|^q d\mu}_{=\|g\|_q^q}$$

$$\frac{\int |f| |g| d\mu}{\|f\|_p \|g\|_q} \leq \frac{1}{p} + \frac{1}{q} \stackrel{\text{n.V.}}{=} 1$$

$$\Leftrightarrow \int |fg| d\mu \leq \|f\|_p \|g\|_q$$

$$\Leftrightarrow \|fg\|_1 \leq \|f\|_p \|g\|_q$$

□

**Otto Ludwig Hölder (22. Dezember 1859 bis 29. August 1937).** 1882 Promotion in Tübingen, seit 1890 Professor in Tübingen.

[http://de.wikipedia.org/wiki/Otto\\_H%C3%B6lder](http://de.wikipedia.org/wiki/Otto_H%C3%B6lder)

**Satz 3.21 (Ungleichung von Minkowski)**

Sind  $f, g : \Omega \rightarrow \mathbb{R}$  meßbar und  $p \geq 1$ , so gilt

$$\|f + g\|_p \leq \|f\|_p + \|g\|_p \quad \text{Dreiecksungleichung}$$

*Beweis.*

$$p = 1 \text{ oder } \|f\|_p = \infty \text{ oder } \|g\|_p = \infty \text{ oder } \|f + g\|_p = 0 \quad \checkmark$$

$$p > 1, \|f\|_p < \infty, \|g\|_p < \infty \text{ und } \|f + g\|_p > 0$$

$$q := (1 - \frac{1}{p})^{-1} \Rightarrow \frac{1}{p} + \frac{1}{q} = 1$$

Damit

$$\begin{aligned} \|f + g\|_p^p &= \int |f + g|^p d\mu \\ &= \int |f + g| |f + g|^{p-1} d\mu \\ &\stackrel{\text{Dreiecksungleichung}}{\leq} \int (|f| + |g|) |f + g|^{p-1} d\mu \\ &= \int |f| |f + g|^{p-1} d\mu + \int |g| |f + g|^{p-1} d\mu \\ &\stackrel{\text{zweimal Hölder}}{\leq} (\|f\|_p + \|g\|_p) \|f + g\|_q^{p-1} \end{aligned}$$

Mit  $(p-1)q = p$  gilt

$$\|f + g\|_q^{p-1} = \left( \int |f + g|^p d\mu \right)^{\frac{1}{q}} = \|f + g\|_p^{\frac{p}{q}}$$

und somit zusammen

$$\begin{aligned} \|f + g\|_p^p &\leq (\|f\|_p + \|g\|_p) \|f + g\|_p^{\frac{p}{q}} \\ \|f + g\|_p^p \|f + g\|_p^{-\frac{p}{q}} &\leq (\|f\|_p + \|g\|_p) \|f + g\|_p^{\frac{p}{q}} \|f + g\|_p^{-\frac{p}{q}} \\ \|f + g\|_p &\leq \|f\|_p + \|g\|_p \end{aligned}$$

(denn  $p - p \cdot q^{-1} = p - p(1 - \frac{1}{p}) = 1$ ) □

**Hermann Minkowski (22. Juni 1864 bis 12. Januar 1909).** Studium in Königsberg zusammen mit Hurwitz und Hilbert. Lehrtätigkeit in Bonn, Königsberg und Zürich (dort u.a. Lehrer von Einstein), 1902 Ordinarius in Göttingen.

[http://de.wikipedia.org/wiki/Hermann\\_Minkowski](http://de.wikipedia.org/wiki/Hermann_Minkowski)

### Definition 3.22 ( $\mathcal{L}^p$ -Raum)

Für  $p \geq 1$  sei

$$\mathcal{L}^p := \mathcal{L}^p(\Omega, \mathcal{F}, \mu) := \{f | f : \Omega \rightarrow \mathbb{R}, f \text{ meßbar}, \|f\|_p < \infty\}$$

*Bemerkung.*  $\mathcal{L}^1 = \mathcal{L}$  ist die Menge der integrierbaren Funktionen.  $\mathcal{L}^p$  ist die Menge der Funktionen, für die  $|f|^p$  integrierbar ist.

*Bemerkung.*  $(\mathcal{L}^p, \|\cdot\|_p)$  ist halbnormierter, vollständiger Raum.

$N := \{f \in \mathcal{L}^p | \|f\|_p = 0 \Rightarrow f = 0 \text{ f.s.}\}$

$L^p := \mathcal{L}^p / N$  Quotientenvektorraum

$(L^p, \|\cdot\|_p)$  Banach-Raum

$(L^2, \|\cdot\|_2)$  mit Skalarprodukt  $\langle f, g \rangle = \int f g d\mu$  ist Hilbertraum.

**Satz 3.23**

Ist  $\mu(\Omega) < \infty$  und  $q > p \geq 1$ , so ist  $L^q \subset L^p$  und es gibt  $c \geq 0$ , so daß

$$\|f\|_p \leq c \|f\|_q \quad \forall f \in L^q.$$

*Beweis.*

$r := \frac{q}{p}$   $s := (1 - \frac{1}{r})^{-1}$ , so daß  $(\frac{1}{r} + \frac{1}{s}) = 1$ .

$$\begin{aligned} \|f\|_p^p &= \int |f|^p d\mu = \| |f|^p \cdot I_\Omega \|_1 \\ &\stackrel{\text{Hölder}}{\leq} \int |f|^{pr} d\mu \int |I_\Omega|^s d\mu^{\frac{1}{s}} \\ &= \|f\|_q^p \cdot \underbrace{\mu(\Omega)^{\frac{1}{s}}}_{< \infty} < \infty \end{aligned}$$

und die  $p$ -te Wurzel liefert die Behauptung. □

**Definition 3.24 (Konvergenz in  $L^p$ )**

Eine Folge  $(f_n)_{n \in \mathbb{N}} \in L^p$  heißt in  $L^p$  konvergent, wenn es ein  $f \in L^p$  gibt, so daß

$$\|f_n - f\|_p \rightarrow 0 \quad \text{für } n \rightarrow \infty$$

Kurz:  $f_n \xrightarrow{L^p} f$ .

**Definition 3.25 (Konvergenz  $\mu$ -f.ü.)**

Sei  $(\Omega, \mathcal{F}, \mu)$  ein Maßraum. Eine Folge  $f_n : \Omega \rightarrow \mathbb{R}$  meßbarer Funktionen heißt  $(\mu)$ -fast überall konvergent, wenn es eine meßbare Funktion  $f : \Omega \rightarrow \mathbb{R}$  und eine  $\mu$ -Nullmenge  $N$  gibt, so daß

$$f_n(x) \rightarrow f(x) \quad \forall x \in \bar{N}.$$

Kurz:  $f_n \rightarrow f$   $\mu$ -f.ü.

**Korollar 3.26 (zu Satz 3.23)**

Ist  $q > p \geq 1$ ,  $f, f_n \in L^q$ ,  $n \in \mathbb{N}$ , so gilt:

$$f_n \xrightarrow{L^q} f \Rightarrow f_n \xrightarrow{L^p} f$$

*Beweis.*

$$\|f_n - f\|_p \leq c \cdot \|f_n - f\|_q \rightarrow 0$$

□

**Satz 3.27**

Seien  $p \geq 1$  und  $f, f_n \in L^p$ ,  $n \in \mathbb{N}$ , so daß  $f_n \rightarrow f$  f. ü. Dann gilt

$$\|f_n\|_p \rightarrow \|f\|_p \Leftrightarrow f_n \xrightarrow{L^p} f.$$

*Beweis.*

$$\text{''}\Leftarrow\text{''}: \left| \|f_n\|_p - \|f\|_p \right| \stackrel{\Delta\text{-Ungleichung für Normen}}{\leq} \|f_n - f\|_p \rightarrow 0$$

$$\text{''}\Rightarrow\text{''}: g_n := 2^p(|f_n|^p + |f|^p), \quad n \in \mathbb{N}$$

$$g := 2^{p+1}|f|^p$$

$$g_n \rightarrow g \text{ f. ü. und } \int g_n d\mu \rightarrow \int g d\mu.$$

wegen  $x, y \in \mathbb{R}$

$$|x - y|^p \leq 2^p(|x|^p + |y|^p)$$

folgt

$$\underbrace{|f_n - f|^p}_{\rightarrow 0 \text{ f. ü.}} \leq |g_n|$$

$\rightarrow 0$  f. ü.

somit (Satz 3.14 von der dominierten Konvergenz)

$$\lim_{n \rightarrow \infty} \int |f_n - f|^p d\mu = \|f_n - f\|_p^p \rightarrow 0$$

$$\Leftrightarrow \|f_n - f\|_p \rightarrow 0$$

□

## 3.5 Maße und Dichten

### Lemma 3.28

Für jedes  $f \in M^+$  ist

$$f \odot \mu : \mathcal{F} \rightarrow \bar{\mathbb{R}}$$

$$(f \odot \mu)(A) := \int_A f d\mu = \int f I_A d\mu$$

ein Maß. Sei  $\nu = f \odot \mu$ , so gilt für alle  $g \in M^+$

$$\int g d\nu = \int (gf) d\mu.$$

*Beweis.*

M1)  $\checkmark$

M2)  $\checkmark$

M3) Sei  $(A_n)_{n \in \mathbb{N}} \in \mathcal{F}$  mit  $\dot{\bigcup}_{n=1}^{\infty} A_n = A$

$$\text{Dann ist } f I_A = \sum_{n=1}^{\infty} f I_{A_n}$$

$$(f \odot \mu)(A) = \int f I_A d\mu$$

$$\begin{aligned}
&= \int \left( \sum_{n=1}^{\infty} f I_{A_n} \right) d\mu \\
&= \sum_{n=1}^{\infty} \int f I_{A_n} d\mu \\
&= \sum_{n=1}^{\infty} (f \odot \mu)(A_n)
\end{aligned}$$

□

**Definition 3.29 (Maß mit Dichte, Dichte)**

Sei  $(\Omega, \mathcal{F}, \mu)$  Maßraum und  $f \in M^+$ . Dann heißt  $f \odot \mu$  Maß mit der Dichte  $f$  bezüglich  $\mu$ . Die Funktion  $f : \Omega \rightarrow [0, \infty[$  heißt Dichte des Maßes  $f \odot \mu$ .

**Definition 3.30 (absolute Stetigkeit)**

Sind  $\mu$  und  $\nu$  zwei Maße auf  $(\Omega, \mathcal{F})$ , so heißt  $\nu$  absolut stetig bezüglich  $\mu$ , wenn  $\forall A \in \mathcal{F}$  gilt:

$$\mu(A) = 0 \Rightarrow \nu(A) = 0$$

Kurz:  $\nu \ll \mu$ . Man sagt auch:  $\mu$  dominiert  $\nu$ .

**Satz 3.31 (Satz von Radon-Nikodym)**

Ist  $(\Omega, \mathcal{F}, \mu)$  ein Maßraum mit einem  $\sigma$ -endlichen Maß  $\mu$  und  $\nu$  ein weiteres Maß auf  $(\Omega, \mathcal{F})$ , gilt

$$\nu \ll \mu \Leftrightarrow \exists \text{ Dichte } f \in M^+ : \nu = f \odot \mu.$$

Gibt es eine weitere Funktion  $g \in M^+$  mit  $\nu = g \odot \mu$  so gilt  $g = f$   $\mu$ -f.ü.

*Beweis.*

” $\Leftarrow$ ”:  $A \in \mathcal{F}$  Nullmenge  $:\Leftrightarrow$

$$\nu(A) = \int_A f d\mu = \underbrace{\int f I_A d\mu}_{(f \odot \mu)(A)=0} = 0$$

” $\Rightarrow$ ”: Meintrup and Schäffler (2005)

□

**Johann Radon (16. Dezember 1887 bis 25. Mai 1956).** 1910 Promotion in Wien, 1913 Beweis der Existenz von Dichten im  $\mathbb{R}^n$ , Professor in Hamburg, Greifswald, Erlangen und Breslau. Nach dem Krieg Professor und Rektor der Universität Wien.

[http://de.wikipedia.org/wiki/Johann\\_Radon](http://de.wikipedia.org/wiki/Johann_Radon)

**Otton Marcin Nikodym (13. August 1887 bis 4. Mai 1974).** Studium der Mathematik und Physik in Lemberg, Promotion in Warschau, bis 1945 Professor in Warschau. 1930 Beweis des allgemeinen Falls. Nach dem Krieg am Kenyon College in Ohio tätig.

# Kapitel 4

## Wahrscheinlichkeitsmaße

### 4.1 Wahrscheinlichkeit als normiertes Maß

Jetzt  $\Omega$  Ergebnisraum. Potentiell interessante Ereignisse sind Teilmengen von  $\Omega$ , d.h., Elemente einer sinnvollen  $\sigma$ -Algebra  $\mathcal{F}$ , des Ereignisraumes.

#### Beispiel 4.1

$$1 \times \text{Würfeln} \quad \Omega_1 = \{1, \dots, 6\}$$

$$2 \times \text{Würfeln} \quad \Omega_2 = \{(1, 1), (1, 2), \dots, (6, 6)\}$$

⋮

$$n \times \text{Würfeln} \quad \Omega_n = \Omega_1^n$$

$\mathcal{F}_n = \mathcal{P}(\Omega_n)$  da  $\Omega_n$  immer endlich

$$A = \{(1, 1), (1, 2), \dots, (1, 6)\} = \{\text{"1 im ersten Wurf"}\} \subset \Omega_2$$

$$A \in \mathcal{P}(\Omega_2)$$

$$\mathbb{P}(A) = ?$$

#### Beispiel 4.2

Aufrufe einer Webseite pro Stunde

$$\Omega = \mathbb{N}$$

$$A = \{100, 101, \dots, 10.000\} = \{\text{"zwischen 100 und 10.000 Aufrufe"}\} \subset \Omega$$

$$A \in \sigma(\mathbb{N})$$

$$\mathbb{P}(A) = ?$$

#### Beispiel 4.3 (Boule/Boccia)

$$1 \text{ Wurf} \quad \Omega_1 = \mathbb{R}^2$$

$$2 \text{ Würfe} \quad \Omega_2 = \mathbb{R}^2 \times \mathbb{R}^2$$

⋮

$$n \text{ Würfe} \quad \Omega_n = \prod_{i=1}^n \mathbb{R}^2$$

$$\mathcal{F}_n = (\mathcal{B}^2)^n$$

$$A = \{(x, y) | x^2 + y^2 \leq r^2\} = \{\text{1. Wurf nicht mehr als } r \text{ cm von } (0, 0) \text{ entfernt}\} \subset \Omega_1$$

$$A \in \mathcal{B}^2$$

$$\mathbb{P}(A) = ?$$

**Definition 4.1 (Wahrscheinlichkeitsmaß, Wahrscheinlichkeit)**

Sei  $(\Omega, \mathcal{F})$  ein Meßraum und  $\mathbb{P} : \mathcal{F} \rightarrow [0, 1]$  ein Maß auf  $(\Omega, \mathcal{F})$  mit  $\mathbb{P}(\Omega) = 1$ . Dann heißt  $\mathbb{P}$  Wahrscheinlichkeitsmaß und ordnet jedem Ereignis  $A \in \mathcal{F}$  die Wahrscheinlichkeit  $\mathbb{P}(A)$  zu.

**Definition 4.2 (Wahrscheinlichkeitsraum, Verteilung)**

$(\Omega, \mathcal{F}, \mathbb{P})$  heißt Wahrscheinlichkeitsraum.  $\mathbb{P}$  heißt auch Verteilung.

**Definition 4.3 ( $\mathbb{P}$ -fast sicher)**

$$\mathbb{P}\text{-fast überall} \Leftrightarrow \mathbb{P}\text{-fast sicher}$$

**Satz 4.4 (Elementare Rechenregeln)**

Sei  $(\Omega, \mathcal{F}, \mathbb{P})$  ein Wahrscheinlichkeitsraum und  $A, B, A_n \in \mathcal{F}$ ,  $n \in \mathbb{N}$ . Dann gilt

- i)  $\mathbb{P}(\bar{A}) = 1 - \mathbb{P}(A)$
- ii)  $A \subset B \Rightarrow \mathbb{P}(A) \leq \mathbb{P}(B)$
- iii) Siebformel:
 
$$\mathbb{P}\left(\bigcup_{i=1}^n A_i\right) = \sum_{i=1}^n \mathbb{P}(A_i) - \sum_{1 \leq j_1 < \dots < j_i \leq n} \mathbb{P}\left(\bigcap_{k=1}^i A_{j_k}\right) + \dots$$
- iv)  $\mathbb{P}\left(\bigcup_{n=1}^{\infty} A_n\right) \leq \sum_{n=1}^{\infty} \mathbb{P}(A_n)$
- v) Stetigkeit von unten:  $A_n \uparrow A \Rightarrow \mathbb{P}(A_n) \uparrow \mathbb{P}(A)$
- vi) Stetigkeit von oben:  $A_n \downarrow A \Rightarrow \mathbb{P}(A_n) \downarrow \mathbb{P}(A)$

*Beweis.*

i) ii) iv)  $\Leftarrow$  Satz 2.23

v) vi)  $\Leftarrow$  Satz 2.24

iii) HA. □

## 4.2 Diskrete Wahrscheinlichkeitsmaße

**Definition 4.5 (diskreter W'keitsraum)**

Sei  $(\Omega, \mathcal{F}, \mathbb{P})$  ein Wahrscheinlichkeitsraum. Gibt es eine abzählbare (endlich oder unendlich) Menge  $T \in \mathcal{F}$  mit  $\mathbb{P}(T) = 1$ , so heißt  $(\Omega, \mathcal{F}, \mathbb{P})$  diskreter Wahrscheinlichkeitsraum,  $\mathbb{P}$  diskretes Wahrscheinlichkeitsmaß und  $T$  ein abzählbarer Träger von  $\mathbb{P}$ .

*Bemerkung.*  $\Omega$  selbst muß nicht abzählbar sein, ist es dies jedoch, so  $T = \Omega$ .



**Satz 4.6**

Ist  $(\Omega, \mathcal{F}, \mathbb{P})$  ein diskreter Wahrscheinlichkeitsraum mit Träger  $T$ , so ist die Funktion

$$f : \Omega \rightarrow [0, 1]$$

$$\omega \mapsto f(\omega) = \begin{cases} \mathbb{P}(\{\omega\}) & \text{für } \omega \in T \\ 0 & \text{sonst} \end{cases}$$

eine Dichte von  $\mathbb{P}$  bezüglich des Zählmaßes  $\mu_Z$ , also  $\mathbb{P} = f \odot \mu_Z$ . Insbesondere gilt

$$\mathbb{P}(A) = \int_A f d\mu_Z = \sum_{\omega \in A \cap T} f(\omega) \quad \forall A \in \mathcal{F}. \quad (4.1)$$

Umgekehrt gibt es zu jeder Funktion  $f$  der obigen Gestalt genau ein diskretes Wahrscheinlichkeitsmaß  $\mathbb{P}$  auf  $(\Omega, \mathcal{F})$ , so daß (4.1) gilt.

**Definition 4.7 (Zähldichte)**

$f$  aus Satz 4.6 heißt Zähldichte.

*Beweis.*

Zunächst zu zeigen:

$$\int_A g d\mu_Z = \sum_{\omega \in A} g(\omega); \quad g \in M^+$$

Der Träger  $\{\omega \in \Omega | g(\omega) > 0\}$  ist abzählbar!

**Zunächst einfach:**  $g = I_B$

$$\int_A g d\mu_Z = \int_A I_B d\mu_Z = \int I_A \cdot I_B d\mu_Z = \int I_{A \cap B} d\mu_Z = \mu_Z(A \cap B) = |A \cap B| = \sum_{\omega \in A} \underbrace{g(\omega)}_{=I_B!}$$

**etwas schwieriger:**  $g = \sum_{i=1}^n c_i I_{B_i} \in T^+$

$$\begin{aligned} \int_A g d\mu_Z &= \int_A \sum_{i=1}^n c_i I_{B_i} d\mu_Z \stackrel{\text{Linearität}}{=} \sum_{i=1}^n c_i \int_A I_{B_i} d\mu_Z = \sum_{i=1}^n c_i \sum_{\omega \in A} I_{B_i}(\omega) \\ &= \sum_{\omega \in A} \sum_{i=1}^n c_i I_{B_i}(\omega) = \sum_{\omega \in A} g(\omega) \end{aligned}$$

**ganz schwierig:**  $g \in M^+$  (Träger immer noch abzählbar)

mit Lemma 3.6 existiert eine Folge von Treppenfunktionen  $(g_n)_{n \in \mathbb{N}} \in T^+$  mit  $g_n \uparrow g$

$$\begin{aligned} \int_A g d\mu_Z &= \int_A \lim_{n \rightarrow \infty} g_n d\mu_Z \stackrel{\text{monotone Konvergenz}}{=} \lim_{n \rightarrow \infty} \int_A g_n d\mu_Z \\ &= \lim_{n \rightarrow \infty} \sum_{\omega \in A} g_n(\omega) \stackrel{g_n \uparrow g}{=} \sum_{\omega \in A} g(\omega) \end{aligned}$$

$f$  hat per Definition abzählbaren Träger und damit

$$\int_A f d\mu_Z = \sum_{\omega \in A} f(\omega) \quad \forall A \in \mathcal{F}.$$

Desweiteren

$$\mathbb{P}(A) = \mathbb{P}(A \cap T) \stackrel{\mathbb{P} \text{ ist diskret}}{=} \sum_{\omega \in A \cap T} \mathbb{P}(\{\omega\}) \stackrel{\text{Def. } f}{=} \sum_{\omega \in A} f(\omega) = \int_A f d\mu_Z \stackrel{\text{Lemma 3.28}}{=} (f \odot \mu_Z)(A)$$

$\Leftrightarrow f$  ist Dichte bzgl.  $\mu_Z$  und  $(f \odot \mu_Z) = \mathbb{P}$  ist Maß mit der Dichte  $f$  bzgl.  $\mu_Z$ .

Umgekehrt: Ist eine Zähldichte  $f$  gegeben, so definieren wir  $\mathbb{P} = f \odot \mu_Z$  und per Definition

$$\mathbb{P}(A) = (f \odot \mu_Z)(A) = \int_A f d\mu_Z = \sum_{\omega \in A} f(\omega)$$

□

*Bemerkung.* Jedes diskrete Wahrscheinlichkeitsmaß  $\mathbb{P}$  hat genau eine Zähldichte  $f$  bezüglich  $\mu_Z$ . Dies folgt aus Satz 3.31.

#### Beispiel 4.4 (diskrete Gleichverteilung)

$\Omega = \{1, \dots, n\}$  endlich.

Zähldichte  $f(\omega) := \frac{1}{|\Omega|} \quad \forall \omega \in \Omega$

$$\mathbb{P}(A) = \int_A f d\mu_Z \stackrel{\text{Satz 4.6}}{=} \sum_{\omega \in A} f(\omega) = \frac{1}{n} \sum_{\omega \in A} 1 = \frac{|A|}{n} = \frac{|A|}{|\Omega|} \quad \forall A \in \mathcal{P}(\Omega)$$

$U := \mathbb{P}$

#### Beispiel 4.5 (Bernoulli-Verteilung)

$\Omega = \underbrace{\{\text{„Kopf“}\}}_{\omega_1}, \underbrace{\{\text{„Zahl“}\}}_{\omega_2} \quad \Omega = \{\text{„defekt“}, \text{„OK“}\}$  endlich

Zähldichte  $f(\omega) = \begin{cases} p & \omega = \omega_1 \\ 1 - p & \omega = \omega_2 \end{cases}$

$p \in [0, 1]$  "Erfolgswahrscheinlichkeit" Parameter

$$\mathbb{P}(A) = \int_A f d\mu_Z = \sum_{\omega \in A} f(\omega) \quad \forall A \in \mathcal{P}(\Omega) = \{\{\omega_1\}, \{\omega_2\}, \Omega, \emptyset\}$$

$B(1, p) := \mathbb{P}$

#### Beispiel 4.6 (Binomial-Verteilung)

$\Omega = \{0, 1, 2, \dots, n\}$  endlich

Zähldichte  $f(x) = \binom{n}{x} p^x (1-p)^{n-x} \quad x \in \Omega$

$$\mathbb{P}(A) = \int_A f d\mu_Z = \sum_{x \in A} \binom{n}{x} p^x (1-p)^{n-x} \quad \forall A \in \mathcal{F} = \mathcal{P}(\Omega)$$

$$\mathbb{P}(\Omega) = \sum_{x \in \Omega} \binom{n}{x} p^x (1-p)^{n-x} = \sum_{x=0}^n \binom{n}{x} p^x (1-p)^{n-x} \stackrel{\text{Bin. Formel}}{=} (p + (1-p))^n = 1^n = 1 \quad \checkmark$$

Achtung:  $n$  und  $p$  sind Parameter dieser Verteilung.

$$B(n, p) := \mathbb{P}$$

### Beispiel 4.7 (Poisson-Verteilung)

$$\Omega = \mathbb{N}_0$$

$$\text{Zähldichte } f(x) = \frac{\lambda^x e^{-\lambda}}{x!} \quad \forall x \in \Omega$$

$\lambda$  Parameter

$$\mathbb{P}(A) = \int_A f d\mu_Z = \sum_{x \in A} f(x) = \sum_{x \in A} \frac{\lambda^x e^{-\lambda}}{x!}$$

$$\mathbb{P}(\Omega) = \sum_{x \in \Omega} \frac{\lambda^x e^{-\lambda}}{x!} = \sum_{x=0}^{\infty} \frac{\lambda^x e^{-\lambda}}{x!} = \frac{1}{e(\lambda)} \sum_{x=0}^{\infty} \frac{\lambda^x}{x!} = \frac{1}{\sum_{x=0}^{\infty} \frac{\lambda^x}{x!}} \sum_{x=0}^{\infty} \frac{\lambda^x}{x!} = 1 \quad \checkmark$$

$$P(\lambda) := \mathbb{P}$$

## 4.3 Stetige Verteilungen

Jetzt:  $\mathbb{P} : \mathcal{B} \rightarrow [0, 1]$

### Definition 4.8 (Verteilungsfunktion)

Ist  $\mathbb{P} : \mathcal{B} \rightarrow [0, 1]$  ein Wahrscheinlichkeitsmaß auf  $\mathbb{R}$ , so heißt

$$\begin{aligned} F_{\mathbb{P}} : \mathbb{R} &\rightarrow [0, 1] \\ x &\mapsto F_{\mathbb{P}}(x) := \mathbb{P}([-\infty, x]) \end{aligned}$$

die Verteilungsfunktion von  $\mathbb{P}$ .

### Satz 4.9 (Eigenschaften der Verteilungsfunktion)

Eine Verteilungsfunktion  $F_{\mathbb{P}}$  ist

- i) monoton wachsend
- ii) rechtsstetig
- iii)  $\lim_{x \rightarrow -\infty} F_{\mathbb{P}}(x) = 0$ ;  $\lim_{x \rightarrow \infty} F_{\mathbb{P}}(x) = 1$

*Beweis.*

$$\text{i) } a \leq b \Rightarrow F_{\mathbb{P}}(b) - F_{\mathbb{P}}(a) = \mathbb{P}([a, b]) \geq 0$$

$$\text{ii) } x_n \downarrow x \Rightarrow$$

$$\lim_{n \rightarrow \infty} F_{\mathbb{P}}(x_n) = \lim_{n \rightarrow \infty} \mathbb{P}([-\infty, x_n]) \stackrel{\text{Satz 2.24}}{=} \mathbb{P}([-\infty, x]) = F_{\mathbb{P}}(x)$$

iii)  $x_n \downarrow -\infty \Rightarrow$

$$\lim_{n \rightarrow \infty} F_{\mathbb{P}}(x_n) = \lim_{n \rightarrow \infty} \mathbb{P}(] - \infty, x_n]) \stackrel{\text{Satz 2.24}}{=} \mathbb{P}(\emptyset) = 0$$

$x_n \uparrow \infty \Rightarrow$

$$\lim_{n \rightarrow \infty} F_{\mathbb{P}}(x_n) = \lim_{n \rightarrow \infty} \mathbb{P}(] - \infty, x_n]) \stackrel{\text{Satz 2.24}}{=} \mathbb{P}(] - \infty, \infty[) = \mathbb{P}(\mathbb{R}) = 1$$

□

### Definition 4.10 (Verteilungsfunktion)

Jede monoton wachsende, rechtsstetige Funktion

$$F : \mathbb{R} \rightarrow [0, 1] \quad \text{mit}$$

$$\lim_{x \rightarrow -\infty} F(x) = 0 \quad \text{und} \quad \lim_{x \rightarrow \infty} F(x) = 1$$

heißt Verteilungsfunktion.

### Satz 4.11 (Korrespondenzsatz)

Für jede Verteilungsfunktion  $F$  ist  $\mu := \lambda_F(]a, b]) = F(b) - F(a)$  (siehe Satz 2.28) ein Wahrscheinlichkeitsmaß mit  $F_{\mu} = F$ . Umgekehrt ist für jedes reelle Wahrscheinlichkeitsmaß  $\mathbb{P}$  die Funktion  $G := F_{\mathbb{P}}$  eine Verteilungsfunktion und  $\lambda_G = \mathbb{P}$ .

*Bemerkung.*  $\lambda_F(\mathbb{R}) = \lim_{n \rightarrow \infty} \lambda_F(] - \infty, n]) = \lim_{n \rightarrow \infty} F(n) = 1$   
 $\Rightarrow \lambda_F$  ist Wahrscheinlichkeitsmaß.

*Beweis.*

” $\Rightarrow$ ”:  $F$  Verteilungsfunktion,  $\mu = \lambda_F$

$$F_{\mu}(x) = \lim_{n \rightarrow \infty} \mu(] - n, x]) = \lim_{n \rightarrow \infty} (F(x) - \underbrace{F(-n)}_{\rightarrow 0}) = F(x) \quad \forall x \in \mathbb{R}$$

” $\Leftarrow$ ”:  $\mathbb{P}$  W'keitsmaß,  $G = F_{\mathbb{P}}$

$$\begin{aligned} \lambda_G(]a, b]) &= G(b) - G(a) \\ &= \mathbb{P}(] - \infty, b]) - \mathbb{P}(] - \infty, a]) \\ &= \mathbb{P}(]a, b]) \quad \forall \underbrace{]a, b], a < b \in \mathbb{R}}_{\pi\text{-System Erzeuger von } \mathcal{B}} \end{aligned}$$

$\Rightarrow \lambda_G$  und  $\mathbb{P}$  stimmen auf einem durchschnittsstabilen Erzeuger von  $\mathcal{B}$  überein  
 $\stackrel{\text{Satz 2.25}}{\Rightarrow} \mathbb{P} = \lambda_G$

□

*Bemerkung.* Wahrscheinlichkeitsmaße auf  $\mathbb{R}$  sind durch Verteilungsfunktionen vollständig definiert.

**Lemma 4.12**

Sei  $\mathbb{P} : \mathcal{B} \rightarrow [0, 1]$  ein Wahrscheinlichkeitsmaß und  $F_{\mathbb{P}}$  seine Verteilungsfunktion. Dann gilt

$$\mathbb{P}(\{x\}) = F_{\mathbb{P}}(x) - F_{\mathbb{P}}(x^-) \quad \forall x \in \mathbb{R}$$

mit  $F_{\mathbb{P}}(x^-) = \lim_{t \uparrow x} F_{\mathbb{P}}(t) \quad \forall x \in \mathbb{R}$  (linksseitiger Grenzwert)

*Beweis.*

$$\begin{aligned} \mathbb{P}(\{x\}) &= \lim_{n \rightarrow \infty} \mathbb{P}\left(\left]x - \frac{1}{n}, x\right]\right) \stackrel{2.24}{=} \\ &= \lim_{n \rightarrow \infty} \left(F_{\mathbb{P}}(x) - F_{\mathbb{P}}\left(x - \frac{1}{n}\right)\right) \\ &= F_{\mathbb{P}}(x) - F_{\mathbb{P}}(x^-) \end{aligned}$$

□

**Korollar 4.13**

Sei  $\mathbb{P} : \mathcal{B} \rightarrow [0, 1]$  ein Wahrscheinlichkeitsmaß und  $F_{\mathbb{P}}$  seine Verteilungsfunktion. Dann sind äquivalent

- i)  $F_{\mathbb{P}}$  ist stetig
- ii)  $\mathbb{P}(\{x\}) = 0 \quad \forall x \in \mathbb{R}$ .

## 4.4 Dichten

Sei  $\mu = (f \odot \lambda)$  ein Maß mit der Dichte  $f$  bezüglich des Lebesgue-Maßes  $\lambda$ , also

$$\mu(A) = \int_A f \, d\lambda \quad \forall A \in \mathcal{B}.$$

**Satz 4.14**

Sei  $f : \mathbb{R} \rightarrow [0, \infty[$  und  $\mathbb{P} = f \odot \lambda$ . Dann ist  $\mathbb{P}$  ein Wahrscheinlichkeitsmaß genau dann, wenn  $f$  auf  $\mathbb{R}$  integrierbar ist und  $\int_{\mathbb{R}} f \, d\lambda = 1$ .

*Beweis.*

$$\mathbb{P}([a, b]) = \int_{[a, b]} f \, d\lambda \in [0, 1] \quad \forall a, b$$

$$\text{Insbesondere } \int_{\mathbb{R}} f \, d\lambda = 1$$

□

*Bemerkung.* Wenn  $f$  Riemann-integrierbar ist gilt:

$$\int_{-\infty}^{\infty} f(x) \, dx = 1 \quad \text{und} \quad F_{\mathbb{P}}(x) = \mathbb{P}(\] - \infty, x]) = \int_{-\infty}^x f(y) \, dy$$

*Bemerkung.* Ist  $g : \mathbb{R} \rightarrow \mathbb{R}$  stetig und  $f = g \cdot I_{]a,b[}$ , so heißt  $f$  stetige Dichte,  $F_{\mathbb{P}}$  ist auf ganz  $\mathbb{R}$  stetig.  $\mathbb{P}$  heißt stetige Verteilung.

#### Beispiel 4.8 (Stetige Gleichverteilung)

$\Omega = \mathbb{R}$ ,  $\mathcal{F} = \mathcal{B}$ ,  $a < b \in \mathbb{R}$

$$f(\omega) = \frac{1}{b-a} I_{]a,b[}(\omega) \quad \forall \omega \in \Omega$$

$$\mathbb{P}(A) = \int_A f d\lambda = \frac{1}{b-a} \int I_{]a,b[ \cap A} d\lambda = \frac{\lambda(]a,b[ \cap A)}{b-a} = 1 \quad A = ]a,b[$$

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

$$U(a, b) := \mathbb{P}$$

#### Beispiel 4.9 (Normalverteilung)

$\Omega = \mathbb{R}$ ,  $\mathcal{F} = \mathcal{B}$ ,  $\mu, \sigma \in \mathbb{R}$ ,  $\sigma > 0$

$$f(x) = \frac{1}{\sigma} \varphi\left(\frac{x-\mu}{\sigma}\right) \quad \text{Dichte der Normalverteilung}$$

$$\varphi(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right) \quad \text{Dichte der Standardnormalverteilung } (\mu = 0, \sigma = 1)$$

$$\mathbb{P}(A) = \int_A f d\lambda \quad \forall A \in \mathcal{B}$$

$$\mathbb{P}(]-\infty, x]) = \int_{-\infty}^x \varphi(y) dy =: \Phi(x) \quad \text{Verteilungsfunktion der Standardnormalverteilung}$$

$$F(x) = \int_{-\infty}^x f(y) dy \quad \text{Verteilungsfunktion der Normalverteilung}$$

$$\text{z.Z. } \Phi(\infty) = 1$$

$$\text{zunächst: } \int_0^{\infty} \exp\left(-\frac{x^2}{2}\right) dx = \sqrt{\pi}$$

$$\left(\int_0^{\infty} \exp(-y^2) dy\right)^2 = \int_0^{\infty} \exp(-y^2) dy \int_0^{\infty} \exp(-t^2) dt$$

$$\stackrel{\text{Fubini}}{=} \int_0^{\infty} \left(\int_0^{\infty} \exp(-y^2) dy\right) \exp(-t^2) dt$$

$$\stackrel{t=x \cdot y}{=} \int_0^{\infty} \int_0^{\infty} \exp(-y^2) dy \exp(-x^2 y^2) y dx$$

$$\begin{aligned}
& \stackrel{\text{Fubini}}{=} \int_0^{\infty} \underbrace{\int_0^{\infty} y \cdot \exp(-(1+x^2)y^2) dy}_{\frac{1}{2} \frac{1}{1+x^2}} dx \\
&= \frac{1}{2} \int_0^{\infty} \frac{1}{1+x^2} dx = \frac{1}{2} [\arctan]_0^{\infty} = \frac{1}{2} \left( \frac{\pi}{2} - 0 \right) = \frac{\pi}{4} \\
&\Rightarrow \int_0^{\infty} \exp(-y^2) dy = \frac{\sqrt{\pi}}{2} \\
&\exp(-y^2) \text{ symmetrisch um } y=0 \Rightarrow \int_{-\infty}^{\infty} \exp(-y^2) dy = \sqrt{\pi}
\end{aligned}$$

weiterhin:

$$\begin{aligned}
& \int_{-\infty}^{\infty} \exp\left(-\frac{y^2}{2}\right) dy \stackrel{x=\frac{y}{\sqrt{2}}}{=} \int_{-\infty}^{\infty} \exp(-x^2) \sqrt{2} dx = \sqrt{2\pi} \\
&\Rightarrow \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} \exp\left(-\frac{y^2}{2}\right) dy = \frac{1}{\sqrt{2\pi}} \sqrt{2\pi} = 1 \\
& \int_{-\infty}^{\infty} f(x) dx = \int_{-\infty}^{\infty} \frac{1}{\sigma} \varphi\left(\frac{x-\mu}{\sigma}\right) dx \stackrel{u=\frac{x-\mu}{\sigma}}{=} \int_{-\infty}^{\infty} \varphi(u) du = 1 \\
& F(x) = \Phi\left(\frac{x-\mu}{\sigma}\right) \quad (\text{nur numerisch zu approximieren.}) \\
& N(\mu, \sigma^2) := \mathbb{P}
\end{aligned}$$

**Beispiel 4.10 (Anwendung der Normalverteilung)**

Sei  $(\mathbb{R}, \mathcal{B}, N(10, 4))$  unser Wahrscheinlichkeitsraum und  $A = ]12, 20]$  das Ereignis  $12 < \omega \leq 20$ .

Dann ist

$$\begin{aligned}
\mathbb{P}(A) &= \int_A f d\lambda = \int_{12}^{20} f(x) dx = \int_{-\infty}^{20} f(x) dx - \int_{-\infty}^{12} f(x) dx = \Phi\left(\frac{20-10}{2}\right) - \Phi\left(\frac{12-10}{2}\right) \\
&= 0.99... - 0.8413447 \approx 0.1586550
\end{aligned}$$

**Beispiel 4.11 (Exponentialverteilung)**

$\Omega = \mathbb{R}, \mathcal{F} = \mathcal{B}$

$$f(x) = \begin{cases} 0 & x \leq 0 \\ \lambda \exp(-\lambda x) & x > 0 \end{cases}$$

$$\mathbb{P}(A) = \int_A f d\lambda$$

$$\begin{aligned}
F(x) &= \int_{-\infty}^x f(y) dy = \int_{-\infty}^x \lambda \exp(-\lambda y) dy = \lambda \int_0^x \exp(-\lambda y) dy = \lambda \frac{1}{-\lambda} [\exp(-\lambda y)]_0^x \\
&= 1 - \exp(-\lambda x) \quad \text{für } x > 0, 0 \text{ sonst} \\
&\rightarrow 1 \quad \text{für } x \rightarrow \infty
\end{aligned}$$

**Beispiel 4.12 (Gemischte Verteilungen)**

Kann es auch Wahrscheinlichkeitsmaße geben, die einen diskreten und einen stetigen Teil besitzen? Sei  $\mathbb{P}$  ein Wahrscheinlichkeitsmaß auf  $(\mathbb{R}, \mathcal{B})$ . Seien  $x_1 \in \mathbb{R}$ ,  $x_2 \in \mathbb{R}$ ,  $\dots$ ,  $x_k \in \mathbb{R}$ , so daß gilt:

- $\mathbb{P}$  ist auf  $\mathbb{R} \setminus \{x_1, \dots, x_k\}$  absolut stetig, also

$$\mathbb{P}(B) = \int_B f(x) d\lambda(x) \quad \forall B \in \mathcal{B} \quad \text{mit } x_j \notin B \quad \forall j \in \{1, \dots, k\}$$

für eine Lebesgue-Dichte  $f$ .

- $\mathbb{P}(\{x_j\}) > 0 \quad \forall j \in \{1, \dots, k\}$

$\mathbb{P}$  besitzt also einen absolut stetigen und einen diskreten Teil;  $\mathbb{P}$  wird nicht vom Lebesgue-maß dominiert und besitzt somit keine Lebesgue-Dichte (vergeiche hierzu auch den Satz von Radon-Nikodym 3.31).

Können wir ein Maß  $\mu$  wählen, so daß  $\mathbb{P} = f^* \odot \mu$  ein Maß mit Dichte  $f^*$  bezüglich  $\mu$  ist? Wähle

$$\mu := \lambda + \delta_{x_1} + \dots + \delta_{x_k}$$

Klar:  $\mu$  ist ein  $\sigma$ -endliches Maß!

Wir zeigen nun

$$\mathbb{P} \ll \mu \tag{4.2}$$

Sei dazu  $B \in \mathcal{B}$ , so dass  $\mu(B) = 0$ . Also

$$\underbrace{\lambda(B)}_{\geq 0} + \underbrace{\delta_{x_1}(B)}_{\geq 0} + \dots + \underbrace{\delta_{x_k}(B)}_{\geq 0} = 0$$

und somit

$$\begin{aligned}
\lambda(B) = 0, \quad & \underbrace{\delta_{x_1}(B) = 0, \delta_{x_2}(B) = 0, \dots, \delta_{x_k}(B) = 0}_{\Rightarrow x_j \notin B \quad \forall j \in \{1, \dots, k\}}
\end{aligned}$$

Schließlich folgt daher

$$\mathbb{P}(B) \stackrel{x_j \notin B}{=} \int_B f(x) d\lambda(x) = \int f(x) I_B(x) d\lambda(x) \stackrel{\text{Bem. nach Satz 3.15}}{=} 0$$



Also ist

$$\mathbb{P} \ll \lambda + \delta_{x_1} + \dots + \delta_{x_k} = \mu$$

und damit existiert mit dem Satz von Radon-Nikodym auch eine Dichte  $f^* \in M^+$  von  $\mathbb{P}$  bzgl.  $\mu$ . Es gilt

$$\mathbb{P}(B) = \int_B f(x) d\lambda(x) \quad \forall B \in \mathcal{B} \quad \text{mit } x_j \notin B \quad \forall j \in \{1, \dots, k\}$$

und

$$\alpha_j := \mathbb{P}(\{x_j\}) > 0 \quad j \in \{1, \dots, k\}$$

Setze nun

$$f^*(x) := f(x) \quad \forall x \in \mathbb{R} \setminus \{x_1, \dots, x_k\}$$

und

$$f^*(x) := \alpha_j \quad \text{falls } x = x_j, \quad j \in \{1, \dots, k\}$$

Dann ist

$$f^* : \mathbb{R} \rightarrow \mathbb{R}, \quad x \mapsto f^*(x)$$

die Dichte von  $\mathbb{P}$  bzgl.  $\mu = \lambda + \delta_{x_1} + \dots + \delta_{x_k}$ , das heißt

$$\mathbb{P}(B) = \int_B f^*(x) d\mu(x) \quad \forall B \in \mathcal{B}$$

Dank der einheitlichen Theorie, welche in den Kapiteln 2 und 3 erarbeitet wurde, können wir alle erdenklichen Verteilungen behandeln. Lästige (und verwirrende) Fallunterscheidungen (stetig, diskret, ...) sind damit nicht mehr nötig!

# Kapitel 5

## Zufallsvariablen

### 5.1 Zufallsvariable und deren Verteilung

#### Definition 5.1 (Zufallsvariable)

Ist  $(\Omega_1, \mathcal{F}_1, \mathbb{P})$  ein Wahrscheinlichkeitsraum und  $(\Omega_2, \mathcal{F}_2)$  ein Meßraum, so heißt eine  $\mathcal{F}_1$ - $\mathcal{F}_2$  meßbare Abbildung

$$X : \Omega_1 \rightarrow \Omega_2$$

Zufallsvariable (ZV). Ist  $\Omega_2 = \mathbb{R}$ , so heißt  $X$  reelle Zufallsvariable,  $\Omega_2 = \bar{\mathbb{R}}$  numerische Zufallsvariable,  $\Omega_2 = \mathbb{R}^n$   $n$ -dimensionale reelle Zufallsvariable.

*Bemerkung.* Das Bildmaß  $\mathbb{P}_X$  von  $\mathbb{P}$  unter  $X$

$$\mathbb{P}_X(A) = \mathbb{P}(\underbrace{X^{-1}(A)}_{\in \mathcal{F}_1}) \in [0, 1] \quad \forall A \in \mathcal{F}_2$$

ist wieder ein Wahrscheinlichkeitsmaß.

#### Definition 5.2 (Verteilung einer Zufallsvariablen)

Ist  $(\Omega_1, \mathcal{F}_1, \mathbb{P})$  ein Wahrscheinlichkeitsraum und  $(\Omega_2, \mathcal{F}_2)$  ein Meßraum und  $X : \Omega_1 \rightarrow \Omega_2$  eine Zufallsvariable, so heißt das Bildmaß  $\mathbb{P}_X$  von  $\mathbb{P}$  unter  $X$  Verteilung von  $X$ .

*Bemerkung.* zur Schreibweise:

$$\begin{aligned} \mathbb{P}_X(A) &= \mathbb{P}(X^{-1}(A)) \\ &= \mathbb{P}(\{\omega \in \Omega_1 | X(\omega) \in A\}) \\ &=: \mathbb{P}(X \in A) \\ \mathbb{P}_X(\{c\}) &= \mathbb{P}(X^{-1}(\{c\})) \\ &= \mathbb{P}(\{\omega \in \Omega_1 | X(\omega) = c\}) \\ &=: \mathbb{P}(X = c) \quad \leq \geq < > \text{ genauso.} \end{aligned}$$

Ist  $\mathbb{P}_X = N(\mu, \sigma^2)$ , so schreiben wir auch

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

Ist  $\mathbb{P}_X$  diskret/stetig, so heißt auch  $X$  diskret/stetig.

### Satz 5.3

Sei  $X : \Omega \rightarrow \mathbb{R}^n$  eine  $n$ -dimensionale reelle Zufallsvariable und  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  eine meßbare Funktion, so daß  $f \circ X : \Omega \rightarrow \mathbb{R}$  integrierbar ist. Dann gilt

$$\int f d\mathbb{P}_X = \int f \circ X d\mathbb{P}.$$

*Beweis.*

Ist  $f = I_A, A \in \mathcal{B}^n$ , so ist

$$\begin{aligned} (f \circ X)(\omega) &= f(X(\omega)) \\ &= I_A(X(\omega)) = \begin{cases} 1 & X(\omega) \in A \\ 0 & \text{sonst} \end{cases} \\ &= \underbrace{I_{X^{-1}(A)}}_{\in \mathcal{F}}(\omega) = \begin{cases} 1 & \omega \in X^{-1}(A) = \{\omega \in \Omega | X(\omega) \in A\} \\ 0 & \text{sonst} \end{cases} \end{aligned}$$

$$\begin{aligned} \Rightarrow \int f d\mathbb{P}_X &= \int I_A d\mathbb{P}_X \\ &= \mathbb{P}_X(A) \\ &= \mathbb{P}(X^{-1}(A)) \\ &= \int I_{X^{-1}(A)} d\mathbb{P} \\ &= \int f \circ X d\mathbb{P} \end{aligned}$$

Für  $f \in T^+$  folgt alles weitere aus der Linearität und  $f \in M^+$  über Grenzwertbildung.  $\square$

## 5.2 Erwartungswert und Varianz

### Definition 5.4 (Erwartungswert)

Ist  $X : \Omega \rightarrow \mathbb{R}$  eine quasi-integrierbare reelle ZV, so heißt

$$\mathbb{E}(X) := \int X d\mathbb{P} = \int x d\mathbb{P}_X(x)$$

der Erwartungswert von  $X$ .

*Bemerkung.* Sei  $\mathbb{P}_X = f_X \odot \mu$  (d.h.,  $f_X : \mathbb{R} \rightarrow \mathbb{R}$  ist die  $\mu$ -Dichte des Bildmaßes von  $\mathbb{P}$  unter  $X$ ) und  $g(x) = x$  (Identität). Damit gilt:

$$\begin{aligned} \mathbb{E}(X) &= \int X d\mathbb{P} = \int g \circ X d\mathbb{P} \\ &\stackrel{\text{Satz 5.3}}{=} \int g d\mathbb{P}_X = \int g d(f_X \odot \mu) \stackrel{\text{Lemma 3.28}}{=} \int g \cdot f_X d\mu \\ &= \begin{cases} \sum_{x \in T} x f_X(x) & \mu = \mu_Z \text{ (diskret)} \\ \int_{-\infty}^{\infty} x f_X(x) dx & \mu = \lambda \text{ (stetig)} \end{cases} \end{aligned}$$

Letzteres vorausgesetzt, daß entweder  $T$  abzählbarer Träger von  $f_X$  (diskreter Fall) oder  $f_X$  Riemann-integrierbar (stetiger Fall) ist.

*Bemerkung.* Alle Eigenschaften des Lebesgue-Integrals übertragen sich auf den Erwartungswert, insbesondere

$$\mathbb{E}(aX + b) = a \mathbb{E}(X) + b$$

$$X \leq Y \Rightarrow \mathbb{E}(X) \leq \mathbb{E}(Y)$$

### Definition 5.5 (Varianz einer ZV)

Ist  $X$  eine ZV mit  $\mathbb{E}(|X|) < \infty$  so heißt

$$\mathbb{V}(X) := \mathbb{E}((X - \mathbb{E}(X))^2) = \mathbb{E}(X^2) - \mathbb{E}(X)^2$$

Varianz von  $X$ .

*Bemerkung.*  $\mathbb{P}_X = f_X \odot \lambda \Rightarrow \mathbb{V}(X) = \int (x - \mathbb{E}(X))^2 f(x) dx$

$$\mathbb{P}_X = f_X \odot \mu_Z \Rightarrow \mathbb{V}(X) = \sum_{x \in T} (x - \mathbb{E}(X))^2 f(x)$$

### Beispiel 5.1

$$\begin{aligned} \mathbb{V}(X) = 0 &\Rightarrow \{\omega \in \Omega \mid |X(\omega) - \mathbb{E}(X)| > 0\} \text{ ist } \mathbb{P}\text{-Nullmenge} \\ &\Rightarrow X = \mathbb{E}(X) \quad \mathbb{P}\text{-fast-sicher} \end{aligned}$$

### Beispiel 5.2 (Bernoulli-Verteilung)

$(\Omega_1 = \{\text{''Kopf''}, \text{''Zahl''}\}, \mathcal{P}(\Omega_1), B(1, p))$  W'keitsraum

$(\Omega_2 = \{0, 1\}, \mathcal{P}(\Omega_2))$  Meßraum

$X : \Omega_1 \rightarrow \Omega_2$

$$\omega \mapsto X(\omega) = \begin{cases} 0 & \omega = \text{''Kopf''} \\ 1 & \omega = \text{''Zahl''} \end{cases} \quad (\text{meßbar})$$

$$\begin{aligned}
\mathbb{P}_X(A) &= B(1, p)(X^{-1}(A)), \text{ d.h. z.B.} \\
\mathbb{P}_X(\{0\}) &= B(1, p)(X^{-1}(\{0\})) \\
&= B(1, p)(\{\text{''Kopf''}\}) \\
&= \int_{\text{''Kopf''}} f d\mu_Z = f(\text{''Kopf''}) = p
\end{aligned}$$

weiterhin:

$$\mathbb{P}_X = f_X \odot \mu_Z \text{ mit } f_X : \underbrace{\{0, 1\}}_{\text{!!! nicht } \Omega} \rightarrow [0, 1]$$

$$f_X(x) = p^x(1-p)^{1-x} \quad x \in \Omega_2, 0 \text{ sonst}$$

$(\Omega_2, \mathcal{P}(\Omega_2), \mathbb{P}_X)$  ist W'keitsraum.

Dann:

$$\begin{aligned}
\mathbb{E}(X) &= \int X d\mathbb{P} = \int x d\mathbb{P}_X(x) = \int x d(f_X \odot \mu_Z)(x) = \int x f_X(x) d\mu_Z(x) \\
&= \sum_{x \in \{0,1\}} x \cdot f_X(x) = 1 \cdot p + 0 \cdot (1-p) = p \\
\mathbb{V}(X) &= \int (X - \mathbb{E}(X))^2 d\mathbb{P} \\
&= \sum_{x \in T} x^2 f_X(x) - p^2 = 1^2 \cdot p + 0^2 \cdot (1-p) - p^2 = p(1-p)
\end{aligned}$$

### Beispiel 5.3 (Binomialverteilung)

$$(\Omega_1 = \{0, \dots, n\}, \mathcal{P}(\Omega_1), B(n, p))$$

$$(\Omega_2 = \Omega_1, \mathcal{P}(\Omega_2))$$

$$X : \Omega_1 \rightarrow \Omega_2$$

$$\omega \mapsto X(\omega) = \omega \quad \text{Identitat}$$

$$\begin{aligned}
\mathbb{E}(X) &= \sum_{x=0}^n x \binom{n}{x} p^x (1-p)^{n-x} \\
&\stackrel{\text{Index } x=1}{=} n p \sum_{x=1}^n \binom{n-1}{x-1} p^{x-1} (1-p)^{n-x} \\
&= n p \underbrace{\sum_{x=0}^{n-1} \binom{n-1}{x} p^x (1-p)^{n-x-1}}_{\text{Binomische Formel}} \\
&= n p \underbrace{(p + (1-p))^{n-1}}_1 = n p
\end{aligned}$$

$$\begin{aligned}
\mathbb{V}(X) &= \sum_{x=0}^n x^2 \binom{n}{x} p^x (1-p)^{n-x} - (np)^2 \\
&\stackrel{q:=1-p}{=} np \sum_{x=1}^n x \binom{n-1}{x-1} p^{x-1} q^{n-x} - (np)^2 \\
&= np \sum_{x=0}^{n-1} (x+1) \binom{n-1}{x} p^x q^{n-1-x} - (np)^2 \\
&= np \left( \sum_{x=0}^{n-1} x \binom{n-1}{x} p^x q^{n-1-x} + 1 \right) - (np)^2 \\
&= np((n-1)p + 1) - (np)^2 = np(1-p)
\end{aligned}$$

**Beispiel 5.4 (Gleichverteilung)**

$$\mathbb{E}(X) = \frac{1}{b-a} \int_a^b x \, dx = \frac{a+b}{2}$$

$$\mathbb{V}(X) = \frac{1}{b-a} \int_a^b x^2 \, dx - \left( \frac{a+b}{2} \right)^2 = \frac{(b-a)^2}{12}$$

**Beispiel 5.5 (Normalverteilung)**

$$\mathbb{E}(X) = \mu$$

$$\mathbb{V}(X) = \sigma^2$$

Warum: etwas später

## 5.3 Funktionen von Zufallsvariablen

**Satz 5.6 (Funktionen von Zufallsvariablen)**

Sei  $X : \Omega \rightarrow \mathbb{R}^n$  eine Zufallsvariable und  $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$  messbar. Dann ist  $g \circ X : \Omega \rightarrow \mathbb{R}^m$  ebenfalls eine Zufallsvariable.

*Beweis.*

$g \circ X$  ist als Komposition von messbaren Funktionen  $\mathcal{F}$ - $\mathcal{B}$ -messbar Satz 2.17 und somit Zufallsvariable.  $\square$

*Bemerkung.* •  $aX + b$  ist ZV

- $X_1 + X_2$  ist ZV (wenn  $X = (X_1, X_2)$  ZV und  $g(X) = X_1 + X_2$ )
- $X_1 \cdot X_2$  ist ZV,  $X_1/X_2$  genauso

- $X^2$  ist ZV
- $\vdots$
- nach Satz 2.18

*Bemerkung.* zur Schreibweise:

$$\begin{aligned}\mathbb{P}_{g(X)}(A) &= \mathbb{P}((g \circ X)^{-1}(A)) \\ &= \mathbb{P}(\{\omega \in \Omega \mid (g \circ X)(\omega) \in A\}) \\ &=: \mathbb{P}(g(X) \in A)\end{aligned}$$

### Beispiel 5.6

$$\mathbb{P}(X^2 \leq c) = \mathbb{P}(\{\omega \in \Omega \mid (X(\omega))^2 \leq c\})$$

*Bemerkung.*

$$\begin{aligned}\mathbb{E}(g(X)) &= \int (g \circ X) d\mathbb{P} \quad \text{wenn } g \circ X \text{ quasi-integrierbar} \\ &= \int g d\mathbb{P}_X \\ &= \begin{cases} \sum_{-\infty}^{\infty} g(x) f_X(x) & \mathbb{P} \text{ diskret} \\ \int_{-\infty}^{\infty} g(x) f_X(x) dx & \mathbb{P} \text{ stetig} \end{cases}\end{aligned}$$

## 5.4 Momente und momenterzeugende Funktionen

### Definition 5.7 (Momente)

Sei  $X$  eine integrierbare Zufallsvariable und  $n \in \mathbb{N}$ , so daß  $X^n$  quasi-integrierbar ist. Dann heißt

$$\begin{aligned}m_{(n)}(X) &= \mathbb{E}(|X|^n) && n\text{-tes absolutes Moment} \\ m_n(X) &= \mathbb{E}(X^n) && n\text{-tes Moment und} \\ m_n^0(X) &= \mathbb{E}((X - \mathbb{E}(X))^n) && n\text{-tes zentriertes Moment von } X\end{aligned}$$

*Bemerkung.*  $\mathbb{E}(X)$  heißt erstes Moment.

$\mathbb{V}(X)$  ist das zweite zentrierte Moment.

$$\mathbb{E}(X - \mathbb{E}(X)) = 0 = m_1^0(X)$$

*Bemerkung.* •  $m_3^0(X) = m_3(X) - 3m_1(X)m_2(X) + 2m_1^3(X)$  ist die Schiefe von  $X$ .

- $K := \frac{m_4(X)}{(m_2^0(X))^2}$  Kurtosis oder Wölbung von  $X$ .
- $m_{(k)} < \infty \Rightarrow m_j < \infty \quad \forall j \leq k$  (vgl Satz 3.23)

*Bemerkung.*

$$\begin{aligned}
 & X \text{ diskret} \\
 \Rightarrow m_k^0(X) &= \sum_x (x - m_1(x))^k f(x) \\
 &= \sum_x x^k f(x - m_1(x))
 \end{aligned}$$

$$\begin{aligned}
 & X \text{ stetig} \\
 \Rightarrow m_k^0(X) &= \int_{-\infty}^{\infty} (x - m_1(x))^k f(x) dx \\
 &= \int_{-\infty}^{\infty} x^k f(x - m_1(x)) dx
 \end{aligned}$$

**Definition 5.8 (symmetrische Verteilung)**

Sei  $\mathbb{P}$  Verteilung auf  $(\mathbb{R}, \mathcal{B})$ .

$\mathbb{P}$  heißt symmetrisch um  $a \in \mathbb{R}$   $\Leftrightarrow \mathbb{P}(] - \infty, a - x]) = \mathbb{P}([a + x, \infty[)$

**Satz 5.9**

Sei  $\mathbb{P}$  eine um  $a$  symmetrische Verteilung auf  $(\mathbb{R}, \mathcal{B})$ ;  $X \sim \mathbb{P}_X = \mathbb{P}$ . Dann gilt

$$i) \ g \in L(\mathbb{R}, \mathcal{B}, \mathbb{P}) \Rightarrow \int g d\mathbb{P}_X = \int g(x) d\mathbb{P}_X(x) = \int g(2a - x) d\mathbb{P}_X(x)$$

$$ii) \ m_1(X) = a$$

$$iii) \ m_{2n+1}^0(X) = 0 \quad \forall n \in \mathbb{N}.$$

*Beweis.*

$$i) \ \mathbb{P}_{X-a} = \mathbb{P}_{-(X-a)} \text{ (da } \mathbb{P} \text{ symmetrisch)}$$

$$\begin{aligned}
 \Rightarrow \mathbb{P}((X - a) \leq t) &= \mathbb{P}(X \leq a + t) \\
 &\stackrel{\text{Symmetrie}}{=} \mathbb{P}(X \geq a - t) \\
 &= \mathbb{P}(-X + a \leq t)
 \end{aligned}$$



$$\begin{aligned}
\Rightarrow \int g \circ X \, d\mathbb{P} &= \int g \, d\mathbb{P}_X &= & \mathbb{E}(g(X)) \\
& \stackrel{\text{Kreative 0}}{=} & \mathbb{E}(g(a + (X - a))) \\
& \stackrel{\text{Symmetrie}}{=} & \mathbb{E}(g(a - (X - a))) \\
& = & \mathbb{E}(g(2a - X)) \\
& = & \int g(2a - x) \, d\mathbb{P}_X(x)
\end{aligned}$$

ii)

$$\begin{aligned}
m_1(X) = \int X \, d\mathbb{P} & \stackrel{\text{Kreative 0}}{=} \frac{1}{2} \underbrace{\left[ \int X \, d\mathbb{P} + \int (2a - X) \, d\mathbb{P} \right]}_{2a} \\
& = \frac{1}{2} 2a = a
\end{aligned}$$

iii)

$$\begin{aligned}
\int (X - a)^k \, d\mathbb{P} &= \frac{1}{2} \left[ \int (X - a)^k \, d\mathbb{P} + \int (2a - X - a)^k \, d\mathbb{P} \right] \\
&= \frac{1}{2} \left[ \int (X - a)^k \, d\mathbb{P} + \int (-1)^k (X - a)^k \, d\mathbb{P} \right] \\
& \stackrel{k \text{ ungerade}}{=} \frac{1}{2} \int \dots - \frac{1}{2} \int \dots = 0
\end{aligned}$$

□

**Beispiel 5.7**

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

$$\Rightarrow m_1(X) = \mathbb{E}(X) = \mu$$

**Definition 5.10 (momenterzeugende Funktion)**

Ist  $X$  eine reelle ZV und  $\mathcal{D} := \{s \in \mathbb{R} \mid \mathbb{E}(\exp(sX)) < \infty\}$ , so heißt die Funktion

$$\begin{aligned}
M : \mathcal{D} &\rightarrow \mathbb{R} \\
s &\mapsto \mathbb{E}(\exp(sX)) = \int \exp(sx) \, d\mathbb{P}_X(x)
\end{aligned}$$

momenterzeugende Funktion.

**Satz 5.11**

Sei  $X$  eine ZV mit momenterzeugender Funktion  $M : \mathcal{D} \rightarrow \mathbb{R}$ . Ist  $] - a, a[ \subset \mathcal{D}$  für ein beliebiges  $a > 0$ , so gilt

- i)  $\mathbb{E}(X^n) < \infty$
- ii)  $M(s) = \sum_{n=0}^{\infty} \frac{s^n}{n!} \mathbb{E}(X^n)$
- iii)  $\left. \frac{\partial^n M(s)}{\partial^n s} \right|_{s=0} = \mathbb{E}(X^n)$

*Bemerkung.*

$$\exp(x) = \sum_{n=0}^{\infty} \frac{x^n}{n!}$$

*Beweis.*

$M$  momentenerzeugende Funktion

$$\begin{aligned} &\stackrel{\text{Def.}}{\Rightarrow} \mathbb{E}(\exp(sX)) < \infty \quad \forall s \in ]-a, a[ \\ &\quad \text{d.h. } \exp(sx) \text{ ist bzgl. } \mathbb{P}_X \text{ integrierbar} \\ &\Rightarrow \exp(|sx|) = \sum_{k=0}^{\infty} \frac{|sx|^k}{k!} \text{ ist bzgl. } \mathbb{P}_X \text{ integrierbar} \end{aligned}$$

Betrachte Folge von Partialsummen

$$f_n(X) = \sum_{i=0}^n \frac{(sX)^i}{i!} \xrightarrow{n \rightarrow \infty} \exp(sX)$$

$$g_n(X) = \exp(|sX|)$$

$$|f_n(X)| \leq g_n(X)$$

$$\stackrel{\text{Satz 3.14}}{\Rightarrow} \lim_{n \rightarrow \infty} \int f_n d\mathbb{P}_X = \int \lim_{n \rightarrow \infty} f_n d\mathbb{P}_X = \int \exp(sX) d\mathbb{P}_X \text{ existiert und}$$

$$\begin{aligned} M(s) &= \mathbb{E}(\exp(sX)) \\ &= \mathbb{E}(\lim_{n \rightarrow \infty} f_n) \\ &= \lim_{n \rightarrow \infty} \mathbb{E}(f_n) = \sum_{n=0}^{\infty} \frac{s^n}{n!} \mathbb{E}(X^n) \quad s \in ]-a, a[ \end{aligned}$$

Wegen der Darstellung

$$M(s) = \sum_{n=0}^{\infty} \frac{s^n}{n!} \mathbb{E}(X^n) = 0 + \frac{s}{1!} \mathbb{E}(X) + \frac{s^2}{2!} \mathbb{E}(X^2) + \frac{s^3}{3!} \mathbb{E}(X^3)$$

ist dies eine Taylorreihe der Form

$$M(s) = \sum_{n=1}^{\infty} \frac{(s-a)^n}{n!} \mathbb{E}(X^n) \left. \frac{\partial^n M(s)}{\partial^n s} \right|_{s=a}$$

$$\Rightarrow \left. \frac{\partial^n M(s)}{\partial^n s} \right|_{s=0} = \mathbb{E}(X^n)$$

□

**Beispiel 5.8 (Normalverteilung)**

$$X \sim N(0, 1)$$

$$\begin{aligned} M(s) &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} \exp(sx) \exp\left(-\frac{x^2}{2}\right) dx \\ &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} \exp\left(sx - \frac{x^2}{2}\right) dx \\ &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} \exp\left(\frac{s^2}{2} - \frac{(x-s)^2}{2}\right) dx \\ &= \frac{1}{\sqrt{2\pi}} \exp\left(\frac{s^2}{2}\right) \int_{-\infty}^{\infty} \exp\left(-\frac{(x-s)^2}{2}\right) dx \\ &\stackrel{u=x-s}{=} \frac{1}{\sqrt{2\pi}} \exp\left(\frac{s^2}{2}\right) \underbrace{\int_{-\infty}^{\infty} \exp\left(-\frac{u^2}{2}\right) du}_{\sqrt{2\pi}} \\ &= \exp\left(\frac{s^2}{2}\right) \end{aligned}$$

$$\left. \frac{\partial M(s)}{\partial s} \right|_{s=0} = s \cdot \exp\left(\frac{s^2}{2}\right) \Big|_{s=0} = 0$$

$$\left. \frac{\partial^2 M(s)}{\partial^2 s} \right|_{s=0} = s^2 \cdot \exp\left(\frac{s^2}{2}\right) + \exp\left(\frac{s^2}{2}\right) \Big|_{s=0} = 1$$

$$\Rightarrow \mathbb{E}(X) = 0$$

$$\mathbb{E}(X^2) = 1$$

$$\mathbb{V}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2 = 1$$

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

$$F_Y(y) = \Phi\left(\frac{y - \mu}{\sigma}\right)$$

$$F_X(x) = \Phi(x)$$

$\Leftrightarrow Y$  und  $\sigma X + \mu$  haben dieselbe Verteilungsfunktion

$\Leftrightarrow Y$  und  $\sigma X + \mu$  haben gleiche Verteilung:  $Y = \sigma X + \mu$

$$\Rightarrow \mathbb{E}(Y) = \mathbb{E}(\sigma X + \mu) = \sigma \mathbb{E}(X) + \mu = \mu$$

$$\begin{aligned}\Rightarrow \mathbb{E}(Y^2) &= \mathbb{E}((\sigma X + \mu)^2) \\ &= \mathbb{E}(\sigma^2 X^2 + 2\sigma X\mu + \mu^2) \\ &= \sigma^2 + \mu^2\end{aligned}$$

$$\begin{aligned}\Rightarrow \mathbb{V}(Y) &= \mathbb{E}(Y^2) - E(Y)^2 \\ &= \sigma^2 + \mu^2 - \mu^2 = \sigma^2\end{aligned}$$

# Kapitel 6

## Bedingte Wahrscheinlichkeit und Unabhängigkeit

### 6.1 Bedingte Wahrscheinlichkeit

**Definition 6.1** (bedingte W'keit)

Ist  $(\Omega, \mathcal{F}, \mathbb{P})$  ein W'keitsraum und  $\mathbb{P}(B) > 0$  für ein  $B \in \mathcal{F}$ , so heißt

$$\begin{aligned} \mathbb{P}(\cdot | B) : \mathcal{F} &\rightarrow [0, 1] \\ A &\mapsto \mathbb{P}(A | B) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)} \end{aligned}$$

die bedingte W'keitverteilung bzw. bedingte Wahrscheinlichkeit von  $A$  gegeben  $B$ .

**Satz 6.2**

$\mathbb{P}(\cdot | B)$  ist W'keitsmaß.

*Beweis.*

**M1)**  $\checkmark$

**M2)**  $\mathbb{P}(\cdot | B) \geq 0$   $\checkmark$

**M3)** Sei  $A_i, i \in \mathbb{N} \in \mathcal{F}$  disjunkt

$$\mathbb{P}\left(\bigcup_{i=1}^{\infty} A_i \mid B\right) \stackrel{!}{=} \sum_{i=1}^{\infty} \mathbb{P}(A_i | B)$$

$$\begin{aligned}
\sum_{i=1}^{\infty} \mathbb{P}(A_i | B) &= \frac{1}{\mathbb{P}(B)} \sum_{i=1}^{\infty} \mathbb{P}(A_i \cap B) \\
&\stackrel{\mathbb{P} \text{ ist W'keitsma\ss}}{=} \frac{1}{\mathbb{P}(B)} \mathbb{P}\left(\bigcup_{i=1}^{\infty} (A_i \cap B)\right) \\
&= \frac{1}{\mathbb{P}(B)} \mathbb{P}\left(\left(\bigcup_{i=1}^{\infty} A_i\right) \cap B\right) \\
&= \mathbb{P}\left(\bigcup_{i=1}^{\infty} A_i \mid B\right)
\end{aligned}$$

**Normiertheit**  $\mathbb{P}(\Omega|B) = \mathbb{P}(B)/\mathbb{P}(B) = 1$ .

□

### Satz 6.3

Sei  $(\Omega, \mathcal{F}, \mathbb{P})$  ein W'keitsraum und  $A, B \in \mathcal{F}$  sowie  $A_n \in \mathcal{F}, n \in \mathbb{N}$ . Dann gilt

$$\begin{aligned}
\text{Ist } \mathbb{P}\left(\bigcap_{i=1}^{n-1} A_i\right) > 0 &\Rightarrow \\
\mathbb{P}\left(\bigcap_{i=1}^n A_i\right) &= \mathbb{P}(A_1) \cdot \mathbb{P}(A_2 | A_1) \cdot \dots \cdot \mathbb{P}\left(A_n \mid \bigcap_{i=1}^{n-1} A_i\right)
\end{aligned}$$

*Beweis.*

vollstandige Induktion

(IA)

$$\begin{aligned}
n = 2 : \quad \mathbb{P}(A_1 \cap A_2) &= \mathbb{P}(A_1) \cdot \mathbb{P}(A_2 | A_1) \\
\Leftrightarrow \mathbb{P}(A_2 | A_1) &= \frac{\mathbb{P}(A_1 \cap A_2)}{\mathbb{P}(A_1)} \quad (\text{Def. 6.1}) \quad \checkmark
\end{aligned}$$

(IV)

$$\begin{aligned}
\mathbb{P}\left(A_n \mid \bigcap_{i=1}^{n-1} A_i\right) &= \frac{\mathbb{P}\left(\bigcap_{i=1}^n A_i\right)}{\mathbb{P}\left(\bigcap_{i=1}^{n-1} A_i\right)} \quad (\text{nach Def. 6.1}) \\
\Leftrightarrow \mathbb{P}\left(\bigcap_{i=1}^n A_i\right) &= \mathbb{P}\left(\bigcap_{i=1}^{n-1} A_i\right) \cdot \mathbb{P}\left(A_n \mid \bigcap_{i=1}^{n-1} A_i\right)
\end{aligned}$$

(IS)

$$\begin{aligned}
\mathbb{P}\left(\bigcap_{i=1}^{n+1} A_i\right) &= \mathbb{P}\left(\left(\bigcap_{i=1}^n A_i\right) \cap A_{n+1}\right) \\
&\stackrel{\text{(IA)}}{=} \mathbb{P}\left(A_{n+1} \mid \bigcap_{i=1}^n A_i\right) \cdot \underbrace{\mathbb{P}\left(\bigcap_{i=1}^n A_i\right)} \\
&\stackrel{\text{(IA)}}{=} \mathbb{P}\left(A_{n+1} \mid \bigcap_{i=1}^n A_i\right) \cdot \mathbb{P}(A_1) \cdot \mathbb{P}(A_2 \mid A_1) \cdot \dots \cdot \mathbb{P}\left(A_n \mid \bigcap_{i=1}^{n-1} A_i\right) \quad \checkmark
\end{aligned}$$

□

**Satz 6.4 (Satz von der totalen Wahrscheinlichkeit)**

Sei  $(\Omega, \mathcal{F}, \mathbb{P})$  W'keitsraum. Sei  $\dot{\bigcup}_{i=1}^{\infty} A_i = \Omega$  eine disjunkte Zerlegung von  $\Omega$  mit  $\mathbb{P}(A_i) > 0 \quad \forall i \in \mathbb{N}$ . Dann gilt

$$\mathbb{P}(A) = \sum_{i=1}^{\infty} \mathbb{P}(A_i) \cdot \mathbb{P}(A \mid A_i) \quad \forall A \in \mathcal{F}.$$

*Beweis.*

$$\begin{aligned}
A &= \dot{\bigcup}_{i=1}^{\infty} A_i \cap A \\
\Rightarrow \mathbb{P}(A) &= \mathbb{P}\left(\dot{\bigcup}_{i=1}^{\infty} (A_i \cap A)\right) = \sum_{i=1}^{\infty} \mathbb{P}(A_i \cap A) = \sum_{i=1}^{\infty} \mathbb{P}(A_i) \cdot \mathbb{P}(A \mid A_i)
\end{aligned}$$

□

**Satz 6.5 (Satz von Bayes)**

Sei  $(\Omega, \mathcal{F}, \mathbb{P})$  W'keitsraum mit  $\dot{\bigcup}_{i=1}^{\infty} A_i = \Omega$  einer disjunkten Zerlegung von  $\Omega$  mit  $\mathbb{P}(A_i) > 0 \quad \forall i \in \mathbb{N}$  und  $B \in \mathcal{F}$  mit  $\mathbb{P}(B) > 0$ . Dann gilt

$$\mathbb{P}(A_i \mid B) = \frac{\mathbb{P}(B \mid A_i) \mathbb{P}(A_i)}{\sum_{i=1}^{\infty} \mathbb{P}(A_i) \mathbb{P}(B \mid A_i)}$$

*Beweis.*

$$\begin{aligned}
\mathbb{P}(B) &= \sum_{i=1}^{\infty} \mathbb{P}(A_i) \cdot \mathbb{P}(B \mid A_i) \quad (\text{totale W'keit}) \\
\Rightarrow \mathbb{P}(A_i \mid B) &= \frac{\mathbb{P}(B \mid A_i) \cdot \mathbb{P}(A_i)}{\mathbb{P}(B)} = \frac{\mathbb{P}(A_i \cap B)}{\underbrace{\mathbb{P}(B)}_{= \sum \mathbb{P}(A_i) \dots}} \quad (\text{Def. 6.1})
\end{aligned}$$

□

**Beispiel 6.1**

Population von  $n$  Personen.

$(\Omega = \{1, \dots, n\}, \mathcal{P}(\Omega), U)$  Gleichverteilung  $U(\{\omega\}) = \frac{1}{n}$

$K = \{1, \dots, 0.02 \times n\}$  Kranke

$G = \{0.02 \times n + 1, \dots, n\}$  Gesunde

$$\mathbb{P}(K) = 0.02$$

$$\mathbb{P}(G) = \mathbb{P}(\bar{K}) = 1 - 0.02 = 0.98$$

$P \dots$  Test positiv,  $N \dots$  Test negativ mit

$$\mathbb{P}(P | K) = 0.95$$

$$\mathbb{P}(P | G) = 0.1$$

$$\mathbb{P}(K | P) = \frac{\mathbb{P}(P | K) \cdot \mathbb{P}(K)}{\underbrace{\mathbb{P}(P | K) \cdot \mathbb{P}(K) + \mathbb{P}(P | G) \cdot \mathbb{P}(G)}_{= \mathbb{P}(P)}} = 16.2\%$$

$$\mathbb{P}(G | P) = 83.8\%$$

*Bemerkung.* Die Definitionen übertragen sich auf Zufallsvariablen, also z.B.

$$\begin{aligned} \mathbb{P}(X > t | X > 0) &= \frac{\mathbb{P}(X > t, X > 0)}{\mathbb{P}(X > 0)} \\ &= \frac{\mathbb{P}(\{\omega \in \Omega | X(\omega) > t \wedge X(\omega) > 0\})}{\mathbb{P}(\{\omega \in \Omega | X(\omega) > 0\})} \end{aligned}$$

**Beispiel 6.2 (Gedächtnislosigkeit der Exponentialverteilung)**

$X \sim \text{Exp}(\lambda)$

$$\mathbb{P}(X > t + s | X > t) = \mathbb{P}(X > s)$$

$$\text{denn: } \mathbb{P}(X > t) = 1 - \mathbb{P}(X \leq t) = 1 - F_X(t) = 1 - (1 - \exp(-\lambda t)) = \exp(-\lambda t) \quad \forall t \geq 0$$

$$\Rightarrow \forall s, t \geq 0$$



$$\begin{aligned}
\mathbb{P}(X > t + s | X > t) &= \frac{\mathbb{P}(X > t + s)}{\mathbb{P}(X > t)} \\
&= \frac{\exp(-\lambda(t + s))}{\exp(-\lambda t)} \\
&= \frac{\exp(-\lambda t) \cdot \exp(-\lambda s)}{\exp(-\lambda t)} \\
&= \exp(-\lambda s) = \mathbb{P}(X > s)
\end{aligned}$$

## 6.2 Unabhängigkeit

### Definition 6.6 (Unabhängigkeit von Ereignissen)

Ereignisse  $A_i \in \mathcal{F}, i \in I \neq \emptyset$ , eines W'keitsraumes  $(\Omega, \mathcal{F}, \mathbb{P})$  heißen stochastisch unabhängig (stu), wenn für jede endliche Teilmenge  $\emptyset \neq J \subset I$  gilt

$$\mathbb{P}\left(\bigcap_{j \in J} A_j\right) = \prod_{j \in J} \mathbb{P}(A_j)$$

*Bemerkung.* Insbesondere  $\mathbb{P}(A \cap B) = \mathbb{P}(A) \cdot \mathbb{P}(B)$  für  $A, B \in \mathcal{F}$ .

### Satz 6.7

- a)  $A, B$  stu,  $\mathbb{P}(B) > 0 \Rightarrow \mathbb{P}(A | B) = \mathbb{P}(A)$
- b)  $A, B$  stu  $\Rightarrow A, \bar{B}$  stu.

*Beweis.*

$$\text{a) } \mathbb{P}(A | B) = \frac{\mathbb{P}(A \cap B)}{\mathbb{P}(B)} \stackrel{\text{stu}}{=} \frac{\mathbb{P}(A) \cdot \mathbb{P}(B)}{\mathbb{P}(B)} = \mathbb{P}(A)$$

b)

$$\begin{aligned}
\mathbb{P}(A) \cdot \mathbb{P}(B) &= \mathbb{P}(A \cap B) \\
\Leftrightarrow \mathbb{P}(A) \cdot (1 - \mathbb{P}(\bar{B})) &= \mathbb{P}(A \cap B) \\
\Leftrightarrow \mathbb{P}(A) - \mathbb{P}(A) \cdot \mathbb{P}(\bar{B}) &= \mathbb{P}(A \cap B) \\
\Leftrightarrow \mathbb{P}(A \cap B) + \mathbb{P}(A \cap \bar{B}) - \mathbb{P}(A) \cdot \mathbb{P}(\bar{B}) &= \mathbb{P}(A \cap B) \quad | - \mathbb{P}(A \cap B) \\
\Leftrightarrow \mathbb{P}(A \cap \bar{B}) &= \mathbb{P}(A) \cdot \mathbb{P}(\bar{B})
\end{aligned}$$

□

**Satz 6.8 (Borel-Cantelli-Lemma)**

Sei  $(\Omega, \mathcal{F}, \mathbb{P})$  W'keitsraum und  $A_i, i \in \mathbb{N}$ , eine Folge von Ereignissen mit  $A_i \in \mathcal{F}$ .

Ist  $\sum_{i=1}^{\infty} \mathbb{P}(A_i) < \infty$ , so folgt

$$\text{a) } \mathbb{P}(\limsup A_i) = 0$$

Sind die  $A_i$  stu und  $\sum_{i=1}^{\infty} \mathbb{P}(A_i) = \infty$ , so folgt

$$\text{b) } \mathbb{P}(\limsup A_i) = 1$$

*Beweis.*

a) Sei  $B_n := \bigcup_{i \geq n} A_i, n \in \mathbb{N}$ .  $B_n \downarrow \limsup A_i$  und somit

$$\mathbb{P}(\limsup A_i) = \lim_{n \rightarrow \infty} \mathbb{P}(B_n) = \lim_{n \rightarrow \infty} \mathbb{P}\left(\bigcup_{i \geq n} A_i\right) \leq \lim_{n \rightarrow \infty} \underbrace{\sum_{i \geq n} \mathbb{P}(A_i)}_{\rightarrow 0 \text{ für } n \rightarrow \infty} = 0$$

b)  $1 - x \leq \exp(-x) \quad \forall x \in \mathbb{R}$

Damit

$$\begin{aligned} 0 \leq \mathbb{P}\left(\bigcap_{n \leq i \leq m} \bar{A}_i\right) &\stackrel{\text{stu}}{=} \prod_{n \leq i \leq m} (1 - \mathbb{P}(A_i)) \\ &\leq \prod_{n \leq i \leq m} \exp(-\mathbb{P}(A_i)) \\ &= \underbrace{\exp\left(-\underbrace{\sum_{n \leq i \leq m} \mathbb{P}(A_i)}_{=\infty}\right)}_{=0 \text{ für } m \rightarrow \infty} \rightarrow 0 \end{aligned}$$

$$\Rightarrow \mathbb{P}(\overline{\limsup A_i}) = \mathbb{P}\left(\bigcup_{n=1}^{\infty} \bigcap_{i \geq n} \bar{A}_i\right) \leq \sum_{n=1}^{\infty} \underbrace{\mathbb{P}\left(\bigcap_{i \geq n} \bar{A}_i\right)}_{=0} = 0$$

$$\Rightarrow \mathbb{P}(\limsup A_i) = 1$$

□

# Kapitel 7

## Mehrdimensionale Verteilungen

### 7.1 Mehrdimensionale Verteilungen

**Definition 7.1** (*n*-dimensionale ZV, Verteilungsfunktion)

Sei  $(\Omega, \mathcal{F}, \mathbb{P})$  ein Wahrscheinlichkeitsraum und  $X : \Omega \rightarrow \mathbb{R}^n$  eine *n*-dimensionale reelle ZV,  $X = (X_1, \dots, X_n)$ . Dann heißt die Funktion

$$\begin{aligned} F_X : \mathbb{R}^n &\rightarrow [0, 1] \\ x = (x_1, \dots, x_n) &\mapsto \mathbb{P}(X \leq x) \\ &= \mathbb{P}(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n) \\ &= \mathbb{P}(\{\omega \in \Omega \mid X_i(\omega) \leq x_i \forall i = 1, \dots, n\}) \end{aligned}$$

die *n*-dimensionale Verteilungsfunktion von  $X$ .

*Bemerkung.* Es gilt

- i)  $F_X(x)$  ist monoton wachsend in jeder Komponente von  $x$ .
- ii)  $F_X(x)$  ist rechtsstetig

$$\lim_{h \downarrow 0} F_X(x + h) = F_X(x) \quad \forall x \in \mathbb{R}^n$$

- iii)  $\lim_{x_k \rightarrow -\infty} F_X(x) = 0, \lim_{h \rightarrow \infty} F_X(x + h) = 1$   
für alle  $k \in \{1, \dots, n\}$ .

**Satz 7.2**

$X, Y$  *n*-dimensionale ZV,  $X \sim F_X, Y \sim F_Y$ .

$$F_X = F_Y \Rightarrow \mathbb{P}_X = \mathbb{P}_Y.$$

*Beweis.*

Satz 4.30 [Meintrup and Schäffler \(2005\)](#)

□

*Bemerkung.* Wahrscheinlichkeitsmaße auf  $\mathbb{R}^n$  sind durch die zugehörigen  $n$ -dimensionalen Verteilungsfunktionen vollständig definiert.

*Bemerkung.*  $(\mathbb{R}^n, \mathcal{B}^n, \mathbb{P} = f \odot \lambda^n)$  mit ZV  $X(\omega) = \omega \in \mathbb{R}^n$

$$\begin{aligned} \Rightarrow \mathbb{P}_X([a, b]) &= \int f I_{[a, b]} d\lambda^n \\ &\stackrel{\text{f Riemann-integrierbar, Fubini}}{=} \int_{a_1}^{b_1} \dots \int_{a_n}^{b_n} f(x_1, \dots, x_n) dx_n dx_{n-1} \dots dx_1 \end{aligned}$$

### Satz 7.3

Sei  $X : \Omega \rightarrow \mathbb{R}^n$  eine  $n$ -dimensionale ZV und  $g : \mathbb{R}^n \rightarrow \mathbb{R}^k$   $\mathcal{B}^n$ - $\mathcal{B}^k$ -meßbar (Baire-Funktion). Dann ist

$$g \circ X : \Omega \rightarrow \mathbb{R}^k, \quad \omega \mapsto g(X(\omega))$$

eine  $k$ -dimensionale reelle ZV mit Verteilung

$$\mathbb{P}_{g(X)}(A) = \mathbb{P}(g(X) \in A) = \mathbb{P}(\{\omega \in \Omega \mid g(X(\omega)) \in A\})$$

*Beweis.*

Satz 2.17 (Meßbarkeit der Komposition) □

### Definition 7.4 (Randverteilung)

Ist  $g : \mathbb{R}^n \rightarrow \mathbb{R}$  mit  $g(x) = x_j$  für ein festes  $j \in \{1, \dots, n\}$  (Projektion auf  $j$ -te Koordinate), so gilt:

$$\begin{aligned} g(X) &= X_j \\ \mathbb{P}_{X_j}(A) &= \mathbb{P}_X(\{x \in \mathbb{R}^n : x_j \in A\}) = \mathbb{P}(X_j \in A) \text{ für } A \in \mathcal{B} \end{aligned}$$

$\mathbb{P}_{X_j}$  heißt Randverteilung oder marginale Verteilung von  $X_j$ .

*Bemerkung.* Besitzt  $X$  die Dichte  $f$ , so hat  $X_j$  die Dichte

$$\begin{aligned} f_j : \mathbb{R} &\rightarrow \mathbb{R} \\ y &\mapsto \int \dots \int f(x_1, x_2, \dots, x_{j-1}, y, x_{j+1}, \dots, x_n) d\nu(x_n) \dots d\nu(x_{j+1}) d\nu(x_{j-1}) \dots d\nu(x_1) \end{aligned}$$

mit  $\nu = \lambda$  oder  $\nu = \mu_Z$

$f_j$  heißt Randdichte von  $X_j$ .

## 7.2 Transformationssatz für Dichten

### Satz 7.5

Sei  $X : \Omega \rightarrow \mathbb{R}$  ZV mit stetiger Verteilungsfunktion  $F_X$  und Dichte  $f_X(x) = \frac{\partial F_X(x)}{\partial x}$  bezüglich des Lebesgue-Maßes  $\lambda$ . Weiterhin sei  $g : \mathbb{R} \rightarrow \mathbb{R}$  bijektiv und stetig differenzierbar,

$$\frac{\partial g(x)}{\partial x} \neq 0 \text{ mit } h = g^{-1}.$$

$$\Rightarrow g \circ X \text{ hat Dichte } f_{g \circ X}(y) = f_X(h(y)) \cdot \left| \frac{\partial h(y)}{\partial y} \right| \text{ bezüglich } \lambda.$$

*Beweis.*

Fallunterscheidung:

$$\text{(A) } h \text{ monoton wachsend: } \frac{\partial h(y)}{\partial y} > 0$$

$$\text{(B) } h \text{ monoton fallend: } \frac{\partial h(y)}{\partial y} < 0$$

(A)

$$\begin{aligned} F_{g \circ X}(y) &= \mathbb{P}(g \circ X \leq y) \\ &= \mathbb{P}(X \leq g^{-1}(y)) \quad (h = g^{-1} \text{ monoton wachsend}) \\ &= \mathbb{P}(X \leq h(y)) = F_X(h(y)) \end{aligned}$$

$$f_{g \circ X}(y) = \frac{\partial F_{g \circ X}(y)}{\partial y} = \frac{\partial F_X(h(y))}{\partial y} = f_X(h(y)) \cdot \underbrace{\frac{\partial h(y)}{\partial y}}_{\geq 0}$$

(B)

$$\begin{aligned} F_{g \circ X}(y) &= \mathbb{P}(g \circ X \leq y) \\ &= \mathbb{P}(X \geq g^{-1}(y)) \quad (h = g^{-1} \text{ monoton fallend}) \\ &= \mathbb{P}(X \geq h(y)) \\ &\stackrel{X \text{ stetig}}{=} \mathbb{P}(X > h(y)) \\ &= 1 - F_X(h(y)) \end{aligned}$$

$$\Rightarrow f_{g \circ X}(y) = \frac{\partial F_{g \circ X}(y)}{\partial y} = 0 - f_X(h(y)) \cdot \underbrace{\frac{\partial h(y)}{\partial y}}_{\leq 0}$$

zusammen (A) und (B):

$$f_{g \circ X}(y) = f_X(h(y)) \cdot \left| \frac{\partial h(y)}{\partial y} \right|$$

□

**Beispiel 7.1**

$X \sim \text{Exp}(\lambda)$       Gesucht: Verteilung von  $X^2$

$$g(x) = x^2$$

$$h(y) = g^{-1}(y) = \sqrt{y} \quad (\text{da } f_X(x) = 0 \text{ für } x \leq 0 \text{ keine Fallunterscheidung nötig})$$

$$\frac{\partial h(y)}{\partial y} = \frac{1}{2\sqrt{y}}$$

$$\begin{aligned} f_{X^2}(y) &= f_X(\sqrt{y}) \cdot \frac{1}{2\sqrt{y}} \\ &= \lambda \exp(-\lambda \sqrt{y}) \cdot \frac{1}{2\sqrt{y}} \cdot I_{[0, \infty[}(\sqrt{y}) \end{aligned}$$

$$F_{X^2}(x) = \int_0^x f_{X^2}(y) dy$$

**Satz 7.6 (Trafo für injektive  $g$ )**

Sei  $X : \Omega \rightarrow \mathbb{R}$  mit Verteilungsfunktion  $F_X$  und stetiger Dichte  $f_X$  sowie  $g : \mathbb{R} \rightarrow \mathbb{R}$  eine Baire-Funktion. Sei  $\mathbb{R} \supset I = \bigcup_{m \in M} I_m$  eine disjunktive Vereinigung offener Intervalle

( $I_m = ]a_m, b_m[$ ) derart, daß gilt:

- a)  $F_X$  ist stetig differenzierbar auf  $I$ :

$$f_X(x) = \frac{\partial F_X(x)}{\partial x}$$

- b)  $\mathbb{P}(X \in I) = 1$

- c) Sei  $g_m = g|_{I_m}$ ;  $g_m : I_m \rightarrow \mathbb{R}$  die Einschränkung von  $g$  auf  $I_m$  mit

- 1)  $g_m$  ist stetig differenzierbar und bijektiv

- 2)  $\frac{\partial g_m(x)}{\partial x} \neq 0$

Dann gilt:  $g \circ X$  hat die Dichte

$$f_{g \circ X}(y) = \sum_{m \in M} v_m(y)$$

$$\text{wobei } v_m(y) = \begin{cases} f_X(h_m(y)) \cdot \left| \frac{\partial h_m(y)}{\partial y} \right| & y \in g(I_m) \\ 0 & \text{sonst} \end{cases}$$

und  $h_m = g_m^{-1}$

*Beweis.*

Sei  $V_m(y) := \mathbb{P}(X \in I_m, g \circ X \leq y)$  die gemeinsame Verteilungsfunktion der Indikatorfunktion  $I_{I_m} \circ X$  und der Komposition  $g \circ X$ .

Zu zeigen:

$$V_m \text{ ist Stammfunktion von } v_m \iff v_m \text{ ist Dichte von } V_m$$

Fallunterscheidung:

$$(A) \quad \frac{\partial h_m(x)}{\partial x} > 0 \quad \forall x \in I_m = ]a_m, b_m[$$

$$(B) \quad \frac{\partial h_m(x)}{\partial x} < 0 \quad \forall x \in I_m = ]a_m, b_m[$$

(A)

$$\begin{aligned} V_m(y) &= \mathbb{P}(a_m \leq X \leq b_m, g_m \circ X \leq y) \\ &= \mathbb{P}(a_m \leq X \leq b_m, X \leq h_m(y)) \\ &= \mathbb{P}(a_m \leq X \leq h_m(y)) \quad \text{weil } h_m(t) \in I_m \Rightarrow h_m(t) \leq b_m \\ &= F_X(h_m(y)) - F_X(a_m) \end{aligned}$$

$$\Rightarrow \frac{\partial V_m(y)}{\partial y} = f_X(h_m(y)) \cdot \underbrace{\frac{\partial h_m(y)}{\partial y}}_{>0} = v_m(y)$$

(B) analog, zusammen folgt Form von  $v_m(y)$

$$\Rightarrow V_m(y) = \int_{-\infty}^y v_m(t) dt$$

Bleibt zu zeigen:  $f_{g \circ X}$  ist Dichte von  $F_{g \circ X}$

$$\begin{aligned}
 \int_{-\infty}^y f_{g \circ X}(t) dt &= \int_{-\infty}^y \sum_{m \in M} v_m(t) dt \\
 &\stackrel{\text{Linearität}}{=} \sum_{m \in M} \underbrace{\int_{-\infty}^y v_m(t) dt}_{V_m(y)} \\
 &= \sum_{m \in M} \mathbb{P}(X \in I_m, g \circ X \leq y) \\
 &\stackrel{I = \dot{\bigcup}_m I_m, \mathbb{R} = I \dot{\cup} \bar{I}}{=} \mathbb{P}(X \in I, g \circ X \leq y) + \underbrace{\mathbb{P}(X \notin I, g \circ X \leq y)}_{=0 \text{ nach Voraussetzung}} \\
 &= \mathbb{P}(X \in I, g \circ X \leq y) \\
 &= \mathbb{P}(g \circ X \leq y) = F_{g \circ X}(y)
 \end{aligned}$$

□

### Beispiel 7.2

$X \sim N(0, 1)$ . Gesucht:  $f_{X^2}$

$$g(x) = x^2$$

$$I_1 = ]-\infty, 0[$$

$$I_2 = ]0, \infty[$$

$$g_1 = g|_{I_1} \Rightarrow h_1(y) = -\sqrt{y}$$

$$g_2 = g|_{I_2} \Rightarrow h_2(y) = \sqrt{y}$$

$$\left| \frac{\partial h_i(y)}{\partial y} \right| = \frac{1}{2\sqrt{y}} \quad i = 1, 2$$

Fallunterscheidung:



$$\begin{aligned}
y < 0: \quad f_{X^2}(y) &= 0 \\
y > 0: \quad f_{X^2}(y) &= \underbrace{f_X(\sqrt{y}) \cdot \frac{1}{2\sqrt{y}}}_{v_2(y)} + \underbrace{f_X(-\sqrt{y}) \cdot \frac{1}{2\sqrt{y}}}_{v_1(y)} \\
&= \frac{1}{2\sqrt{y}} \left( \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{y}{2}\right) + \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{y}{2}\right) \right) \\
&= \frac{1}{\sqrt{2\pi}} \frac{1}{2\sqrt{y}} \left( 2 \cdot \exp\left(-\frac{y}{2}\right) \right) \\
&= \frac{1}{\sqrt{2\pi y}} \exp\left(-\frac{y}{2}\right) \\
&\hat{=} \text{Dichte der } \chi^2\text{-Verteilung mit einem Freiheitsgrad.}
\end{aligned}$$

**Satz 7.7 (Verallgemeinerungen auf den  $n$ -dimensionalen Fall)**

Sei  $X : \Omega \rightarrow \mathbb{R}^n$  ZV mit Dichte  $f_X$  bzgl.  $\lambda^n$ .

Sei  $g : \mathbb{R}^n \rightarrow \mathbb{R}^n$  Baire-Funktion.

Ferner sei  $G_m \in \mathcal{B}^n, m \in M$  derart, daß

$$\text{i) } \mathbb{P} \left( X \in \bigcup_{m \in M} G_m \right) = 1$$

ii)  $g_m := g|_{G_m}$  bijektiv und stetig differenzierbar.

$$\text{Sei } H_m(y) = \underbrace{\left( \frac{\partial h_m(y)}{\partial y_1 \partial y_2 \cdots \partial y_n} \right)}_{=: J \text{ Jacobi-Matrix von } h_m} \text{ und } h_m = g_m^{-1}.$$

Dann gilt

$$f_{g \circ X}(y) = \sum_{m \in M} v_m(y)$$

$$\text{mit } v_m(y) = \begin{cases} f_X(h_m(y)) \cdot |\det(H_m(y))| & \text{falls } h_m(y) \in G_m \\ 0 & \text{sonst} \end{cases}$$

*Beweis.*

geschenkt. □

**Beispiel 7.3**

Sei  $X = (X_1, X_2)$  eine zwei-dimensionale ZV mit Dichte  $f_X$  bzgl.  $\lambda^2$ . Gesucht ist  $f_{X_1+X_2}$ .

$$g(x_1, x_2) = (X_1 + X_2, X_2) \in \mathbb{R}^2$$

$\Rightarrow g$  bijektiv und damit

$$\begin{aligned} h(y) &= g^{-1}(y_1, y_2) = (y_1 - y_2, y_2) \\ g \circ X &= \underbrace{(X_1 + X_2, X_2)}_{=Y} \\ \det H &= \det \left( \frac{\partial g^{-1}}{\partial y} \right) = \det \begin{pmatrix} \frac{\partial y_1 - y_2}{\partial y_1} & \frac{\partial y_1 - y_2}{\partial y_2} \\ \frac{\partial y_2}{\partial y_1} & \frac{\partial y_2}{\partial y_2} \end{pmatrix} \\ &= \det \begin{pmatrix} 1 & -1 \\ 0 & 1 \end{pmatrix} = 1 \end{aligned}$$

Trafo  
 $\Rightarrow$

$$f_{Y, X_2}(y, x_2) = f_X(y_1 - x_2, x_2) \cdot 1$$

$\Rightarrow$

$$\begin{aligned} f_Y(y) &\stackrel{\text{Randdichte}}{=} \int f_{Y, X_2}(y, x_2) dx_2 \quad (\text{Bemerkung zu Definition 7.4}) \\ &\stackrel{x_1 = y - x_2}{=} \int f_X(y - x_2, x_2) dx_2 \quad \text{''Faltungsformel''} \end{aligned}$$

Falls  $X_1$  und  $X_2$  stu:

$$f_X(x_1, x_2) = f_{X_1}(x_1) \cdot f_{X_2}(x_2) \quad (\text{kommt noch!})$$

und damit

$$f_Y(y) = \int f_{X_1}(y - x_2) \cdot f_{X_2}(x_2) dx_2$$

### Beispiel 7.4

$X_1 \sim N(0, 1)$ ,  $X_2 \sim N(0, 1)$  stu.

$$Y_1 := \frac{X_2}{X_1} \quad Y_2 := X_1$$

$$g(x_1, x_2) = \begin{pmatrix} \frac{x_2}{x_1} \\ x_1 \end{pmatrix}$$

$$g^{-1}(y_1, y_2) = (y_2, y_1 y_2)$$

$$\det J = \det \begin{pmatrix} 0 & 1 \\ y_2 & y_1 \end{pmatrix} = -y_2$$

$$\begin{aligned} f_{Y_1, Y_2}(y_1, y_2) &= f_{X_1}(y_2) \stackrel{\text{stu}}{\cdot} f_{X_2}(y_1 y_2) \cdot |\det J| \\ &= |-y_2| \cdot \frac{1}{2\pi} \exp\left(-\frac{1}{2} (y_2^2 + (y_1 y_2)^2)\right) \\ &= |y_2| \cdot \frac{1}{2\pi} \exp\left(-\frac{1}{2} (y_2^2 \cdot (1 + y_1^2))\right) \end{aligned}$$

Randverteilung von  $Y_1$ :

$$\begin{aligned}
 f_{Y_1}(y_1) &= \int_{-\infty}^{\infty} f_{Y_1, Y_2}(y_1, y_2) dy_2 \\
 &\stackrel{\text{Symmetrie}}{=} 2 \cdot \int_0^{\infty} \frac{1}{2\pi} \cdot \exp\left(-\frac{1}{2} y_2^2 (1 + y_1^2)\right) \cdot y_2 dy_2 \\
 &= \frac{1}{\pi} \cdot \int_0^{\infty} \exp\left(-\frac{1}{2} y_2^2 (1 + y_1^2)\right) \cdot y_2 dy_2 \\
 &\stackrel{\text{Stammfkt. bilden}}{=} \frac{1}{\pi} \cdot \left[ \exp\left(-\frac{1}{2} y_2^2 (1 + y_1^2)\right) \cdot \frac{-1}{1 + y_1^2} \right]_{y_2=0}^{\infty} \\
 &= \frac{1}{\pi} \cdot \frac{-1}{1 + y_1^2} \cdot \underbrace{\left[ \exp\left(-\frac{1}{2} y_2^2 (1 + y_1^2)\right) \right]_{y_2=0}^{\infty}}_{=-1} \\
 &= \frac{1}{\pi} \cdot \frac{1}{1 + y_1^2} \cong \text{Cauchy-Verteilung}
 \end{aligned}$$

**Augustin Louis Cauchy (21. August 1789 bis 23. Mai 1857)** war ein französischer Mathematiker. Jede Kurzfassung seines Lebenswerkes muß scheitern, deshalb sei an dieser Stelle auf

[http://de.wikipedia.org/wiki/Augustin\\_Louis\\_Cauchy](http://de.wikipedia.org/wiki/Augustin_Louis_Cauchy) verwiesen.

## 7.3 Unabhängigkeit von Zufallsvariablen

### Definition 7.8

- i) Eine Familie von Mengensystemen  $\mathcal{F}_i \subset \mathcal{F}$ ,  $i \in I \neq \emptyset$ , heißt stochastisch unabhängig, wenn dies für jede Familie von Ereignissen  $A_i \in \mathcal{F}_i$ ,  $i \in I$ , für alle  $i \in I$  gilt. Vgl. Definition 6.6
- ii) Eine Familie von Zufallsvariablen  $X_i : \Omega \rightarrow \Omega_i$ , auf einem W'keitsraum  $(\Omega, \mathcal{F}, \mathbb{P})$  heißt stochastisch unabhängig, wenn dies für die Familie der von den Zufallsvariablen  $X_i$  erzeugten  $\sigma$ -Algebra

$$\sigma(X_i) = \sigma(X_i^{-1}(\mathcal{F}_i)) \quad i \in I$$

gilt.

*Bemerkung.*

$$\sigma(X_i^{-1}(\mathcal{F}_i)) \stackrel{\text{Satz 2.12}}{=} \underbrace{X_i^{-1}(\mathcal{F}_i)}_{X_i \text{ ist ZV, also } \mathcal{F}\text{-}\mathcal{F}_i\text{-meßbar}} \subset \mathcal{F}$$

*Bemerkung.*  $X_1, \dots, X_n$  sind reelle ZV auf  $(\mathbb{R}, \mathcal{B}, \mathbb{P})$ . Dann gilt:

$$X_1, \dots, X_n \text{ stu} \Leftrightarrow \mathbb{P}(X_1 \in B_1, \dots, X_n \in B_n) = \prod_{i=1}^n \mathbb{P}(X_i \in B_i) \quad \forall B_i \in \mathcal{B}$$

denn  $\sigma(X_i) = X_i^{-1}(\mathcal{B}) \subset \mathcal{B}$  und nach Definition 7.8 muß obige Gleichung für alle möglichen Ereignisse  $B_i$  gelten.

### Satz 7.9

Ist  $X = (X_1, \dots, X_n)$  reelle  $n$ -dimensionale ZV, so sind  $X_1, \dots, X_n$  stu  $\Leftrightarrow \forall c \in \mathbb{R}^n$  gilt

$$\begin{aligned} \mathbb{P}(X \leq c) &= \mathbb{P}(X_1 \leq c_1, \dots, X_n \leq c_n) \\ &= \prod_{i=1}^n \mathbb{P}(X_i \leq c_i) \\ \text{bzw. } F_X(c) &= \prod_{i=1}^n F_{X_i}(c_i) \end{aligned}$$

Ist  $X$  diskret, so gilt:  $X_1, \dots, X_n$  stu  $\Leftrightarrow \forall x \in T_1 \times T_2 \times \dots \times T_n$  ( $T_i$  Träger von  $X_i$ ) gilt

$$\mathbb{P}(X_1 = x_1, \dots, X_n = x_n) = \prod_{i=1}^n \mathbb{P}(X_i = x_i)$$

*Beweis.*

$X$  diskret

$$\begin{aligned} \mathbb{P}(X_1 \leq c_1, \dots, X_n \leq c_n) &= \sum_{X_1 \in T_1, x_1 \leq c_1} \cdots \sum_{X_n \in T_n, x_n \leq c_n} \mathbb{P}(X_1 = x_1, \dots, X_n = x_n) \\ &= \sum_{x_1 \leq c_1} \cdots \sum_{x_n \leq c_n} \prod_{i=1}^n \mathbb{P}(X_i = x_i) \\ &= \left( \sum_{x_1 \leq c_1} \mathbb{P}(X_1 = x_1) \right) \cdots \left( \sum_{x_n \leq c_n} \mathbb{P}(X_n = x_n) \right) \\ &= \mathbb{P}(X_1 \leq c_1) \cdots \mathbb{P}(X_n \leq c_n) \end{aligned}$$

$X$  stetig: Weise die Unabhängigkeit der Mengensysteme  $\{\omega \in \Omega \mid X_i(\omega) \leq c, c \in \mathbb{R}\}$  nach und nutze  $\{]-\infty, c] \mid c \in \mathbb{R}\}$  als durchschnittsstabilen Erzeuger von  $\mathcal{B}$ . Details Satz 5.9/5.10 Meintrup and Schäffler (2005).  $\square$

**Satz 7.10**

Sind  $X_1, \dots, X_n$  reelle unabhängige ZV mit Dichten  $f_{X_1}, \dots, f_{X_n}$  bzgl.  $\lambda$ , dann und genau dann ist die gemeinsame Dichte von  $X = (X_1, \dots, X_n)$  das Produkt der einzelnen Dichten, d.h.

$$f_X(x) = \prod_{i=1}^n f_{X_i}(x_i)$$

ist Dichte bzgl.  $\lambda^n$ .

*Beweis.*

Sei  $F_X$  die Verteilungsfunktion von  $X$ . Dann folgt

$$\begin{aligned} F_X(c) &= \mathbb{P}(X_1 \leq c_1, \dots, X_n \leq c_n) \\ &= \prod_{i=1}^n \mathbb{P}(X_i \leq c_i) \\ &= \int_{-\infty}^{c_1} f_{X_1}(x_1) dx_1 \int_{-\infty}^{c_2} f_{X_2}(x_2) dx_2 \cdots \int_{-\infty}^{c_n} f_{X_n}(x_n) dx_n \\ &\stackrel{\text{Fubini}}{=} \int_{-\infty}^{c_1} \cdots \int_{-\infty}^{c_n} f_{X_1}(x_1) \cdots f_{X_n}(x_n) dx_n \cdots dx_1 \\ &= \underbrace{\int_{-\infty}^c f_X(x) dx}_{n\text{-dimensionales Integral}} \end{aligned}$$

□

**Satz 7.11**

Seien  $X_1 : \Omega \rightarrow \mathbb{R}^{n_1}$  und  $X_2 : \Omega \rightarrow \mathbb{R}^{n_2}$  zwei  $n_i$ -dimensionale stochastisch unabhängige Zufallsvariablen ( $i = 1, 2$ ) und  $h_i : \mathbb{R}^{n_i} \rightarrow \mathbb{R}^{m_i}$  Baire-Funktionen.

$$\Rightarrow Y_1 = h_1 \circ X_1 \text{ und } Y_2 = h_2 \circ X_2 \text{ stu.}$$

*Beweis.*

Nach Voraussetzung gilt

$$\sigma(X_1) = X_1^{-1}(\mathcal{B}^{n_1}) \quad \text{und} \quad \sigma(X_2) = X_2^{-1}(\mathcal{B}^{n_2}) \quad \text{stu.}$$

z.Z.

$$Y_1^{-1}(\mathcal{B}^{m_1}) \quad \text{und} \quad Y_2^{-1}(\mathcal{B}^{m_2}) \quad \text{stu.}$$

$$\begin{aligned}
Y_i^{-1}(\mathcal{B}^{m_i}) &= (h_i \circ X_i)^{-1}(\mathcal{B}^{m_i}) \\
&= X_i^{-1}\left(\underbrace{h_i^{-1}(\mathcal{B}^{m_i})}_{\subset \mathcal{B}^{n_i} \text{ da } h \text{ Baire-Funktion}}\right) \\
&\subset X_i^{-1}(\mathcal{B}^{n_i})
\end{aligned}$$

$\Rightarrow$  wg.  $X_1^{-1}(\mathcal{B}^{n_1}), X_2^{-1}(\mathcal{B}^{n_2})$  stu,  
auch  $Y_1^{-1}(\mathcal{B}^{m_1}), Y_2^{-1}(\mathcal{B}^{m_2})$  stu. □

### Satz 7.12 (Erwartungswert des Produkts unabhängiger ZV)

Sind  $X_1, \dots, X_n$  unabhängige integrierbare ZV, so folgt

$$\mathbb{E}\left(\prod_{i=1}^n X_i\right) = \prod_{i=1}^n \mathbb{E}(X_i)$$

(Die Umkehrung folgt nicht!)

*Beweis.*

Betrachte  $n = 2$

Sei  $f_X = f_{X_1} \cdot f_{X_2}$  (stu) und

$$\mathbb{P}_X = f_X \odot (\mu_1 \otimes \mu_2) = f_{X_1} \cdot f_{X_2} \odot (\mu_1 \otimes \mu_2)$$

Betrachte  $g : \mathbb{R}^2 \rightarrow \mathbb{R} \quad x \mapsto g(x) = x_1 \cdot x_2$

$$\begin{aligned}
\mathbb{E}(g \circ X) &= \int g d\mathbb{P}_X \\
&= \int g d(f_X \odot (\mu_1 \otimes \mu_2)) \\
&\stackrel{\text{stu und 3.28}}{=} \int g \cdot (f_{X_1} \cdot f_{X_2}) d(\mu_1 \otimes \mu_2) \\
&\stackrel{\text{Fubini}}{=} \int \int x_1 x_2 f_{X_1}(x_1) \cdot f_{X_2}(x_2) d\mu_1(x_1) d\mu_2(x_2) \\
&= \int x_1 f_{X_1}(x_1) d\mu_1(x_1) \int x_2 f_{X_2}(x_2) d\mu_2(x_2) \\
&= \mathbb{E}(X_1) \cdot \mathbb{E}(X_2)
\end{aligned}$$

□

### Satz 7.13

Seien  $X_1, \dots, X_n$  unabhängige reelle ZV, deren momenterzeugende Funktionen  $M_1, \dots, M_n$

alle auf dem Intervall  $] - a, a[$  definiert sind.

Sei  $S_n := \sum_{i=1}^n X_i$ , so ist auch

$$M(s) = \mathbb{E}(\exp(s S_n))$$

auf  $] - a, a[$  definiert und es gilt

$$M(s) = \prod_{i=1}^n M_i(s), \quad s \in ] - a, a[$$

*Beweis.*

Nach Satz 7.11 sind  $\exp(s X_1), \dots, \exp(s X_n)$  als Komposition stochastisch unabhängiger ZV wieder st. u. n. d., nach Voraussetzung, auf  $] - a, a[$  integrierbar.

$\Rightarrow \exp\left(s \cdot \sum_{i=1}^n X_i\right) = \exp(s X_1) \cdot \dots \cdot \exp(s X_n)$  ist integrierbar

$\Rightarrow M(s) = \mathbb{E}(\exp(s S_n)) \stackrel{\text{Satz 7.12, stu}}{=} \prod_{i=1}^n \mathbb{E}(\exp(s \cdot X_i)) = \prod_{i=1}^n M_i(s)$  □

## 7.4 Einige Ungleichungen

### Satz 7.14 (Markow- und Tschebyschow-Ungleichungen)

Sei  $X : \Omega \rightarrow \mathbb{R}$  eine reelle ZV. Dann gilt für jedes  $\epsilon > 0$ :

$$\begin{aligned} \mathbb{P}(|X| \geq \epsilon) &\leq \frac{1}{\epsilon^n} \int |X|^n I_{\{|X| \geq \epsilon\}} d\mathbb{P} \\ &\leq \frac{1}{\epsilon^n} \mathbb{E}(|X|^n) \end{aligned}$$

Insbesondere ( $n = 1$ )

$$\mathbb{P}(|X| \geq \epsilon) \leq \frac{1}{\epsilon} \mathbb{E}(|X|) \quad (\text{Markow-Ungleichung})$$

und für  $\mathbb{E}(|X|) < \infty$

$$\mathbb{P}(|X - \mathbb{E}(X)| \geq \epsilon) \leq \frac{\mathbb{E}((X - \mathbb{E}(X))^2)}{\epsilon^2} = \frac{\mathbb{V}(X)}{\epsilon^2} \quad (\text{Tschebyschow-Ungleichung}).$$

*Beweis.*

Sei  $Y \geq 0$  ZV. Dann gilt für jedes  $\alpha > 0$ :

$$\alpha \cdot I_{\{Y \geq \alpha\}} \leq Y \cdot I_{\{Y \geq \alpha\}} \leq Y$$

$$\begin{aligned} \int \alpha \cdot I_{\{Y \geq \alpha\}} d\mathbb{P} &\stackrel{\int \text{monoton}}{\Rightarrow} \int \alpha \cdot I_{\{Y \geq \alpha\}} d\mathbb{P} = \alpha \cdot \int I_{\{Y \geq \alpha\}} d\mathbb{P} = \alpha \cdot \mathbb{P}(\{Y \geq \alpha\}) \leq \int Y I_{\{Y \geq \alpha\}} d\mathbb{P} \\ &\leq \int Y d\mathbb{P} = \mathbb{E}(Y) \\ \stackrel{|\cdot \alpha}{\Rightarrow} \mathbb{P}(Y \geq \alpha) &\leq \frac{1}{\alpha} \int_{\{Y \geq \alpha\}} Y d\mathbb{P} \leq \frac{1}{\alpha} \mathbb{E}(Y) \end{aligned}$$

Mit  $Y := |X|^n$  und  $\alpha = \epsilon^n$  folgt

$$\mathbb{P}(|X|^n \geq \epsilon^n) \stackrel{\forall}{=} \mathbb{P}(|X| \geq \epsilon) \leq \frac{1}{\epsilon^n} \mathbb{E}(|X|^n)$$

Markov: Spezialfall für  $n = 1$

Tschebyschew:  $n = 2$  und  $X = X - \mathbb{E}(X)$  □

**Andrei Andrejewitsch Markow (2./14. Juni 1856 bis 20. Juli 1922)** in Rußland geborener Mathematiker, 1885 verteidigte er seine Habilitationsschrift an der Universität Sankt Petersburg und wurde dort 1886 Professor an der Fakultät für Mathematik und Physik. Er berechnete 1913 die Buchstabensequenzen in russischer Literatur, um die Notwendigkeit der Unabhängigkeit für das Gesetz der großen Zahlen nachzuweisen. Aus diesem Ansatz entwickelte sich der Markow-Prozess.

[http://de.wikipedia.org/wiki/Andrei\\_Andrejewitsch\\_Markow](http://de.wikipedia.org/wiki/Andrei_Andrejewitsch_Markow)

**Pafnuti Lwowitsch Tschebyschow (14. Mai/26. Mai 1821 bis 26. November/8. Dezember 1894)** entstammte einer russischen Großgrundbesitzerfamilie und wurde 1850 Professor in Sankt Petersburg. Zahlreiche Beiträge zu Interpolation, Approximationstheorie, Funktionentheorie, Wahrscheinlichkeitsrechnung, Zahlentheorie, Mechanik und Ballistik.

[http://de.wikipedia.org/wiki/Pafnuti\\_Lwowitsch\\_Tschebyschow](http://de.wikipedia.org/wiki/Pafnuti_Lwowitsch_Tschebyschow)

### Satz 7.15 (Jensen'sche Ungleichung)

Sei  $f : I \rightarrow \mathbb{R}$  eine konvexe Funktion auf einem Intervall  $I \subset \mathbb{R}$  und  $X : \Omega \rightarrow I$  eine integrierbare ZV. Dann gilt

$$f(\mathbb{E}(X)) \leq \mathbb{E}(f(X))$$

*Beweis.*

$$f : I \rightarrow \mathbb{R} \text{ konvex} \quad :\Leftrightarrow \quad f(\alpha x + (1 - \alpha)y) \leq \alpha f(x) + (1 - \alpha)f(y) \\ \forall x, y \in I, \alpha \in [0, 1]$$

$$\Rightarrow f(x) = \sup_{v \in V} v(x)$$

mit  $V = \{v \mid v(x) = a + bx \leq f(x) \quad \forall x \in I\}$  die Menge aller linearen Funktionen unterhalb  $f$

$$\Rightarrow \mathbb{E}(f(X)) = \mathbb{E}(\sup_{v \in V} v(X)) \stackrel{\forall v_0 \in V}{\geq} \mathbb{E}(v_0(X)) = v_0(\mathbb{E}(X))$$

$$\Rightarrow \underbrace{\sup_{v_0 \in V} \mathbb{E}(f(X))}_{\mathbb{E}(f(X))} \geq \sup_{v_0 \in V} v_0(\mathbb{E}(X)) \\ \mathbb{E}(f(X)) \geq f(\mathbb{E}(X))$$

□



**Johan Ludwig William Valdemar Jensen (8. Mai 1859 bis 5. März 1925)** war ein dänischer Mathematiker und leistete wichtige Beiträge bei der Erforschung der riemannschen Vermutung. Er arbeitete bei der Bell Telephone Company und später der Kopenhagener Telefongesellschaft.

[http://de.wikipedia.org/wiki/Johann\\_Ludwig\\_Jensen](http://de.wikipedia.org/wiki/Johann_Ludwig_Jensen)

**Beispiel 7.5** •  $\mathbb{E}(X^2) \geq \mathbb{E}(X)^2$  mit  $f(x) = x^2$  konvex

•  $\mathbb{P}(X > 0) = 1 \Rightarrow \mathbb{E}\left(\frac{1}{X}\right) \geq \frac{1}{\mathbb{E}(X)}$  mit  $f(x) = \frac{1}{x}$

## 7.5 Der mehrdimensionale Erwartungswert und die Kovarianzmatrix

### Definition 7.16

Sei  $X : \Omega \rightarrow \mathbb{R}^n$ ,  $X = (X_1, \dots, X_n)$  eine  $n$ -dimensionale ZV, dann heißt

$$\mathbb{E}(X) := (\mathbb{E}(X_1), \dots, \mathbb{E}(X_n))$$

der ( $n$ -dimensionale) Erwartungswert von  $X$  und

$$\mathbb{V}(X) = \mathbb{E}((X - \mathbb{E}(X))(X - \mathbb{E}(X))^\top)$$

die Kovarianzmatrix von  $X$ .

*Bemerkung.*

$$X \in \mathbb{R}^{n \times 1} \Rightarrow XX^\top \in \mathbb{R}^{n \times n}$$

*Bemerkung.*

$$\begin{aligned} \text{Cov}(X, Y) &= \mathbb{V}((X, Y))_{1,2} \\ &= \mathbb{V}((X, Y))_{2,1} \\ &= \mathbb{E}((X - \mathbb{E}(X)) \cdot (Y - \mathbb{E}(Y))) \end{aligned}$$

heißt Kovarianz von  $X$  und  $Y$ .

### Satz 7.17

Sei  $X : \Omega \rightarrow \mathbb{R}^n$   $n$ -dimensionale ZV,  $A \in \mathbb{R}^{m \times n}$  und  $b \in \mathbb{R}^m$ . Dann gilt

- i)  $\mathbb{E}(AX + b) = A\mathbb{E}(X) + b$
- ii)  $\mathbb{V}(AX + b) = A\mathbb{V}(X)A^\top$
- iii)  $\mathbb{V}(X)$  psd

*Beweis.*

i) Linearität des  $\mathbb{E}$ -Wertes

ii)

$$\begin{aligned}
 \mathbb{V}(AX + b) &= \mathbb{E}((AX + b - \mathbb{E}(AX + b))(AX + b - \mathbb{E}(AX + b))^\top) \\
 &= \mathbb{E}((AX + b - A\mathbb{E}(X) - b)(AX + b - A\mathbb{E}(X) - b)^\top) \\
 &= \mathbb{E}((AX - A\mathbb{E}(X))(AX - A\mathbb{E}(X))^\top) \\
 &= \mathbb{E}(A(X - \mathbb{E}(X))(X - \mathbb{E}(X))^\top A^\top) \\
 &= A\mathbb{E}((X - \mathbb{E}(X))(X - \mathbb{E}(X))^\top)A^\top \\
 &= A\mathbb{V}(X)A^\top
 \end{aligned}$$

iii) z.Z.  $x^\top \mathbb{V}(X) x \geq 0 \quad \forall x \in \mathbb{R}^n$  HA

□

### Satz 7.18

$X, Y$  ZV,  $X_1, \dots, X_n$  ZV

i)  $\text{Cov}(X, Y) = \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y)$

ii)  $X, Y$  stu  $\Rightarrow \text{Cov}(X, Y) = 0$

iii)

$$\begin{aligned}
 \mathbb{V}\left(\sum_{i=1}^n X_i\right) &= \sum_{i=1}^n \mathbb{V}(X_i) + 2 \sum_{1 \leq i < j \leq n} \text{Cov}(X_i, X_j) \\
 X_1, \dots, X_n \text{ stu} &\stackrel{=}{=} \sum_{i=1}^n \mathbb{V}(X_i)
 \end{aligned}$$

*Beweis.*

i)

$$\begin{aligned}
 \text{Cov}(X, Y) &= \mathbb{E}((X - \mathbb{E}(X))(Y - \mathbb{E}(Y))) \\
 &= \mathbb{E}(XY) - \mathbb{E}(Y)\mathbb{E}(X) - \mathbb{E}(X)\mathbb{E}(Y) + \mathbb{E}(X)\mathbb{E}(Y) \\
 &= \mathbb{E}(XY) - \mathbb{E}(X)\mathbb{E}(Y)
 \end{aligned}$$

ii)  $X, Y$  stu  $\Rightarrow \mathbb{E}(XY) \stackrel{\text{Satz 7.12}}{=} \mathbb{E}(X)\mathbb{E}(Y)$

iii)

$$\begin{aligned}
\mathbb{V}\left(\sum_{i=1}^n X_i\right) &= \mathbb{E}\left(\left(\sum_{i=1}^n (X_i - \mathbb{E}(X_i))\right)^2\right) \\
&= \mathbb{E}\left(\sum_{i,j} (X_i - \mathbb{E}(X_i))(X_j - \mathbb{E}(X_j))\right) \\
&= \sum_{i,j} \underbrace{\mathbb{E}((X_i - \mathbb{E}(X_i))(X_j - \mathbb{E}(X_j)))}_{\text{Cov}(X_i, X_j)}
\end{aligned}$$

□

**Definition 7.19 (Korrelationskoeffizient)**Seien  $X, Y$  ZV mit  $\mathbb{V}(X) < \infty$ ,  $\mathbb{V}(Y) < \infty$ . Dann heißt

$$\rho(X, Y) := \frac{\text{Cov}(X, Y)}{\sqrt{\mathbb{V}(X)\mathbb{V}(Y)}}$$

der Korrelationskoeffizient von  $X$  und  $Y$ .**Satz 7.20**

$$|\rho(X, Y)| \leq 1$$

*Beweis.*

$$\begin{aligned}
|\text{Cov}(X, Y)| &\leq \mathbb{E}(|(X - \mathbb{E}(X)) \cdot (Y - \mathbb{E}(Y))|) \\
&\stackrel{\text{Hölder-Ungleichung}}{\leq} \mathbb{E}((X - \mathbb{E}(X))^2)^{\frac{1}{2}} \cdot \mathbb{E}((Y - \mathbb{E}(Y))^2)^{\frac{1}{2}} \\
&= \mathbb{V}(X)^{\frac{1}{2}} \cdot \mathbb{V}(Y)^{\frac{1}{2}} = \sqrt{\mathbb{V}(X) \cdot \mathbb{V}(Y)}
\end{aligned}$$

□

**Satz 7.21 (Standardisierung)**Sei  $X = (X_1, \dots, X_n)$   $n$ -dimensionale ZV mit  $\mathbb{E}(X) = \mu$  und  $\mathbb{V}(X) = \Sigma$ . Dann existiert  $B \in \mathbb{R}^{n,n}$  mit  $Y = B^{-1}(X - \mu)$  und  $\mathbb{E}(Y) = 0_n$  sowie  $\mathbb{V}(Y) = \mathbf{E}_n$ .*Beweis.* $\Sigma$  ist psd (siehe HA) und damit existiert die Cholesky-Zerlegung

$$\Sigma = B B^\top \quad \text{mit } B \in \mathbb{R}^{n,n}, B \text{ existiert.}$$

Also

$$\mathbb{E}(Y) = \mathbb{E}(B^{-1}(X - \mu)) = B^{-1}(\mathbb{E}(X) - \mu) = 0_n$$

$$\mathbb{V}(Y) = B^{-1} \mathbb{V}(X) B^{-1\top} = B^{-1} B B^\top B^{-1\top} = \mathbf{E}_n B^\top B^{\top-1} = \mathbf{E}_n \mathbf{E}_n = \mathbf{E}_n$$

□

*Bemerkung.* Für  $n = 1$  gilt:  $(\mathbb{V}(X) = \sigma^2)$

$$Y = \frac{X - \mu}{\sigma} \quad \text{hat} \quad \mathbb{E}(Y) = 0 \quad \text{und} \quad \mathbb{V}(Y) = 1.$$

# Kapitel 8

## Einige spezielle Verteilungen und deren Eigenschaften

### 8.1 Diskrete Verteilungen

**Satz 8.1 (Erwartungswert und Varianz der  $B(n, p)$ )**

Seien  $X_1, \dots, X_n$  stu mit  $X_i \sim B(1, p)$ ,  $i = 1, \dots, n$ . Dann gilt für  $X = \sum_{i=1}^n X_i$

$$\begin{aligned}\mathbb{E}(X) &= n \cdot p \\ \mathbb{V}(X) &= n \cdot p \cdot (1 - p)\end{aligned}$$

*Beweis.*

$$\mathbb{E}(X) = \mathbb{E}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \underbrace{\mathbb{E}(X_i)}_{=p} = n \cdot p$$

$$\mathbb{V}(X) = \mathbb{V}\left(\sum_{i=1}^n X_i\right) \stackrel{\text{stu}}{=} \sum_{i=1}^n \underbrace{\mathbb{V}(X_i)}_{p(1-p)} = n \cdot p \cdot (1 - p) \quad \square$$

**Satz 8.2 (Zusammenhang zwischen  $B(1, p)$  und  $B(n, p)$ )**

Seien  $X_1, \dots, X_n$  stu mit  $X_i \sim B(1, p)$ . Dann gilt:

$$X = \sum_{i=1}^n X_i \sim B(n, p).$$

*Beweis.*

$$\begin{aligned}\mathbb{P}(X_1 = 1, X_2 = 1, \dots, X_m = 1, X_{m+1} = 0, \dots, X_n = 0) &\stackrel{\text{stu}}{=} \prod_{i=1}^m \mathbb{P}(X_i = 1) \prod_{i=m+1}^n \mathbb{P}(X_i = 0) \\ &= \prod_{i=1}^m p \prod_{i=m+1}^n (1 - p) = p^m (1 - p)^{n-m}\end{aligned}$$

Da es  $\binom{n}{m}$  Möglichkeiten gibt, die 1/0 zu permutieren, folgt

$$\mathbb{P}\left(\sum X_i = m\right) = \binom{n}{m} p^m (1-p)^{n-m}$$

$$\Rightarrow \sum X_i \sim B(n, p)$$

□

**Korollar 8.3**

$X_1 \sim B(n_1, p)$ ,  $X_2 \sim B(n_2, p)$  stu.  $\Rightarrow X_1 + X_2 \sim B(n_1 + n_2, p)$  Summenstabilität

**Definition 8.4 (Hypergeometrische Verteilung)**

Modell: Ziehen ohne Zurücklegen

$X \sim H(n, K, N)$ ,

$$\mathbb{P}(X = k) = \frac{\binom{K}{k} \binom{N-K}{n-k}}{\binom{N}{n}}$$

**Satz 8.5 (Erwartungswert und Varianz von  $X \sim H(n, K, N)$ )**

$X \sim H(n, K, N)$

$$\begin{aligned} \mathbb{E}(X) &= n \cdot \frac{K}{N} \\ \mathbb{V}(X) &= n \cdot \frac{K}{N} \left(1 - \frac{K}{N}\right) \cdot \left(\frac{N-n}{N-1}\right) \end{aligned}$$

*Bemerkung.*  $\mathbb{E}(X)$  ist analog zu  $B(n, p)$ , da  $\frac{K}{N}$  der Erfolgswahrscheinlichkeit  $p$  entspricht.

$\mathbb{V}(X)$  ist für  $n > 1$  kleiner als die Varianz von  $B(n, p)$

$\Rightarrow$  „Endlichkeitskorrektur“

*Beweis.*

Wir betrachten die einzelnen Ziehungen mit  $Y_1, \dots, Y_n$ ,  $X = \sum_{i=1}^n Y_i$ ,  $Y_i$  binär.

Betrachte gemeinsame Verteilung der  $Y_i$  z.B.  $k = 2$ ,  $n = 4$ ,

$$\mathbb{P}(Y_1 = 1, Y_2 = 1, Y_3 = 0, Y_4 = 0) = \frac{K}{N} \cdot \frac{K-1}{N-1} \cdot \frac{N-K}{N-2} \cdot \frac{N-K-1}{N-3}$$

$$\mathbb{P}(Y_1 = 1, Y_2 = 0, Y_3 = 0, Y_4 = 1) = \frac{K}{N} \cdot \frac{N-K}{N-1} \cdot \frac{N-K-1}{N-2} \cdot \frac{K-1}{N-3}$$

Wahrscheinlichkeit ist für alle Varianten mit  $\sum Y_n = k$  identisch.

$$\mathbb{P}(Y_1 = i_1, \dots, Y_n = i_n) = \frac{K \cdot \dots \cdot (K-k+1) \cdot (N-K) \cdot \dots \cdot (N-K-(n-k)+1)}{N(N-1) \cdot \dots \cdot (N-n+1)} \text{ für } \sum_{j=1}^n i_j = k$$

$\Rightarrow$  gemeinsame Verteilung von  $Y_1, \dots, Y_n$  ist vertauschbar,

d.h.  $\mathbb{V}(Y_1, \dots, Y_n) = \mathbb{V}(Y_{\pi(1)}, \dots, Y_{\pi(n)})$

$\Rightarrow$  Alle Randverteilungen sind identisch

$$Y_i \sim B\left(1, \frac{K}{N}\right)$$

$$\begin{aligned}\mathbb{E}\left(\sum_{i=1}^n Y_i\right) &= \sum_{i=1}^n \mathbb{E}(Y_i) = n \cdot \frac{K}{N} \\ \mathbb{V}\left(\sum_{i=1}^n Y_i\right) &= \sum_{i=1}^n \mathbb{V}(Y_i) + \sum_{i \neq j, i < j} 2 \cdot \text{Cov}(Y_i, Y_j)\end{aligned}$$

Es gilt

$$\text{Cov}(Y_i, Y_j) = \text{Cov}(Y_1, Y_2) = \mathbb{E}(Y_1 Y_2) - \mathbb{E}(Y_1) \cdot \mathbb{E}(Y_2)$$

$$= \frac{K}{N} \cdot \frac{K-1}{N-1} - \left(\frac{K}{N}\right)^2 = \frac{K}{N} \cdot \left(\frac{K-1}{N-1} - \frac{K}{N}\right)$$

$$(\text{weil } Y_1 Y_2 = 1 \iff Y_1 = 1 \text{ und } Y_2 = 1 \text{ und damit } \mathbb{E}(Y_1 Y_2) = \mathbb{P}(Y_1 = 1, Y_2 = 1) = \frac{K}{N} \cdot \frac{K-1}{N-1})$$

$$\begin{aligned}\mathbb{V}\left(\sum_{i=1}^n Y_i\right) &= n \cdot \frac{K}{N} \left(1 - \frac{K}{N}\right) + \frac{n(n-1)}{2} \cdot 2 \frac{K}{N} \left(\frac{K-1}{N-1} - \frac{K}{N}\right) \\ &= n \cdot \frac{K}{N} \left(1 - \frac{K}{N}\right) \cdot \left(\frac{N-n}{N-1}\right)\end{aligned}$$

□

**Satz 8.6 (Zusammenhang zwischen  $B(n, p)$  und  $H(n, K, N)$ )**

Seien  $K_m, N_m \in \mathbb{N}$  mit  $0 \leq K_m \leq N_m$  Folgen ( $m \in \mathbb{N}$ ) mit  $K_m \rightarrow \infty, N_m \rightarrow \infty$  und  $p \in [0, 1], n \in \mathbb{N}$  fest. Dann gilt mit  $\frac{K_m}{N_m} \rightarrow p$  für  $m \rightarrow \infty$

$$\lim_{m \rightarrow \infty} \mathbb{P}(H_m = k) = \mathbb{P}(B = k) \quad \forall k \in \mathbb{N}$$

für  $H_m \sim H(n, K_m, N_m)$  und  $B \sim B(n, p)$ .

*Beweis.*

Dichte

$$\begin{aligned}\mathbb{P}(H_m = k) &= h(k, n, K_m, N_m) = \frac{\binom{K_m}{k} \binom{N_m - K_m}{n - k}}{\binom{N_m}{n}} \\ &= \frac{n!}{k! (n - k)!} \cdot \frac{K_m!}{(K_m - k)!} \cdot \frac{(N_m - K_m)!}{((N_m - K_m) - (n - k))!} \\ &= \left(\binom{n}{k}\right) \underbrace{\frac{K_m}{N_m}}_{\rightarrow p} \cdot \underbrace{\frac{K_m - 1}{N_m - 1}}_{\rightarrow p} \cdots \underbrace{\frac{K_m - (k - 1)}{N_m - (k - 1)}}_{\rightarrow p} \cdot \\ &\quad \underbrace{\frac{(N_m - K_m)}{N_m - k}}_{\rightarrow 1 - p} \cdot \underbrace{\frac{N_m - K_m - 1}{N_m - k - 1}}_{\rightarrow 1 - p} \cdots \underbrace{\frac{N_m - K_m - (n - k - 1)}{N_m - (n - 1)}}_{\rightarrow 1 - p}\end{aligned}$$

$$\xrightarrow{m \rightarrow \infty} \binom{n}{k} p^k (1-p)^{n-k} = b(k, n, p) = \mathbb{P}(B = k) \quad \square$$

**Satz 8.7 (Zusammenhang zwischen  $B(n, p)$  und  $P(\lambda)$ )**

Sei  $p_n \in [0, 1]$ ,  $n \in \mathbb{N}$ , eine Folge und  $\lambda_n = n \cdot p_n \rightarrow \lambda > 0$  für  $n \rightarrow \infty$ . Dann gilt

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

*Beweis.*

$$\begin{aligned} b(k, n, p_n) &= \binom{n}{k} p_n^k (1-p_n)^{n-k} \\ &= \frac{n!}{k! (n-k)!} \left(\frac{\lambda_n}{n}\right)^k \left(1 - \frac{\lambda_n}{n}\right)^{n-k} \\ &= \frac{\lambda_n^k}{k!} \left(1 - \frac{\lambda_n}{n}\right)^n \frac{n(n-1) \cdots (n-k+1)}{n^k} \left(1 - \frac{\lambda_n}{n}\right)^{-k} \\ &= \frac{\lambda_n^k}{k!} \left(1 - \frac{\lambda_n}{n}\right)^n \frac{\frac{n}{n} \frac{n-1}{n} \frac{n-2}{n} \cdots \frac{n-k+1}{n}}{\left(1 - \frac{\lambda_n}{n}\right)^k} \\ &\xrightarrow{n \rightarrow \infty} \frac{\lambda^k}{k!} e^{-\lambda} \underbrace{\frac{1 \cdot \left(1 - \frac{1}{n}\right) \cdots \left(1 - \frac{k-1}{n}\right)}{\left(1 - \frac{\lambda_n}{n}\right)^k}}_{\rightarrow 1 \text{ da } \frac{1}{n} \dots \frac{\lambda_n}{n} \rightarrow 0} \\ &= \frac{\lambda^k}{k!} e^{-\lambda} = f(k) \hat{=} \text{Dichte der Poissonverteilung mit Parameter } \lambda. \end{aligned}$$

□

**Definition 8.8 (Geometrische Verteilung)**

Die diskrete Verteilung mit Parameter  $p \in [0, 1]$  und Dichte

$$\mathbb{P}(X = x) = (1-p)^{x-1} p \quad x \in \mathbb{N}$$

heißt geometrische Verteilung, kurz  $X \sim G(p)$ , und beschreibt die Wahrscheinlichkeit der Anzahl von Versuchen bis zum ersten Erfolg.

**Satz 8.9 (Eigenschaften der Geometrischen Verteilung)**

$X \sim G(p)$

(a)  $\mathbb{E}(X) = \frac{1}{p}$  und  $\mathbb{V}(X) = \frac{1-p}{p^2}$

(b) Gedächtnislosigkeit  $\mathbb{P}(X = x + x_0 | X > x_0) = \mathbb{P}(X = x)$



**Definition 8.10 (Negative Binomialverteilung)**

Die diskrete Verteilung mit Parametern  $p \in [0, 1]$  und  $n \in \mathbb{N}$  sowie der Dichte

$$\mathbb{P}(X = x) = \binom{x-1}{n-1} p^n (1-p)^{x-n} \quad \text{für } x \in \mathbb{N}, x \geq n$$

heißt negative Binomialverteilung, kurz  $X \sim B^{-1}(n, p)$ .

*Bemerkung.*  $X$  beschreibt die Anzahl von Versuchen, die zur Erreichung von  $n$  Erfolgen notwendig sind, wenn die Wahrscheinlichkeit für einen Erfolg gleich  $p$  ist. Die Dichte kann folgendermaßen hergeleitet werden. Sei  $Y$  die Anzahl von Erfolgen bei  $x-1$  Versuchen;  $Y \sim B(x-1, p)$ . Die Wahrscheinlichkeit,  $n-1$  Erfolge bei  $x-1$  Versuchen erzielt zu haben ist

$$\begin{aligned} \mathbb{P}(Y = n-1) &= b(x-1, n-1, p) = \binom{x-1}{n-1} p^{n-1} (1-p)^{x-1-(n-1)} \\ &= \binom{x-1}{n-1} p^{n-1} (1-p)^{x-n} \end{aligned}$$

Die Wahrscheinlichkeit, im  $x$ ten Versuch einen Erfolg und damit insgesamt  $n$  Erfolge zu erzielen ist  $p$ , also

$$\mathbb{P}(X = x) = \mathbb{P}(Y = n-1)p = \binom{x-1}{n-1} p^n (1-p)^{x-n}$$

**Satz 8.11 (Zusammenhang zwischen  $G(p)$  und  $B^{-1}(n, p)$ )**

Seien  $X_1, \dots, X_n$  stu mit  $X_i \sim G(p), i = 1, \dots, n$ . Dann gilt

$$X = \sum_{i=1}^n X_i \sim B^{-1}(n, p)$$

**Korollar 8.12**

$$X \sim B^{-1}(n, p) \Rightarrow \mathbb{E}(X) = \frac{n}{p}$$

$$X = \sum_{i=1}^n X_i \quad X_i \sim G(p) \quad \text{stu.}$$

$$\mathbb{E}(X) = n \cdot \mathbb{E}(X_i) = \frac{n}{p} \quad \text{und} \quad \mathbb{V}(X) = \frac{n(1-p)}{p^2}$$

Negative Binomialverteilung ist nicht gedächtnislos.

*Beweis.*

Zunächst  $n = 2$ .

$$f_{X_1, X_2}(x_1, x_2) \stackrel{\text{stu}}{=} (1-p)^{x_1-1} \cdot p \cdot (1-p)^{x_2-1} \cdot p$$

$$\begin{aligned}
\mathbb{P}(X_1 + X_2 = x) &= \mathbb{P}(\{\omega \in \Omega \mid X_1(\omega) + X_2(\omega) = x\}) \\
&= \mathbb{P}\left(\bigcup_{x_1 \in \mathbb{N}} \{\omega \in \Omega \mid X_1(\omega) = x_1 \wedge X_2(\omega) = x - x_1\}\right) \\
&= \sum_{x_1 \in \mathbb{N}} \mathbb{P}(\{\omega \in \Omega \mid X_1(\omega) = x_1 \wedge X_2(\omega) = x - x_1\}) \\
&= \sum_{x_1 \in \mathbb{N}} \mathbb{P}(X_1 = x_1, X_2 = x - x_1) \\
&\stackrel{\text{alles diskret}}{=} \sum_{x_1 \in \mathbb{N}} f_{X_1, X_2}(x_1, x - x_1) \quad \text{''Faltung'' im diskreten Fall} \\
&\stackrel{\text{stu}}{=} \sum_{x_1 \in \mathbb{N}} f_{X_1}(x_1) \cdot f_{X_2}(x - x_1) \\
&\stackrel{f_{X_2}(x-x_1)=0 \text{ f\"ur } x \leq x_1}{=} \sum_{x_1=1}^{x-1} (1-p)^{x_1-1} p^2 (1-p)^{x-x_1-1} \\
&= p^2 \sum_{x_1=1}^{x-1} (1-p)^{x_1-1+(x-x_1-1)} \\
&= p^2 \sum_{x_1=1}^{x-1} (1-p)^{x-2} \\
&= p^2 (x-1) \cdot (1-p)^{x-2} \\
&\stackrel{n=2}{=} \binom{x-1}{n-1} p^n (1-p)^{x-n} \\
&\stackrel{\cong}{=} \text{Dichte der } B^{-1}(2, p)
\end{aligned}$$

Rest: VI □

### Definition 8.13 (Multinomialverteilung)

Sei  $n \in \mathbb{N}$  und  $p_1, \dots, p_k \in [0, 1]$  mit  $\sum_{j=1}^k p_j = 1$ . Sei  $Y = (Y_1, \dots, Y_k)$  eine  $k$ -dimensionale diskrete ZV mit Dichte

$$\begin{aligned}
f_Y(y) &= \mathbb{P}(Y_j = y_j \quad \forall j = 1, \dots, k) \\
&= \begin{cases} \frac{n!}{y_1! \cdots y_k!} p_1^{y_1} \cdots p_k^{y_k} & \text{falls } \sum_{j=1}^k y_j = n \\ 0 & \text{sonst.} \end{cases}
\end{aligned}$$

Dann heit die zugehrige Verteilung Multinomialverteilung mit Parametern  $n$  und  $p_1, \dots, p_k$  :  $Y \sim M(n, p_1, \dots, p_k)$ .

*Bemerkung.* Es langt,  $p_1, \dots, p_{k-1}$  anzugeben, denn

$$p_k = 1 - \sum_{j=1}^{k-1} p_j.$$

**Satz 8.14 (Eigenschaften der Multinomialverteilung)**

i)  $Y_i \sim B(n, p_i)$

ii)  $\mathbb{E}(Y) = n(p_1, \dots, p_k)$

iii)  $\mathbb{V}(Y) = n \begin{pmatrix} p_1(1-p_1) & -p_1 p_2 & \cdots & -p_1 p_k \\ -p_1 p_2 & p_2(1-p_2) & \cdots & -p_2 p_k \\ \vdots & \vdots & \ddots & \vdots \\ -p_1 p_k & -p_2 p_k & \cdots & p_k(1-p_k) \end{pmatrix}$

*Beweis.*

i)

$$\begin{aligned} \mathbb{P}(Y_i = y_i) &= \mathbb{P}(Y_i = y_i, \sum_{j \neq i} Y_j = n - y_i) \\ &\stackrel{M(n, \underline{p_i}, 1-p_i)}{=} \frac{n!}{y_i! (n - y_i)!} p_i^{y_i} (1 - p_i)^{n - y_i} \\ &= \binom{n}{y_i} p_i^{y_i} (1 - p_i)^{n - y_i} \end{aligned}$$

$$\Rightarrow Y_i \sim B(n, p_i)$$

ii)

$$\mathbb{E}(Y) \stackrel{Y_i \sim B(n, p_i)}{=} (\mathbb{E}(Y_1), \mathbb{E}(Y_2), \dots, \mathbb{E}(Y_n)) = n(p_1, \dots, p_k)$$

iii)  $Y_i \sim B(n, p_i) \Rightarrow \mathbb{V}(Y_i) = n p_i (1 - p_i)$

$$\begin{aligned} \mathbb{V}(Y_i + Y_j) &= \mathbb{V}(Y_i) + \mathbb{V}(Y_j) + 2 \operatorname{Cov}(Y_i, Y_j) \\ &= n p_i (1 - p_i) + n p_j (1 - p_j) + 2 \operatorname{Cov}(Y_i, Y_j) \end{aligned}$$

Es gilt:  $Y_i + Y_j \sim B(n, p_i + p_j)$ , denn

$$\left( Y_i, Y_j, Z = \sum_{k \neq i, j} Y_k \right) \sim M(n, p_i, p_j, (1 - (p_i + p_j)))$$

und die Randverteilung von  $Z$  ist  $Z \sim B(n, 1 - (p_i + p_j))$ . Somit ist die Verteilung von  $n - Z = Y_i + Y_j \sim B(n, p_i + p_j)$  und  $\mathbb{V}(Y_i + Y_j) = n(p_i + p_j)(1 - (p_i + p_j))$ .

Somit gilt (nach Cov auflösen):

$$\begin{aligned} \text{Cov}(Y_i, Y_j) &= \frac{\mathbb{V}(Y_i + Y_j) - n(p_i(1 - p_i) + p_j(1 - p_j))}{2} \\ &= \frac{n(p_i + p_j)(1 - (p_i + p_j)) - n(p_i(1 - p_i) + p_j(1 - p_j))}{2} \\ &= \frac{n}{2}(p_i(1 - (p_i + p_j)) + p_j(1 - (p_i + p_j)) - p_i(1 - p_i) - p_j(1 - p_j)) \\ &= \frac{n}{2}(p_i(1 - (p_i + p_j) - 1 + p_i) + p_j(1 - (p_i + p_j) - 1 + p_j)) \\ &= \frac{n}{2}(-p_i p_j - p_j p_i) = -\frac{n}{2} 2 p_i p_j = -n p_i p_j \end{aligned}$$

□

## 8.2 Die univariate Normalverteilung

Bekannt:  $X \sim N(\mu, \sigma^2) \Rightarrow \mathbb{E}(X) = \mu, \quad \mathbb{V}(X) = \sigma^2$

**Satz 8.15 (Lineare Transformation)**

$$X \sim N(\mu, \sigma^2) \Rightarrow Y = aX + b \sim N(a\mu + b, a^2\sigma^2) \quad \text{für } a, b \in \mathbb{R}, a \neq 0.$$

*Beweis.*

$$y = g(x) = ax + b \Rightarrow g^{-1}(y) = \frac{y - b}{a} \text{ bijektiv}$$

$$\frac{\partial g^{-1}(y)}{\partial y} = \frac{1}{a}$$

$$\begin{aligned} \stackrel{\text{Trafo}}{\Rightarrow} f_Y(y) &= f_X\left(\frac{y - b}{a}\right) \cdot \frac{1}{|a|} \\ &= \frac{1}{\sqrt{2\pi} \sigma |a|} \exp\left(-\frac{1}{2} \left(\frac{\frac{y-b}{a} - \mu}{\sigma}\right)^2\right) \\ &= \frac{1}{\sqrt{2\pi \sigma^2 a^2}} \exp\left(-\frac{1}{2} \left(\frac{y - (a\mu + b)}{a \sigma}\right)^2\right) \end{aligned}$$

$$\Rightarrow Y \sim N(a\mu + b, a^2 \sigma^2)$$

□

**Korollar 8.16**

$$X \sim N(\mu, \sigma^2) \Rightarrow Y = \frac{X - \mu}{\sigma} \sim N(0, 1).$$

**Satz 8.17**

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

$$m_r^0(X) = \begin{cases} 1 \cdot 3 \cdot 5 \cdot \dots \cdot (r-1) \sigma^r & r = 2k, k \in \mathbb{N} \\ 0 & \text{sonst} \end{cases}$$

*Beweis.*

$$r = 2k + 1 \stackrel{\text{Symmetrie Satz 5.9}}{\Rightarrow} m_r^0(X) = 0$$

Sei  $U \sim N(0, 1)$ . Dann gilt

$$\begin{aligned} \frac{\partial \varphi(x)}{\partial x} &= -x \varphi(x) \quad \text{und} \\ \mathbb{E}(U^r) &= \int \underbrace{x^{r-1}}_v \cdot \underbrace{x \cdot \varphi(x)}_{u'} dx \\ &\stackrel{PI}{=} [-x^{r-1} \varphi(x)]_{-\infty}^{\infty} - \int -\varphi(x) (r-1) x^{r-2} dx \\ &= 0 + (r-1) \underbrace{\int x^{r-2} \varphi(x) dx}_{\mathbb{E}(U^{r-2})} \end{aligned}$$

$$\Rightarrow \mathbb{E}(U^r) = (r-1) \mathbb{E}(U^{r-2})$$

Wegen  $\mathbb{E}(U) = 0$  folgt  $\mathbb{E}(U^r) = 0 \quad \forall r$  ungerade und wegen  $\mathbb{E}(U^2) = \mathbb{V}(U) = 1$  folgt für  $r$  gerade,  $r = 2k$ ,

$$\begin{aligned} \mathbb{E}(U^r) &= (r-1) \mathbb{E}(U^{r-2}) \\ &\stackrel{r=2k}{=} (2k-1) \mathbb{E}(U^{2(k-1)}) \\ &= (2k-1)(2k-3) \mathbb{E}(U^{2(k-2)}) \dots \\ &= (2k-1)(2k-3) \dots (3) \underbrace{\mathbb{E}(U^2)}_{=1} \\ &= 1 \cdot 3 \cdot 5 \dots (2k-1) \end{aligned}$$

Wegen  $\mathbb{E}((X - \mu)^r) = \mathbb{E}((\sigma U)^r) = \sigma^r \mathbb{E}(U^r)$  folgt

$$m_r^0(X) = \mathbb{E}((X - \mu)^r) = 1 \cdot 3 \cdot 5 \dots (2k-1) \sigma^r$$

□

**Satz 8.18 (Additivität der Normalverteilung)**

Seien  $X_1 \sim N(\mu_1, \sigma_1^2)$  und  $X_2 \sim N(\mu_2, \sigma_2^2)$  stu

$$\Rightarrow X_1 + X_2 \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2)$$

*Beweis.*

$$X_1 + X_2 \sim N(\mu_1 + \mu_2, \sigma_1^2 + \sigma_2^2) \Leftrightarrow \frac{X_1 + X_2 - (\mu_1 + \mu_2)}{\sqrt{\sigma_1^2 + \sigma_2^2}} \sim N(0, 1)$$

Weiterhin:

$$\frac{X_1 + X_2 - (\mu_1 + \mu_2)}{\sqrt{\sigma_1^2 + \sigma_2^2}} = \underbrace{\frac{X_1 - \mu_1}{\sqrt{\sigma_1^2 + \sigma_2^2}}}_{\tilde{X}_1} + \underbrace{\frac{X_2 - \mu_2}{\sqrt{\sigma_1^2 + \sigma_2^2}}}_{\tilde{X}_2} \sim N(0, 1)$$

$$\mathbb{E}(\tilde{X}_1) = \mathbb{E}(\tilde{X}_2) = 0$$

$$\mathbb{V}(\tilde{X}_1) = \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} := \lambda^2$$

$$\mathbb{V}(\tilde{X}_2) = \frac{\sigma_2^2}{\sigma_1^2 + \sigma_2^2} = 1 - \lambda^2$$

Es reicht also zu zeigen:

$$\tilde{X}_1 \sim N(0, \lambda^2) \text{ und } \tilde{X}_2 \sim N(0, 1 - \lambda^2) \text{ st. u.} \Rightarrow \tilde{X}_1 + \tilde{X}_2 \sim N(0, 1)$$

$$\begin{aligned} f_{\tilde{X}_1 + \tilde{X}_2}(z) &\stackrel{\text{Faltung}}{=} \int f_{\tilde{X}_1}(z-x) f_{\tilde{X}_2}(x) dx \\ &= \int \frac{1}{\sqrt{2\pi\lambda^2}} \exp\left(-\frac{1}{2} \left(\frac{z-x}{\lambda}\right)^2\right) \frac{1}{\sqrt{2\pi(1-\lambda^2)}} \exp\left(-\frac{1}{2} \frac{x^2}{1-\lambda^2}\right) dx \\ &= \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2} z^2\right) \cdot \end{aligned}$$

$$\underbrace{\int \frac{1}{\sqrt{2\pi}} \frac{1}{\sqrt{\lambda^2(1-\lambda^2)}} \exp\left(-\frac{1}{2} \underbrace{\left(\frac{(z-x)^2}{\lambda^2} + \frac{x^2}{1-\lambda^2} - z^2\right)}_A\right) dx}_B$$

$$\begin{aligned} A &= \frac{(1-\lambda^2)z^2 - 2(1-\lambda^2)zx + (1-\lambda^2)x^2 + \lambda^2x^2 - \lambda^2(1-\lambda^2)z^2}{\lambda^2(1-\lambda^2)} \\ &= \frac{x^2 - 2(1-\lambda^2)zx + [(1-\lambda^2)z]^2}{\lambda^2(1-\lambda^2)} = \frac{(x - (1-\lambda^2)z)^2}{\lambda^2(1-\lambda^2)} \end{aligned}$$

$\Rightarrow B(x)$  ist Dichte von  $N((1-\lambda^2)z, \lambda^2(1-\lambda^2))$

$$\Rightarrow \int B(x) dx = 1$$

□

**Korollar 8.19**

$X_1, \dots, X_n$  stu,  $X_i \sim N(\mu_i, \sigma_i^2)$  für  $i = 1, \dots, n$ . Dann gilt

$$\text{i) } \sum X_i \sim N(\sum \mu_i, \sum \sigma_i^2)$$

$$\text{ii) } \mu_1 = \dots = \mu_n, \sigma_1^2 = \dots = \sigma_n^2 \quad \Rightarrow \quad \bar{X} = \frac{1}{n} \sum X_i \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$

**Korollar 8.20**

$X_1 \sim N(\mu_1, \sigma_1^2), X_2 \sim N(\mu_2, \sigma_2^2)$  stu.  $\Rightarrow aX_1 + bX_2 + c \sim N(a\mu_1 + b\mu_2 + c, a^2\sigma_1^2 + b^2\sigma_2^2)$

*Bemerkung.* Es gilt auch die Umkehrung:

Sind  $X$  und  $Y$  stu und  $X + Y$  normalverteilt, so sind auch  $X$  und  $Y$  normalverteilt.

## 8.3 Die $k$ -dimensionale Normalverteilung

**Definition 8.21 ( $k$ -dimensionale Normalverteilung)**

Sei  $X : \Omega \rightarrow \mathbb{R}^k$ .  $X = (X_1, \dots, X_k)$  heißt  $k$ -dimensional (multivariat) standardnormalverteilt, wenn  $X$  eine stetige Verteilung mit Dichte

$$f_X(x) = \left(\frac{1}{\sqrt{2\pi}}\right)^k \exp\left(-\frac{1}{2} \sum x_i^2\right) \quad x = (x_1, \dots, x_k) \in \mathbb{R}^k$$

besitzt:  $X \sim N_k(0, I_k)$ .

**Satz 8.22**

$$X \sim N_k(0, I_k) \quad \Leftrightarrow \quad X_1, \dots, X_k \text{ stu, } X_i \sim N(0, 1) \quad \forall i = 1, \dots, k.$$

*Beweis.*

$$\begin{aligned} X_1, \dots, X_k \text{ stu} &\stackrel{7.10}{\Leftrightarrow} f_X(x) = \prod_{i=1}^k f_{X_i}(x_i) \\ &\stackrel{X_i \sim N(0,1)}{=} \prod_{i=1}^k \varphi(x_i) \\ &= \left(\frac{1}{\sqrt{2\pi}}\right)^k \exp\left(-\frac{1}{2} \sum x_i^2\right) \end{aligned}$$

□

**Definition 8.23**

Sei  $X \sim N_k(0, I_k)$  und  $A \in \mathbb{R}^{p,k}$  sowie  $\mu \in \mathbb{R}^p$ . Dann heißt

$$Y = AX + \mu$$

$p$ -dimensional normalverteilt:

$$Y \sim N_p(\mu, \Sigma) \quad \text{mit } \Sigma = A A^\top$$

**Satz 8.24**

$$Y \sim N_p(\mu, \Sigma) \Rightarrow \begin{aligned} \mathbb{E}(Y) &= \mu \\ \mathbb{V}(Y) &= \Sigma \end{aligned}$$

*Beweis.*

Satz 7.17

□

**Satz 8.25**

Wenn  $A \in \mathbb{R}^{k,k}$  invertierbar, dann hat  $Y \sim N_k(\mu, \Sigma)$  die Dichte  $f_Y : \mathbb{R}^k \rightarrow \mathbb{R}$

$$f_Y(y) = \frac{1}{\sqrt{(2\pi)^k \det(\Sigma)}} \exp\left(-\frac{(y-\mu)^\top \Sigma^{-1} (y-\mu)}{2}\right)$$

mit  $\Sigma = A A^\top$ .

*Beweis.*

Mit Satz 7.7 gilt für allgemeine  $Y = A X + \mu$

$$f_Y(y) = f_X(A^{-1}(y-\mu)) \cdot |\det(A)|^{-1} \quad \text{vgl. Übung}$$

Also wegen

$$f_X(x) = \frac{1}{\sqrt{(2\pi)^k}} \exp\left(-\frac{1}{2} x^\top x\right)$$

gilt

$$\begin{aligned} f_Y(y) &= f_X(A^{-1}(y-\mu)) \cdot |\det(A)|^{-1} \\ &= \frac{|\det(A)|^{-1}}{\sqrt{(2\pi)^k}} \exp\left(-\frac{1}{2} (y-\mu)^\top A^{-1\top} A^{-1} (y-\mu)\right) \end{aligned}$$

und wegen  $A^{-1\top} A^{-1} = (A A^\top)^{-1} = \Sigma^{-1}$  und  $0 \leq \det(\Sigma) = \det(A^\top A) = \det(A)^2$  folgt

$$f_Y(y) = \frac{1}{\sqrt{(2\pi)^k \det(\Sigma)}} \exp\left(-\frac{(y-\mu)^\top \Sigma^{-1} (y-\mu)}{2}\right)$$

□

**Satz 8.26**



- a)  $Y \sim N_k(\mu, \Sigma) \Rightarrow Y_i \sim N(\mu_i, \Sigma_{ii}) \quad \forall i = 1, \dots, k$
- b)  $Y \sim N_k(\mu, \Sigma) \Leftrightarrow n^\top Y \sim N_1(n^\top \mu, n^\top \Sigma n) \quad \forall n \in \mathbb{R}^k$
- c)  $(Y_1, Y_2) \sim N_2(\mu, \Sigma)$  mit  $\mu = (\mu_1, \mu_2)$  und  $\Sigma = \begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}$
- $$Y_1, Y_2 \text{ stu} \Leftrightarrow \Sigma_{12} = \Sigma_{21} = 0$$

*Beweis.*

- a), b) [Meintrup and Schäffler \(2005\)](#) Seite 197ff
- c) HA

□

## 8.4 Gamma- und $\chi^2$ -Verteilung

**Definition 8.27** ( $\Gamma$ -Funktion)

$$\Gamma : \mathbb{R}^+ \rightarrow \mathbb{R}^+$$

$$\Gamma(z) = \int_0^{\infty} t^{z-1} e^{-t} dt$$

**Satz 8.28** (Eigenschaften der  $\Gamma$ -Funktion)

- $\Gamma(z+1) = z\Gamma(z)$
- $\Gamma(1) = 1$
- $\Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$
- $\Gamma(m+1) = m! \quad m \in \mathbb{N}$
- $\Gamma\left(\frac{k+1}{2}\right) = \frac{k-1}{2} \cdot \frac{k-3}{2} \cdot \dots \cdot \frac{3}{2} \cdot \frac{1}{2} \cdot \sqrt{\pi}$  falls  $k$  gerade.

*Beweis.*

PI

□

**Definition 8.29**

Eine ZV  $X$  mit stetiger Dichte

$$f_X(x; k, \lambda) = \frac{\lambda}{\Gamma(k)} (\lambda x)^{k-1} \exp(-\lambda x) \cdot I_{(0, \infty)}(x)$$

Mit  $k > 0$  und  $\lambda > 0$  heißt  $\Gamma$ -verteilt:  $X \sim \Gamma(k, \lambda)$ .

**Satz 8.30**

$$\Gamma(k = 1, \lambda) = \text{Exp}(\lambda)$$

*Beweis.*

klar. □

**Satz 8.31**

$$\mathbb{E}(X) = \frac{k}{\lambda}, \quad \mathbb{V}(X) = \frac{k}{\lambda^2} \quad \text{und} \quad M_X(s) = \left( \frac{\lambda}{\lambda - s} \right)^k \quad \text{für } s < \lambda.$$

*Beweis.*

$$\begin{aligned} M_X(s) &= \mathbb{E}(\exp(sX)) \\ &= \int_0^{\infty} \frac{\lambda}{\Gamma(k)} (\lambda x)^{k-1} \exp(-\lambda x) \exp(sx) dx \\ &= \int_0^{\infty} \frac{\lambda^k}{\Gamma(k)} x^{k-1} \exp((-\lambda + s)x) dx \\ &= \lambda^k \int_0^{\infty} \frac{1}{\Gamma(k)} x^{k-1} \exp(-(\lambda - s)x) dx \\ &\stackrel{\text{Kreative 1}}{=} \frac{\lambda^k}{(\lambda - s)^k} \underbrace{\int_0^{\infty} \frac{(\lambda - s)^k}{\Gamma(k)} x^{k-1} \exp(-(\lambda - s)x) dx}_{\text{Dichte } \Gamma(k, \lambda - s) \equiv 1} \\ &= \frac{\lambda^k}{(\lambda - s)^k} \\ \Rightarrow \frac{\partial M_X(s)}{\partial s} \Big|_{s=0} &= k \cdot \lambda^k \cdot (\lambda - s)^{-k-1} \Big|_{s=0} \\ &= \frac{k \cdot \lambda^k}{\lambda^{k+1}} = \frac{k}{\lambda} = \mathbb{E}(X) \\ \frac{\partial^2 M_X(s)}{\partial^2 s} \Big|_{s=0} &= k(k+1) \lambda^k (\lambda - s)^{-k-2} \\ &= \frac{k(k+1)}{\lambda^2} = \mathbb{E}(X^2) \end{aligned}$$

$$\text{Zusammen: } \mathbb{V}(X) = \mathbb{E}(X^2) - \mathbb{E}(X)^2 = \frac{k(k+1)}{\lambda^2} - \frac{k^2}{\lambda^2} = \frac{k}{\lambda^2} \quad \square$$

*Bemerkung.*

$$\begin{aligned} \int_0^{\infty} f_X(x) dx &= \frac{1}{\Gamma\left(\frac{k}{2}\right)} \cdot \int_0^{\infty} \frac{x^{\frac{k}{2}-1}}{2^{\frac{k}{2}}} \exp\left(-\frac{1}{2}x\right) dx \\ &= \frac{1}{\Gamma\left(\frac{k}{2}\right)} \cdot \int_0^{\infty} \frac{1}{2} \left(\frac{x}{2}\right)^{\frac{k}{2}-1} \exp\left(-\frac{x}{2}\right) dx \\ &\stackrel{t=\frac{x}{2}, dx=dt \cdot 2}{=} \frac{1}{\Gamma\left(\frac{k}{2}\right)} \cdot \underbrace{\int_0^{\infty} t^{\frac{k}{2}-1} \exp(-t) dt}_{\Gamma\left(\frac{k}{2}\right)} = 1 \end{aligned}$$

### Definition 8.32

Eine ZV  $X$  mit stetiger Dichte

$$f_X(x; k) = \frac{1}{\Gamma\left(\frac{k}{2}\right)} \left(\frac{1}{2}\right)^{\frac{k}{2}} x^{\frac{k}{2}-1} \exp\left(-\frac{1}{2}x\right) \cdot I_{(0,\infty)}(x)$$

heißt  $\chi^2$ -verteilt mit  $k$  Freiheitsgraden:  $X \sim \chi_k^2$ .

*Bemerkung.*

$$\Gamma\left(\frac{k}{2}, \frac{1}{2}\right) = \chi_k^2$$

### Satz 8.33

$$\mathbb{E}(X) = k, \quad \mathbb{V}(X) = 2k, \quad M_X(s) = \left(\frac{1}{1-2s}\right)^{\frac{k}{2}} \quad s < \frac{1}{2}$$

*Beweis.*

Satz 8.31 mit  $k = \frac{k}{2}$  und  $\lambda = \frac{1}{2}$ . □

### Satz 8.34

$X_1, \dots, X_n$  stu mit  $X_i \sim N(0, 1)$ . Dann

$$Y = \sum_{i=1}^n X_i^2 \sim \chi_n^2.$$

*Beweis.*

$$\begin{aligned}
M_Y(s) &= \mathbb{E}(\exp(sY)) \\
&= \mathbb{E}\left(\exp\left(s \sum_{i=1}^n X_i^2\right)\right) \\
&= \mathbb{E}\left(\prod_{i=1}^n \exp(s X_i^2)\right) \\
&\stackrel{X \text{ stu}}{=} \prod_{i=1}^n \mathbb{E}(\exp(s X_i^2))
\end{aligned}$$

Aber

$$\begin{aligned}
\mathbb{E}(\exp(s X_i^2)) &= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2} x^2\right) \cdot \exp(s x^2) dx \\
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(\left(-\frac{1}{2} + s\right) x^2\right) dx \\
&= \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2} (1 - 2s) x^2\right) dx \\
&\stackrel{\text{Kreative 1}}{=} \frac{1}{\sqrt{1 - 2s}} \underbrace{\int_{-\infty}^{\infty} \frac{\sqrt{1 - 2s}}{\sqrt{2\pi}} \exp\left(-\frac{1}{2} (1 - 2s) x^2\right) dx}_{\equiv 1, \text{ da der Integrand die Dichte von } N(0, (1-2s)^{-1}) \text{ ist.}} \\
&= \frac{1}{\sqrt{1 - 2s}}
\end{aligned}$$

Zusammen:

$$\begin{aligned}
M_Y(s) &= \prod_{i=1}^n \mathbb{E}(\exp(s X_i^2)) \\
&= \prod_{i=1}^n \frac{1}{\sqrt{1 - 2s}} = \underbrace{\left(\frac{1}{1 - 2s}\right)^{\frac{n}{2}}}_{\text{Momentengenerierende Fkt. von } \chi_n^2 \text{ nach Satz 8.33}}
\end{aligned}$$

□

## 8.5 t- und F-Verteilung

### Satz 8.35

Sei  $U \sim \chi_m^2$  und  $V \sim \chi_n^2$  stu. Dann hat die Zufallsvariable

$$X = \frac{U/m}{V/n}$$

eine stetige Verteilung mit Dichte

$$f_X(x; m, n) = \frac{\Gamma\left(\frac{m+n}{2}\right)}{\Gamma\left(\frac{m}{2}\right) \Gamma\left(\frac{n}{2}\right)} \left(\frac{m}{n}\right)^{\frac{m}{2}} \frac{x^{\frac{m-2}{2}}}{\left(1 + \left(\frac{m}{n}\right) \cdot x\right)^{\frac{m+n}{2}}} \cdot I_{(0,\infty)}(x)$$

*Beweis.*

$$f_{U,V}(u, v) \stackrel{\text{stu}}{=} \frac{1}{\Gamma\left(\frac{m}{2}\right) \Gamma\left(\frac{n}{2}\right) \cdot 2^{\frac{m+n}{2}}} u^{\frac{m-2}{2}} v^{\frac{n-2}{2}} \cdot \exp\left(-\frac{1}{2}(u+v)\right) \cdot I_{(0,\infty)}(u) \cdot I_{(0,\infty)}(v)$$

$$g(u, v) = \left( \underbrace{\frac{u/m}{v/n}}_x, \underbrace{v}_y \right)$$

$$h(x, y) = \left( xy \frac{m}{n}, y \right)$$

$$J = \frac{\partial h(x, y)}{\partial x \partial y} = \begin{pmatrix} y \frac{m}{n} & 0 \\ x \frac{m}{n} & 1 \end{pmatrix} \Rightarrow |J| = y \frac{m}{n}$$

Trafo  
 $\Rightarrow$

$$f_{X,Y}(x, y) = \frac{m}{n} \cdot y \cdot \frac{1}{\Gamma\left(\frac{m}{2}\right) \Gamma\left(\frac{n}{2}\right) 2^{\frac{m+n}{2}}} \left(\frac{m}{n} xy\right)^{\frac{m-2}{2}} \cdot y^{\frac{n-2}{2}} \cdot \exp\left(-\frac{1}{2}\left(\frac{m}{n} xy + y\right)\right)$$

$$f_X(x) = \int_0^{\infty} f_{X,Y}(x, y) dy$$

$$= \underbrace{\frac{1}{\Gamma\left(\frac{m}{2}\right) \Gamma\left(\frac{n}{2}\right) 2^{\frac{m+n}{2}}} \left(\frac{m}{n}\right)^{\frac{m}{2}} x^{\frac{m-2}{2}}}_{=: A} \int_0^{\infty} y^{\frac{m+n-2}{2}} \exp\left(-\frac{1}{2}\left(\frac{m}{n} x + 1\right) y\right) dy$$

$$= A \cdot \int_0^{\infty} y^{(m+n-2)} \exp\left(-\frac{1}{2}\left(\frac{m}{n} x + 1\right) y\right) dy$$

$$\stackrel{\text{div. Umformungen}}{=} \frac{\Gamma\left(\frac{m+n}{2}\right)}{\Gamma\left(\frac{m}{2}\right) \Gamma\left(\frac{n}{2}\right)} \left(\frac{m}{n}\right)^{\frac{m}{2}} \frac{x^{\frac{m-2}{2}}}{\left(1 + \frac{m}{n} \cdot x\right)^{\frac{m+n}{2}}} \cdot I_{(0,\infty)}(x)$$

□ check

**Definition 8.36** (*F-Verteilung*)

Eine ZV  $X$  mit Dichte  $f_X$  heißt *F-verteilt* mit Freiheitsgraden  $m$  und  $n$ :  $X \sim F_{m,n}$ .

**Satz 8.37**

$$\begin{aligned} X \sim F_{m,n} \Rightarrow \mathbb{E}(X) &= \frac{n}{n-2} \text{ für } n > 2 \text{ und} \\ \mathbb{V}(X) &= \frac{2n^2(m+n-2)}{m(n-2)^2(n-4)} \text{ für } n > 4 \end{aligned}$$

*Beweis.*

$$\mathbb{E}(X) = \mathbb{E}\left(\frac{U/m}{V/n}\right) \stackrel{\text{stu}}{=} \left(\frac{m}{n}\right)^{-1} \mathbb{E}(U) \cdot \mathbb{E}\left(\frac{1}{V}\right) = \left(\frac{m}{n}\right)^{-1} \cdot m \cdot \underbrace{\mathbb{E}\left(\frac{1}{V}\right)}_{= \frac{1}{n-2} \text{ o.B.}} = \frac{n}{n-2} \quad \square$$

*Bemerkung.*

$$X \sim F_{m,n} \Rightarrow \frac{1}{X} \sim F_{n,m}$$

**Satz 8.38**

Sei  $Z \sim N(0, 1)$  und  $U \sim \chi_k^2$  stu. Dann hat

$$X = \frac{Z}{\sqrt{U/k}}$$

eine Verteilung mit Dichte

$$f_X(x) = \frac{\Gamma\left(\frac{k+1}{2}\right)}{\Gamma\left(\frac{k}{2}\right)} \frac{1}{\sqrt{k\pi}} \frac{1}{\left(1 + \frac{x^2}{k}\right)^{\frac{k+1}{2}}}$$

*Beweis.*

$$f_{Z,U}(z, u) = \frac{1}{\sqrt{2\pi}} \frac{1}{\Gamma\left(\frac{k}{2}\right)} \left(\frac{1}{2}\right)^{\frac{k}{2}} u^{\frac{k}{2}-1} \exp\left(-\frac{1}{2}u\right) \exp\left(-\frac{1}{2}z^2\right) I_{(0,\infty)}(u)$$

$$g(z, u) = (x, y) = \left(\frac{z}{\sqrt{u/k}}, u\right)$$

$$\Rightarrow |J| = \sqrt{y/k} \text{ und}$$

$$\int_{-\infty}^{\infty} f_{X,Y}(x, y) dy = f_X(x) \text{ wie oben angegeben.} \quad \square$$

**Definition 8.39** (*t-Verteilung*)

Eine ZV  $X$  mit Dichte  $f_X$  heißt *t-verteilt* mit  $k$  Freiheitsgraden:  $X \sim t_k$ .

**Satz 8.40**

a)  $\mathbb{E}(X) = 0$

b)  $\mathbb{V}(X) = \frac{k}{k-2}$

*Beweis.*a) Symmetrie in  $x$ 

b) geschenkt.

□

# Kapitel 9

## Konvergenz und Wahrscheinlichkeit

### 9.1 Konvergenzarten

#### Beispiel 9.1

$X_i \sim B(1, \frac{1}{2}) \quad i = 1, 2, \dots$  stu.

$$Y_n = \sum_{i=1}^n X_i \sim B(n, \frac{1}{2})$$

Wie groß ist der Abstand  $\frac{1}{n} Y_n - \frac{1}{2}$  ?

$$Z_i = 1 - X_i$$

$Z_i \neq X_i$  aber  $Z_i$  und  $X_i$  haben die gleiche Verteilung.

#### Definition 9.1 (Konvergenzarten)

Sei  $(\Omega, \mathcal{F}, \mathbb{P})$  W'keitsraum und  $X_i : \Omega \rightarrow \mathbb{R}$  ZV,  $i = 1, 2, \dots$ . Dann konvergiert die Folge  $(X_n)_{n \in \mathbb{N}}$  gegen eine ZV  $X : \Omega \rightarrow \mathbb{R}$

a) fast sicher, wenn

$$\mathbb{P}(\{\omega \in \Omega \mid X_n(\omega) \rightarrow X(\omega) \text{ f\"ur } n \rightarrow \infty\}) = 1;$$

$$X_n \xrightarrow{\text{f.s.}} X, X_n \xrightarrow{\text{a.s.}} X, X_n \xrightarrow{\text{a.e.}} X, X_n \rightarrow X \text{ wp 1.}$$

b) im  $r$ -ten Moment,  $r \geq 1$ , wenn

$$\mathbb{E}(|X_n|^r) < \infty \quad \forall n \quad \text{und} \quad \mathbb{E}(|X_n - X|^r) \rightarrow 0 \quad \text{f\"ur } n \rightarrow \infty;$$

$$X_n \xrightarrow{r} X$$

c) in Wahrscheinlichkeit, falls

$$\mathbb{P}(|X_n - X| > \epsilon) \rightarrow 0 \quad \text{f\"ur } n \rightarrow \infty \quad \forall \epsilon > 0;$$

$$X_n \xrightarrow{\mathbb{P}} X$$



d) in Verteilung, falls

$$\lim_{n \rightarrow \infty} \mathbb{P}(X_n \leq x) = \mathbb{P}(X \leq x)$$

und alle Stetigkeitsstellen von  $F_X(x) = \mathbb{P}(X \leq x)$ ;

$$X_n \xrightarrow{D} X$$

*Bemerkung.* a)  $\Omega = \{\omega \in \Omega \mid \lim_{n \rightarrow \infty} X_n(\omega) = X(\omega)\} =: A$  ist uninteressant, da keine W'keit vorkommt. Konvergenz fast sicher meint, daß  $\bar{A}$  eine Nullmenge bzgl.  $\mathbb{P}$  ist. Vgl. Def. 3.25

b) Schreibweisen:  $X_n \xrightarrow{2} X$  heißt

$$\mathbb{E}(|X_n - X|^2) \rightarrow 0 \quad \text{Vgl. Def. 3.24} \quad L^p\text{-Konvergenz}$$

$$\text{c) } \mathbb{P}(|X_n - X| > \epsilon) = \int I_{A_n} d\mathbb{P}$$

$$\text{mit } A_n = \{\omega \in \Omega \mid |X_n(\omega) - X(\omega)| > \epsilon\}$$

d)  $X_n(\omega) \neq X(\omega) \quad \forall \omega \in \Omega, \forall n$

aber  $X_n \xrightarrow{D} X$  ist erlaubt.

**Beispiel 9.2 (Fortsetzung)** •  $Z_i \xrightarrow{D} X_1$  denn  $Z_i \sim B(1, \frac{1}{2}), X_1 \sim B(1, \frac{1}{2})$

aber  $Z_i \neq X_1$

$$\mathbb{E}\left(\frac{1}{n} Y_n\right) = \frac{1}{n} n p = p$$

$$\Rightarrow \mathbb{E}\left(\left(\frac{1}{n} Y_n - p\right)^2\right) = \mathbb{V}\left(\frac{1}{n} Y_n\right) = \frac{1}{n^2} n p (1-p) = \frac{1}{n} p (1-p) \rightarrow 0$$

und damit  $\frac{1}{n} Y_n \xrightarrow{r=2} p$

$$\mathbb{E}\left(\frac{1}{n} Y_n\right) = \frac{1}{n} \mathbb{E}(Y_n) = \frac{1}{n} n p = p$$

$$\mathbb{P}\left(\left|\frac{1}{n} Y_n - \mathbb{E}\left(\frac{1}{n} Y_n\right)\right| > \epsilon\right) \stackrel{\text{Tschebyschev}}{\leq} \frac{\mathbb{V}\left(\frac{1}{n} Y_n\right)}{\epsilon^2} = \frac{\frac{1}{n^2} n p (1-p)}{\epsilon^2} = \frac{\frac{1}{n} p (1-p)}{\epsilon^2} \rightarrow 0$$

für  $n \rightarrow \infty$

und damit  $\frac{1}{n} Y_n \xrightarrow{\mathbb{P}} p = \frac{1}{2}$

**Satz 9.2**

Sei  $(X_n)_{n \in \mathbb{N}}$ , Folge von ZV  $X_i : \Omega \rightarrow \mathbb{R}$  und  $X : \Omega \rightarrow \mathbb{R}$  ZV. Dann gilt

- a)  $X_n \xrightarrow{\mathbb{P}} X \Rightarrow X_n \xrightarrow{D} X$
- b)  $X_n \xrightarrow{\text{f.s.}} X \Rightarrow X_n \xrightarrow{\mathbb{P}} X$
- c)  $X_n \xrightarrow{r} X \Rightarrow X_n \xrightarrow{\mathbb{P}} X$  für  $r \geq 1$
- d)  $X_n \xrightarrow{r} X \Rightarrow X_n \xrightarrow{s} X$   $r > s \geq 1$

*Beweis.*

a)

$$\begin{aligned} X_n \xrightarrow{\mathbb{P}} X; \quad F_n(x) &= \mathbb{P}(X_n \leq x) \\ F(x) &= \mathbb{P}(X \leq x) \end{aligned}$$

Es gilt für  $\epsilon > 0$

$$\begin{aligned} F_n(x) &= \mathbb{P}(X_n \leq x) = \mathbb{P}(X_n \leq x, X \leq x + \epsilon) + \mathbb{P}(X_n \leq x, X > x + \epsilon) \\ &\leq F(x + \epsilon) + \mathbb{P}(|X_n - X| > \epsilon) \end{aligned}$$

und

$$\begin{aligned} F(x - \epsilon) &= \mathbb{P}(X \leq x - \epsilon) = \mathbb{P}(X \leq x - \epsilon, X_n \leq x) + \mathbb{P}(X \leq x - \epsilon, X_n > x) \\ &\leq F_n(x) + \mathbb{P}(|X_n - X| > \epsilon) \end{aligned}$$

Zusammen:

$$F(x - \epsilon) - \mathbb{P}(|X_n - X| > \epsilon) \leq F_n(x) \leq F(x + \epsilon) + \mathbb{P}(|X_n - X| > \epsilon)$$

Für  $n \rightarrow \infty$  gilt

$$F(x - \epsilon) - \underbrace{\mathbb{P}(|X_n - X| > \epsilon)}_{\rightarrow 0} \leq F_n(x) \leq F(x + \epsilon) + \underbrace{\mathbb{P}(|X_n - X| > \epsilon)}_{\rightarrow 0}$$

$$\Rightarrow F(x - \epsilon) \leq \liminf_{n \rightarrow \infty} F_n(x) \leq \limsup_{n \rightarrow \infty} F_n(x) \leq F(x + \epsilon)$$

Falls  $F$  stetig ist, gilt

$$F(x) \leq \liminf_{n \rightarrow \infty} F_n(x) \leq \limsup_{n \rightarrow \infty} F_n(x) \leq F(x)$$

$$\Rightarrow F(x) = \lim_{n \rightarrow \infty} F_n(x)$$

$$\Rightarrow X_n \xrightarrow{D} X$$

d) Korollar 3.26

c)  $r = 1$  reicht. Dann

$$\mathbb{P}(|X_n - X| > \epsilon) \leq \frac{\mathbb{E}(|X_n - X|)}{\epsilon} \quad (\text{Markov für } X_n - X)$$

b) Sei

$$A_n(\epsilon) = \{\omega \in \Omega \mid |X_n(\omega) - X(\omega)| > \epsilon\}$$

und

$$B_m(\epsilon) = \bigcup_{n \geq m} A_n(\epsilon)$$

sowie

$$C = \{\omega \in \Omega \mid X_n(\omega) \rightarrow X(\omega) \text{ für } n \rightarrow \infty\}$$

sowie

$$A(\epsilon) = \bigcap_m \bigcup_{n=m}^{\infty} A_n(\epsilon) = \{\omega \in \Omega \mid \omega \in A_n(\epsilon) \text{ für unendlich viele } n\}$$

$$X_n(\omega) \rightarrow X(\omega) \Leftrightarrow \omega \notin A(\epsilon) \quad \forall \epsilon > 0$$

$$\text{somit: } \mathbb{P}(C) = 1 \Rightarrow \mathbb{P}(A(\epsilon)) = 0 \quad \forall \epsilon > 0$$

$$\text{Falls } \mathbb{P}(A(\epsilon)) = 0 \quad \forall \epsilon > 0 \Rightarrow$$

$$\mathbb{P}(\bar{C}) = \mathbb{P}\left(\bigcup_{\epsilon > 0} A(\epsilon)\right) = \mathbb{P}\left(\bigcup_{m=1}^{\infty} A\left(\frac{1}{m}\right)\right) \leq \underbrace{\sum_{m=1}^{\infty} \mathbb{P}\left(A\left(\frac{1}{m}\right)\right)}_{=0 \text{ nach Vor.}} = 0$$

$$\Rightarrow \mathbb{P}(C) = 1 \Leftrightarrow \mathbb{P}(A(\epsilon)) = 0 \quad \forall \epsilon > 0$$

$$\text{Weiterhin } B_m(\epsilon) \downarrow A(\epsilon) \Rightarrow$$

$$\mathbb{P}(A(\epsilon)) = 0 \Leftrightarrow \lim_{m \rightarrow \infty} \mathbb{P}(B_m(\epsilon)) = 0$$

Zusammen:

$$X_n \xrightarrow{\text{f.s.}} X \Leftrightarrow \mathbb{P}(B_m(\epsilon)) \rightarrow 0 \quad \text{für } m \rightarrow \infty$$

Weiterhin

$$X_n \xrightarrow{\text{f.s.}} X \Leftrightarrow \sum_n \mathbb{P}(A_n(\epsilon)) < \infty \quad \forall \epsilon > 0, \text{ denn}$$

$$\mathbb{P}(B_m(\epsilon)) \leq \sum_{n=m}^{\infty} \mathbb{P}(A_n(\epsilon))$$

$$\begin{aligned}
& \text{(Borel-Cantelli) Schlußendlich: } A_n(\epsilon) \subseteq B_n(\epsilon) \\
& \Rightarrow \mathbb{P}(A_n(\epsilon)) \leq \mathbb{P}(B_n(\epsilon)) \\
& \Leftrightarrow \mathbb{P}(|X_n - X| > \epsilon) \leq \mathbb{P}(B_n(\epsilon)) \\
& \Rightarrow \mathbb{P}(|X_n - X| > \epsilon) \rightarrow 0 \quad \text{falls} \quad \mathbb{P}(B_n(\epsilon)) \rightarrow 0 \\
& \Leftrightarrow X_n \xrightarrow{\mathbb{P}} X \quad \Leftarrow \quad X_n \xrightarrow{\text{f.s.}} X \quad \Leftarrow \quad \mathbb{P}(B_n(\epsilon)) \rightarrow 0 \quad \text{für } n \rightarrow \infty.
\end{aligned}$$

□

*Bemerkung.* Andere Beziehungen gelten so allgemein nicht.

$$\bullet X_n \xrightarrow{s} X \not\Leftarrow X_n \xrightarrow{r} X \quad r > s \geq 1$$

Betrachte

$$\begin{aligned}
X_n &= \begin{cases} n & \text{mit Wahrscheinlichkeit } n^{-\frac{1}{2}(r+s)} \\ 0 & \text{mit Wahrscheinlichkeit } 1 - n^{-\frac{1}{2}(r+s)} \end{cases} \\
\mathbb{E}(|X_n|^s) &= n^s \cdot n^{-\frac{1}{2}(r+s)} \\
&= n^{\frac{1}{2}(s-r)} \rightarrow 0 \quad \text{weil } s < r \\
\mathbb{E}(|X_n|^r) &= n^r \cdot n^{-\frac{1}{2}(r+s)} \\
&= n^{\frac{1}{2}(r-s)} \rightarrow \infty \quad \text{weil } r > s
\end{aligned}$$

und somit  $X_n \xrightarrow{s} 0$  aber nicht  $X_n \xrightarrow{r} 0$

$$\bullet X_n \xrightarrow{\mathbb{P}} X \not\Leftarrow X_n \xrightarrow{1} X$$

Betrachte

$$\begin{aligned}
X_n &= \begin{cases} n^3 & \text{mit Wahrscheinlichkeit } n^{-2} \\ 0 & \text{mit Wahrscheinlichkeit } 1 - n^{-2} \end{cases} \\
\mathbb{P}(|X_n| > \epsilon) &= n^{-2} \rightarrow 0 \quad \Leftrightarrow \quad X_n \xrightarrow{\mathbb{P}} 0
\end{aligned}$$

Aber  $\mathbb{E}(|X_n|) = n^3 \cdot n^{-2} = n \rightarrow \infty$

### Satz 9.3

$$\text{a) } X_n \xrightarrow{D} c \text{ konstant} \quad \Rightarrow \quad X_n \xrightarrow{\mathbb{P}} c$$

$$\text{b) } X_n \xrightarrow{\mathbb{P}} X \quad \text{und} \quad \mathbb{P}(|X_n| \leq k) = 1 \quad \forall n \text{ und ein } k \in \mathbb{R}^+$$

$$\Rightarrow X_n \xrightarrow{r} X \quad \forall r \geq 1$$

$$\begin{aligned} \text{c) } P_n(\epsilon) &= \mathbb{P}(|X_n - X| > \epsilon) \quad \text{mit} \quad \sum_n P_n(\epsilon) < \infty \quad \forall \epsilon > 0 \\ &\Rightarrow X_n \xrightarrow{\text{f.s.}} X \end{aligned}$$

*Beweis.*

a)

$$\begin{aligned} \mathbb{P}(|X_n - c| > \epsilon) &= \mathbb{P}(X_n < c - \epsilon) + \mathbb{P}(X_n > c + \epsilon) \\ &\leq \mathbb{P}(X_n \leq c - \epsilon) + (1 - \mathbb{P}(X_n \leq c + \epsilon)) \\ &\rightarrow \mathbb{P}(X \leq c - \epsilon) + (1 - \mathbb{P}(X \leq c + \epsilon)) \\ &= 0 + (1 - 1) = 0 \end{aligned}$$

$$\text{b) } X_n \xrightarrow{\mathbb{P}} X, \quad \mathbb{P}(|X_n| \leq k) = 1 \quad \Rightarrow \quad \mathbb{P}(|X| \leq k) = 1$$

$$\text{weil} \quad \mathbb{P}(|X| \leq k + \epsilon) = \lim_{n \rightarrow \infty} \mathbb{P}(|X_n| \leq k + \epsilon) = 1 \quad \forall \epsilon > 0$$

$$\text{Sei} \quad A_n(\epsilon) = \{\omega \in \Omega \mid |X_n(\omega) - X(\omega)| > \epsilon\}$$

Dann gilt:

$$|X_n(\omega) - X(\omega)|^r \leq \epsilon^r \quad \omega \in \overline{A_n(\epsilon)}$$

bzw.

$$|X_n(\omega) - X(\omega)|^r \leq (2k)^r \quad \omega \in A_n(\epsilon)$$

jeweils mit W'keit 1. Also

$$|X_n - X|^r \leq \epsilon^r I_{\overline{A_n(\epsilon)}} + (2k)^r I_{A_n(\epsilon)}$$

$$\begin{aligned} \mathbb{E}(|X_n - X|^r) &\leq \epsilon^r \mathbb{P}(\overline{A_n(\epsilon)}) + (2k)^r \mathbb{P}(A_n(\epsilon)) \\ &= ((2k)^r - \epsilon^r) \underbrace{\mathbb{P}(A_n(\epsilon))}_{\rightarrow 0} + \epsilon^r \\ &\rightarrow \epsilon^r \quad \text{für } n \rightarrow \infty \\ &\rightarrow 0 \quad \text{für } \epsilon \downarrow 0 \\ &\Rightarrow X_n \xrightarrow{r} X \end{aligned}$$

c) Siehe Beweis zu Satz 9.2 b)

□

## 9.2 Konvergenz in Wahrscheinlichkeit

### Satz 9.4 (Schwaches Gesetz der großen Zahlen)

Seien  $X_1, \dots, X_n$  unabhängig und identisch verteilt mit  $\mathbb{E}(X_i) = \mu$  und  $\mathbb{V}(X_i) = \sigma^2 < \infty \quad \forall i = 1, \dots, n$ . Dann gilt

$$\bar{X} := \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{\mathbb{P}} \mu.$$

*Beweis.*

$\bar{X} \xrightarrow{2} \mu$  denn

$$\mathbb{E}(\bar{X}) = \frac{1}{n} \sum (\mathbb{E}(X_i)) = \frac{1}{n} n \mu = \mu$$

und

$$\mathbb{E}(|\bar{X} - \mu|^2) = \mathbb{V}(\bar{X}) = \frac{1}{n^2} n \sigma^2 = \frac{1}{n} \sigma^2 \rightarrow 0$$

Satz 9.2c)  $\Rightarrow \bar{X} \xrightarrow{\mathbb{P}} \mu$

□

### Beispiel 9.3

$X_i \sim P(\lambda)$  stu.  $\Rightarrow \mathbb{E}(X_i) = \lambda, \quad \mathbb{V}(X_i) = \lambda, i = 1, \dots, n$  und  $\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{\mathbb{P}} \lambda$

*Bemerkung.*  $\mathbb{V}(X_i) = \sigma^2 < \infty$  ist nicht notwendig,  $\sigma^2 = \infty$  funktioniert auch (sog. Satz von Khinchine).

### Satz 9.5 (Eindeutigkeit der Konvergenz)

$$X_n \xrightarrow{\mathbb{P}} X \quad \text{und} \quad X_n \xrightarrow{\mathbb{P}} \tilde{X} \quad \Rightarrow \quad \mathbb{P}(X = \tilde{X}) = 1$$

*Beweis.*

Sei  $\epsilon > 0$ , dann

$$\begin{aligned} 0 &\leq \mathbb{P}(|X - \tilde{X}| \geq \epsilon) = \mathbb{P}(|X - X_n + X_n - \tilde{X}| \geq \epsilon) \\ &\leq \mathbb{P}(|X - X_n| + |\tilde{X} - X_n| \geq \epsilon) \\ &\leq \underbrace{\mathbb{P}\left(|X - X_n| \geq \frac{\epsilon}{2}\right)}_{\rightarrow 0 \text{ n.V.}} + \underbrace{\mathbb{P}\left(|\tilde{X} - X_n| \geq \frac{\epsilon}{2}\right)}_{\rightarrow 0 \text{ n.V.}} \\ &\rightarrow 0 \quad \forall \epsilon \end{aligned}$$

$$\begin{aligned} \mathbb{P}(X \neq \tilde{X}) &= \mathbb{P}\left(\bigcup_{k=1}^{\infty} |X - \tilde{X}| \geq \frac{1}{k}\right) \\ &\leq \sum_{k=1}^{\infty} \mathbb{P}\left(|X - \tilde{X}| \geq \frac{1}{k}\right) \\ &= \sum_{k=1}^{\infty} 0 = 0 \end{aligned}$$

□

**Satz 9.6**

Seien  $A_n$  und  $B_n$  Folgen von ZV mit  $A_n \xrightarrow{\mathbb{P}} a$  und  $B_n \xrightarrow{\mathbb{P}} b$ . Dann gilt

$$\text{a) } \begin{aligned} A_n + B_n &\xrightarrow{\mathbb{P}} a + b \\ A_n - B_n &\xrightarrow{\mathbb{P}} a - b \end{aligned}$$

$$\text{b) } A_n \cdot B_n \xrightarrow{\mathbb{P}} a \cdot b$$

$$\text{c) } \frac{A_n}{B_n} \xrightarrow{\mathbb{P}} \frac{a}{b} \quad \forall b \neq 0$$

*Beweis.*

Vorarbeit:

Seien  $E_n$  und  $F_n$  Folgen von Ereignissen ( $E_n \in \mathcal{F}, F_n \in \mathcal{F}$ ), dann gilt:

$$\mathbb{P}(E_n) \rightarrow 1 \quad \text{und} \quad \mathbb{P}(F_n) \rightarrow 1 \quad \Rightarrow \quad \mathbb{P}(E_n \cap F_n) \rightarrow 1$$

weil

$$1 - \mathbb{P}(E_n \cap F_n) = \mathbb{P}(\overline{E_n \cap F_n}) = \mathbb{P}(\bar{E}_n \cup \bar{F}_n) \leq \mathbb{P}(\bar{E}_n) + \mathbb{P}(\bar{F}_n) \rightarrow 0.$$

Hauptteil:

$$\mathbb{P}(|A_n - a| < \epsilon) \rightarrow 1$$

$$\mathbb{P}(|B_n - b| < \epsilon) \rightarrow 1$$

$$\begin{aligned} \Rightarrow \quad & \mathbb{P}(|A_n - a| < \epsilon \wedge |B_n - b| < \epsilon) \\ & \leq \mathbb{P}(|A_n - a + B_n - b| < \epsilon) \\ & = \mathbb{P}(|(A_n + B_n) - (a + b)| < \epsilon) \rightarrow 1 \end{aligned}$$

□

**Satz 9.7**

Sei  $X_n$  eine Folge von ZV mit  $X_n \xrightarrow{\mathbb{P}} c$  und  $f : \mathbb{R} \rightarrow \mathbb{R}$  eine in  $c \in \mathbb{R}$  stetige Funktion

$$\Rightarrow f(X_n) \xrightarrow{\mathbb{P}} f(c).$$

*Beweis.*

$f$  stetig in  $c \Leftrightarrow |f(x) - f(c)| < a, a > 0$  für ein  $b$  mit  $|x - c| < b$ .

$$\mathbb{P}(|f(X_n) - f(c)| < a) \geq \mathbb{P}(|X_n - c| < b) \rightarrow 1 \quad \forall a > 0$$

$$\Rightarrow f(X_n) \xrightarrow{\mathbb{P}} f(c)$$

□

*Bemerkung.* Die Ergebnisse lassen sich im Wesentlichen auf den  $k$ -dimensionalen Fall übertragen, siehe [Lehmann \(2001\)](#).

*Bemerkung.*  $X_n \xrightarrow{\mathbb{P}} c$  konstant  $\not\Rightarrow \mathbb{E}(X_n) \rightarrow c$

$$\text{z.B. } X_n = \begin{cases} 1 & \text{mit W'keit } 1 - p_n \\ n & \text{mit W'keit } p_n \end{cases}$$

Wenn  $p_n \rightarrow 0$ , dann auch  $\mathbb{P}(|X_n - 1| > \epsilon) \rightarrow 0 \Rightarrow X_n \xrightarrow{\mathbb{P}} 1$

Aber

$$\mathbb{E}(X_n) = (1 - p_n) + n p_n = 1 + (n - 1)p_n \rightarrow \infty \quad \text{für } p_n = \frac{1}{\sqrt{n}} \quad \text{z.B.}$$

### Beispiel 9.4

$X_n \sim N(\mu, \sigma_n^2), n = 1, \dots$

$X_n \xrightarrow{\mathbb{P}} \mu \Leftrightarrow \sigma_n^2 \rightarrow 0$ . Denn

$$\mathbb{P}(|X_n - \mu| \leq \epsilon) = \mathbb{P}\left(\underbrace{\left|\frac{X_n - \mu}{\sigma_n}\right|}_{\sim N(0,1)} \leq \frac{\epsilon}{\sigma_n}\right) \rightarrow 1 \quad \text{wenn } \frac{\epsilon}{\sigma_n} \rightarrow \infty \quad \text{und somit } \sigma_n \rightarrow 0.$$

## 9.3 Konvergenz in Verteilung

### Beispiel 9.5

$X_n \sim N(0, \sigma_n^2)$  mit Verteilungsfunktion  $H_n$  mit  $\sigma_n^2 \rightarrow \infty$

$$H_n(x) = \mathbb{P}\left(\frac{X_n}{\sigma_n} \leq \frac{x}{\sigma_n}\right) = \Phi\left(\frac{x}{\sigma_n}\right)$$

Mit  $\sigma_n^2 \rightarrow \infty$  folgt  $\frac{x}{\sigma_n} \rightarrow 0$  und somit  $H_n(x) \rightarrow \Phi(0) = \frac{1}{2} \quad \forall x \in \mathbb{R}$ . Deshalb

$$\lim_{n \rightarrow \infty} H_n(x) = H(x) \equiv \frac{1}{2}$$

und somit ist  $H$  keine Verteilungsfunktion und  $X_n$  konvergiert nicht in Verteilung.

### Satz 9.8

Sei  $(X_n)_{n \in \mathbb{N}}$  eine Folge von ZV mit Verteilungsfunktion  $X_n \sim F_n$ . Dann existiert  $X \sim F$  mit  $X_n \xrightarrow{D} X$  genau dann, wenn  $\forall \epsilon > 0$  eine Konstante  $k \in \mathbb{R}^+$  und  $n_0 \in \mathbb{N}$  existiert, so daß

$$\mathbb{P}(|X_n| \leq k) \geq 1 - \epsilon \quad \forall n \geq n_0.$$



*Beweis.*

Sei  $F$  derart, daß

$$\lim_{n \rightarrow \infty} F_n(x) = F(x) \quad \forall x \in \mathbb{R}.$$

z.Z.  $F$  ist Verteilungsfunktion, also

- $F(x) \in [0, 1]$     ✓
- $F$  monoton wachsend    ✓
- $F$  rechtsstetig    ✓
- $\lim_{x \rightarrow -\infty} F(x) = 0, \lim_{x \rightarrow \infty} F(x) = 1$

$$F_n(x) = \mathbb{P}(X_n \leq x) \geq 1 - \epsilon \quad \text{für } x \geq k, n > n_0 \text{ und } \forall \epsilon > 0$$

$$\text{also } \lim_{n \rightarrow \infty} F_n(x) = F(x) \geq 1 - \epsilon \quad \text{für } x \geq k \text{ und } \forall \epsilon > 0$$

$$\text{und } \lim_{x \rightarrow \infty} F(x) = 1 \quad \text{für } \epsilon \downarrow 0$$

□

### Beispiel 9.6

$$X \sim U(0, 1)$$

$$X_n = \begin{cases} X & n \text{ gerade} \\ 1 - X & n \text{ ungerade} \end{cases}$$

Dann

$$X_n \xrightarrow{D} X \text{ und}$$

$$X_n \xrightarrow{D} 1 - X \text{ nämlich}$$

$$X_n \xrightarrow{D} U(0, 1) \quad (\text{d.h. jede ZV, welche gleichverteilt auf } [0, 1] \text{ ist}).$$

$$Y_n \sim N(0, 1) \begin{cases} \xrightarrow{D} Y \sim N(0, 1) \\ \xrightarrow{D} -Y \sim N(0, 1) \end{cases} \quad \text{Grenzwert nicht eindeutig!}$$

### Beispiel 9.7

$$X_n \sim N(\mu_n, \sigma_n^2) \quad \mu_n \rightarrow 0, \sigma_n^2 \rightarrow 1$$

$$\Rightarrow X_n \xrightarrow{D} N(0, 1) \text{ weil}$$

$$X_n \sim H_n \text{ mit}$$

$$H_n(x) = \mathbb{P}\left(\frac{X_n - \mu_n}{\sigma_n} \leq \frac{x - \mu_n}{\sigma_n}\right) = \Phi\left(\frac{x - \mu_n}{\sigma_n}\right)$$

Wegen  $\frac{x - \mu_n}{\sigma_n} \rightarrow x$  folgt aus der Stetigkeit von  $\Phi$  auch  $H_n(x) \rightarrow \Phi(x)$  und somit  
 $X_n \xrightarrow{D} N(0, 1)$

**Satz 9.9**

$$X_n \xrightarrow{D} X, a, b \neq 0 \in \mathbb{R} \text{ konstant} \Rightarrow b X_n + a \xrightarrow{D} b X + a.$$

*Beweis.*

Sei o.B.d.A  $b > 0$ .

$$\begin{aligned} \mathbb{P}(b X_n + a \leq x) &= \mathbb{P}\left(X_n \leq \frac{x - a}{b}\right) = F_n\left(\frac{x - a}{b}\right) \\ &\rightarrow F\left(\frac{x - a}{b}\right) = \mathbb{P}\left(X \leq \frac{x - a}{b}\right) \end{aligned} \quad \square$$

**Satz 9.10**

$$X_n \xrightarrow{D} X \Leftrightarrow \mathbb{E}(g(X_n)) \rightarrow \mathbb{E}(g(X))$$

$\forall$  beschränkten und stetigen Funktionen  $g : \mathbb{R} \rightarrow \mathbb{R}$ .

*Beweis.*

ohne Beweis □

**Satz 9.11 (Slutsky's Theorem)**

$$X_n \xrightarrow{D} X, A_n \xrightarrow{\mathbb{P}} a \text{ und } B_n \xrightarrow{\mathbb{P}} b \Rightarrow A_n + B_n X_n \xrightarrow{D} a + b X$$

**Lemma 9.12**

$$X_n \xrightarrow{D} X \Leftrightarrow M_{X_n}(s) \rightarrow M_X(s) \quad s \in \mathcal{D} \quad \text{vgl Satz 5.10}$$

*Beweis.*

i.W. Konvergenz der  $\mathbb{E}$ -Werte  $\mathbb{E}(X_n^r) \rightarrow \mathbb{E}(X^r)$  □

*Bemerkung.* Die momenterzeugende Funktion ist hier eigentlich ungeeignet, weil alle Momente  $\mathbb{E}(X_n^r)$ ,  $r \geq 1$ , existieren müssen. Besser wäre die charakteristische Funktion  $\varphi_X(t) = \mathbb{E}(\exp(itX))$ . Siehe [Meintrup and Schäffler \(2005\)](#).

*Beweis.*

zu [9.11](#) (Skizze)

Sei  $Y_n \xrightarrow{D} Y$  unabhängig von  $X_n, X$ . Dann

$$M_{(X_n, Y_n)}(s) \stackrel{\text{stu}}{=} M_{X_n}(s) \cdot M_{Y_n}(s)$$

Lemma  $\xrightarrow{9.12} M_X(s) \cdot M_Y(s) = M_{(X,Y)}(s)$

Mit  $Y_n \xrightarrow{\mathbb{P}} a$  und Faltung folgt  $X_n + Y_n \rightarrow X + a$ , analog für  $Y_n \xrightarrow{\mathbb{P}} b$ .  $\square$

**Evgeny Evgenievich Slutsky (7. April 1880 bis 10. März 1948)** Ukrainischer Ökonom und Statistiker.

[http://en.wikipedia.org/wiki/Eugen\\_Slutsky](http://en.wikipedia.org/wiki/Eugen_Slutsky)

### Beispiel 9.8

$X_n \sim P(\lambda) \quad \mathbb{E}(X_n) = \lambda = \mathbb{V}(X_n)$

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{\mathbb{P}} \lambda$$

Was passiert mit  $\bar{X}_n - \lambda$  ?

$$\bar{X}_n - \lambda \xrightarrow{\mathbb{P}} 0$$

mit  $\mathbb{E}(\bar{X}_n - \lambda) = 0$  und

$$\mathbb{V}(\bar{X}_n - \lambda) = \mathbb{V}(\bar{X}_n) = \frac{1}{n^2} \mathbb{V}\left(\sum X_i\right) = \frac{1}{n^2} n \lambda = \frac{\lambda}{n} \rightarrow 0$$

Aber  $\frac{\bar{X}_n - \lambda}{\sqrt{\lambda/n}}$  hat Varianz 1.

Was ist die Verteilung dieser Größe?

### Satz 9.13 (Zentraler Grenzwertsatz)

Seien  $X_i, i = 1, \dots$  u.i.v. mit  $\mathbb{E}(X_i) = \mu$  und  $\mathbb{V}(X_i) = \sigma^2 < \infty \forall i = 1, \dots$ . Dann gilt

$$\frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \xrightarrow{D} N(0, 1)$$

bzw.

$$\sqrt{n}(\bar{X} - \mu) \xrightarrow{D} N(0, \sigma^2)$$

*Beweis.*

(Skizze) bekannt:

$$M_{\sum_{i=1}^n Y_i}(s) \stackrel{Y_i \text{ stu}}{=} \prod_{i=1}^n M_{Y_i}(s) \\ \stackrel{Y_i \text{ u.i.v.}}{=} (M_{Y_1}(s))^n$$

$$\text{Jetzt: } Y_i = \frac{X_i - \mu}{\sigma}$$

$$\mathbb{E}(Y_i) = 0, \mathbb{V}(Y_i) = 1$$

$$e^{ty} \stackrel{\text{Taylorreihe}}{=} 1 + ty + \frac{1}{2}t^2 y^2 + \text{Rest}$$

$$\begin{aligned} \Rightarrow M_{Y_1}(s) &= \mathbb{E}(e^{sY_1}) \\ &= 1 + s\mathbb{E}(Y_1) + \frac{1}{2}s^2\mathbb{E}(Y_1^2) + \mathbb{E}(\text{Rest}) \\ &= 1 + \frac{1}{2}s^2 + \mathbb{E}(\text{Rest}) \\ \Rightarrow M_{\sum Y_i}(s) &= \left[1 + \frac{1}{2}s^2 + \mathbb{E}(\text{Rest})\right]^n \\ \Rightarrow M_{\frac{1}{\sqrt{n}}\sum Y_i}(s) &= \left[1 + \frac{1}{2n}s^2 + \mathbb{E}\left(\frac{\text{Rest}}{n}\right)\right]^n \end{aligned}$$

$$\text{mit } \mathbb{E}\left(\frac{\text{Rest}}{n}\right) \rightarrow 0 \text{ (o.B.)}$$

und damit

$$M_{\frac{1}{\sqrt{n}}\sum Y_i}(s) = \left(1 + \frac{\frac{1}{2}s^2}{n}\right)^n \rightarrow \exp\left(\frac{1}{2}s^2\right) \quad \text{für } n \rightarrow \infty.$$

Die Behauptung folgt aus  $M_{N(0,1)}(s) = \exp\left(\frac{s^2}{2}\right)$ . Um den Beweis vollständig zu haben, muß man von der momenterzeugenden Funktion zur charakteristischen Funktion übergehen.  $\square$

*Bemerkung.* Der ZGWS gilt für alle  $X_i$  mit beliebiger Verteilung!

### Beispiel 9.9 (Bernoulliverteilung)

$X_i \sim B(1, p), i = 1, \dots, n$  mit  $p = 0.5$ . Die Verteilung des standardisierten Mittelwertes konvergiert nach dem Zentralen Grenzwertsatz gegen eine Normalverteilung

$$\sqrt{n} \frac{n^{-1} \sum_{i=1}^n X_i - p}{\sqrt{p(1-p)}} \xrightarrow{D} N(0, 1)$$

### Beispiel 9.10 (Poissonverteilung)

$X_i \sim P(\lambda), i = 1, \dots, n$  mit  $\lambda = 5$ . Die Verteilung des standardisierten Mittelwertes konvergiert nach dem Zentralen Grenzwertsatz gegen eine Normalverteilung

$$\sqrt{n} \frac{n^{-1} \sum_{i=1}^n X_i - \lambda}{\sqrt{\lambda}} \xrightarrow{D} N(0, 1)$$

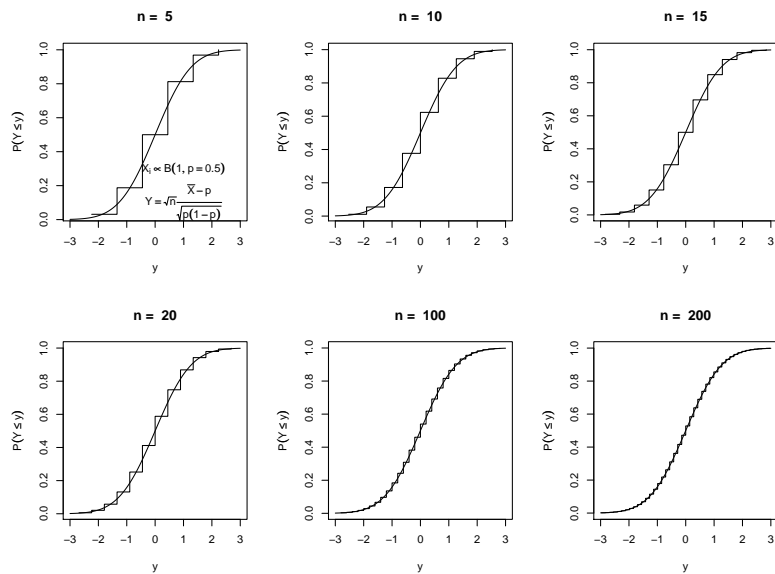


Abbildung 9.1: Approximation der Binomialverteilung durch die Normalverteilung.

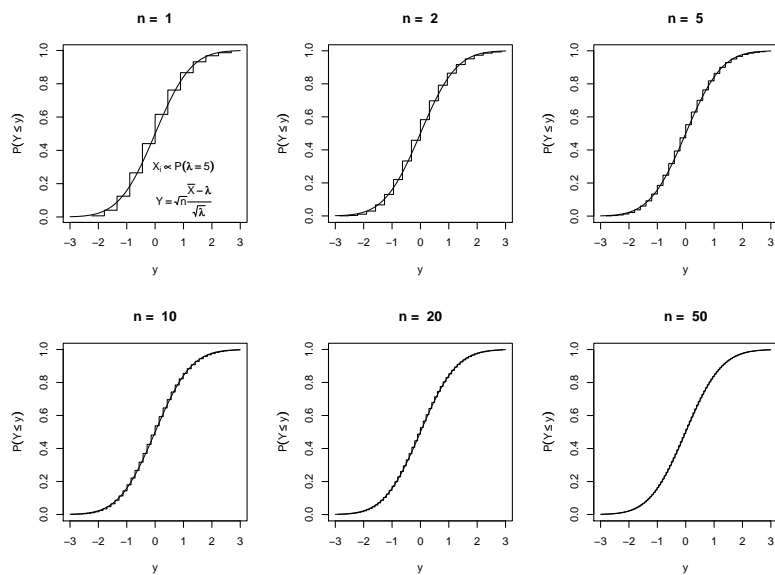


Abbildung 9.2: Approximation der Poissonverteilung durch die Normalverteilung.

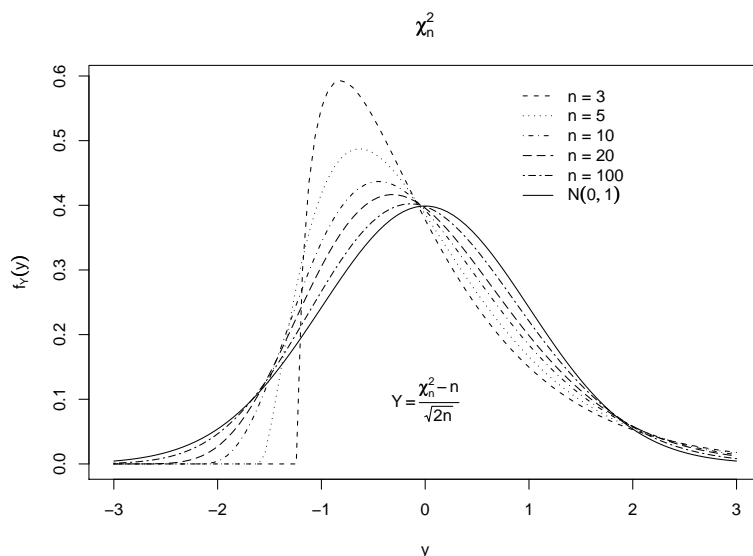


Abbildung 9.3: Approximation der  $\chi^2$ -Verteilung durch die Normalverteilung.

### Beispiel 9.11 ( $\chi^2$ -Verteilung)

$X \sim \chi_n^2$  mit  $\mathbb{E}(X) = n$  und  $\mathbb{V}(X) = 2n$ . Betrachte die Dichte der standardisierten ZV

$$Y = \frac{X - n}{\sqrt{2n}}$$

also die Transformation  $y = g(x) = (x - n)(2n)^{-1/2}$ . Mit dem Transformationssatz folgt

$$f_Y(y) = f_{\chi_n^2}(y\sqrt{2n} + n)\sqrt{2n}$$

Da  $X$  die Summe von unabhängigen standardnormalverteilten ZV ist, folgt mit dem ZGWS, daß die zugehörigen Verteilungsfunktionen konvergieren, und zwar  $F_Y(y) \rightarrow \Phi(y) \iff Y \xrightarrow{D} N(0, 1)$ .

### Beispiel 9.12

$X_1, \dots, X_n$  iid mit  $\mathbb{E}(X_i) = 0$ ,  $\mathbb{V}(X_i) = \sigma^2$  und  $\mathbb{V}(X_i^2) = \tau^2 < \infty$ .

$$\sqrt{n}(S^2 - \sigma^2) \xrightarrow{D} ?$$

$$S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \xrightarrow{\mathbb{P}} \sigma^2 \text{ (siehe HA)}$$

$S^2$  hängt nicht von  $\mu$  ab, also o.B.d.A.  $\mu = 0$

$$\text{ZGWS: } \sqrt{n} \left( \frac{1}{n} \sum_{i=1}^n X_i^2 - \sigma^2 \right) \xrightarrow{D} N(0, \tau^2)$$

Gesetz der großen Zahlen:  $\bar{X}^2 \xrightarrow{\mathbb{P}} 0$

Damit folgt:  $\sqrt{n}(S^2 - \sigma^2) = \sqrt{n} \left( \frac{1}{n} \sum_{i=1}^n X_i^2 - \underbrace{\bar{X}^2}_{\rightarrow 0} - \sigma^2 \right) \xrightarrow{D} N(0, \tau^2)$

### Satz 9.14 (Berry-Esseen)

Es seien  $X_1, \dots, X_n$  u.i.v.,  $X_i \sim F$  mit  $\mathbb{E}(X_i) = \mu$ ,  $\mathbb{V}(X_i) = \sigma^2$ ,  $\mathbb{E}(X_i^3) < \infty \Rightarrow$

$\exists c$  (unabhängig von  $F$ ) mit

$$|G_n(x) - \Phi(x)| \leq \frac{c}{\sqrt{n}} \frac{\mathbb{E}(|X_1 - \mu|^3)}{\sigma^3}$$

wobei  $G_n(x) = \mathbb{P} \left( \sqrt{n} \left( \frac{\bar{X} - \mu}{\sigma} \right) \leq x \right)$ .

*Beweis.*

geschenkt □

*Bemerkung.* Satz 9.14 gilt für alle  $n$ , nicht nur für  $n \rightarrow \infty$ !  $c$  ist unabhängig von  $F$  und es ist bekannt, daß  $c_{\min} \leq 0.7975$ .

$F$  darf ohne zusätzliche Annahmen nicht von  $n$  abhängen!

### Beispiel 9.13

$X_1, \dots, X_n, \quad X_i \sim P\left(\frac{1}{n}\right)$

$\Rightarrow \sum_{i=1}^n X_i \sim P(1)$

Aber  $\sqrt{n} \frac{(\bar{X} - \frac{1}{n})}{\sqrt{\frac{1}{n}}} = \frac{\sum X_i - n \frac{1}{n}}{\sqrt{n} \frac{1}{\sqrt{n}}} = \sum X_i - 1 \sim P(1) - 1 \neq N(0, 1) \quad \forall n$

### Satz 9.15

Es seien  $X_1, \dots, X_n$  u.i.v. mit  $X_i \sim F$ ,  $\mathbb{E}(X_i) = \mu$ ,  $\mathbb{V}(X_i) = \sigma^2$ ,  $\mathbb{E}(X_i^3) < \infty$  und  $k$ -tem zentralen Moment  $\mu_k^0 = \mathbb{E}((X_i - \mu)^k)$ . Dann gilt:

$$\begin{aligned} G_n(x) &= \mathbb{P} \left( \sqrt{n} \left( \frac{\bar{X} - \mu}{\sigma} \right) \leq x \right) \\ &= \Phi(x) + \underbrace{\frac{\mu_3^0}{6 \sigma^3 \sqrt{n}} (1 - x^2) \varphi(x)}_{\text{erste Edgeworth-Korrektur}} + o \left( \frac{1}{\sqrt{n}} \right) \end{aligned}$$

*Bemerkung.* •  $o \left( \frac{1}{\sqrt{n}} \right)$  meint eine Folge, die wie  $\frac{1}{\sqrt{n}} \rightarrow 0$  für  $n \rightarrow \infty$ , aber schneller als  $\frac{1}{\sqrt{n}}$ .

- für symmetrische Verteilungen ist  $\mu_3 = 0$  und damit ist z.B. für die  $t$ -Verteilung die Approximation durch  $N(0, 1)$  schneller als  $\frac{1}{\sqrt{n}}$ . Die erste Edgeworth-Korrektur ist also für schiefe Verteilungen, etwa  $\chi_n^2$  von Interesse.

**Satz 9.16 ( $\Delta$ -Methode)**

Falls  $\sqrt{n}(X_n - \nu) \xrightarrow{D} N(0, \tau^2)$

dann auch  $\sqrt{n}(f(X_n) - f(\nu)) \xrightarrow{D} N\left(0, \tau^2 \cdot \frac{\partial f(\nu)^2}{\partial \nu}\right)$

falls  $f: \mathbb{R} \rightarrow \mathbb{R}$  in  $\nu$  differenzierbar ist und  $\frac{\partial f(\nu)}{\partial \nu} \neq 0$ .

*Beweis.*

Entwickle  $f$  in Taylorreihe

$$f(x + \Delta) = f(x) + \Delta \left. \frac{\partial f(x)}{\partial x} \right|_{x=x} + \dots + \frac{\Delta^r}{r!} \left. \frac{\partial^r f(x)}{\partial x^r} \right|_{x=x} + \text{Rest}$$

mit  $\Delta = X_n - \nu$  und  $x = \nu$  folgt

$$f(X_n) = f(\nu) + (X_n - \nu) \frac{\partial f(\nu)}{\partial \nu} + \text{Rest}$$

$$\Rightarrow \sqrt{n}(f(X_n) - f(\nu)) = \underbrace{\sqrt{n}(X_n - \nu) \cdot \frac{\partial f(\nu)}{\partial \nu}}_{\text{linear}} + \underbrace{\text{Rest}}_{\rightarrow 0 \text{ ohne Beweis}}$$

$$\stackrel{9.9}{\Rightarrow} \sqrt{n}(f(X_n) - f(\nu)) \xrightarrow{D} N\left(0, \tau^2 \cdot \frac{\partial f(\nu)^2}{\partial \nu}\right)$$

□

**Beispiel 9.14**

$X_1, \dots, X_n$  u.i.v.  $X_i \sim P(\lambda)$

$$\stackrel{\text{ZGWS}}{\Rightarrow} \sqrt{n}(\bar{X} - \lambda) \xrightarrow{D} N(0, \lambda)$$

Problem: Varianz der Grenzverteilung hängt von unbekanntem  $\lambda$  ab.

Suche  $f$  mit

$$\sqrt{n}(f(\bar{X}) - f(\lambda)) \xrightarrow{D} N\left(0, \lambda \cdot \frac{\partial f(\lambda)^2}{\partial \lambda}\right)$$

wobei  $\lambda \cdot \frac{\partial f(\lambda)^2}{\partial \lambda} \equiv \text{konstant}$ .

zum Beispiel  $\frac{\partial f(\lambda)}{\partial \lambda} = \frac{c}{\sqrt{\lambda}}$

$$\Rightarrow f(\lambda) = 2c\sqrt{\lambda} \quad \text{denn } c \int \frac{1}{\sqrt{\lambda}} d\lambda = c \cdot 2\sqrt{\lambda}$$



und damit ( $c \equiv 1$ )

$$2\sqrt{n} \left( \sqrt{\bar{X}} - \sqrt{\lambda} \right) \xrightarrow{D} N(0, 1)$$

### Beispiel 9.15

$X_1, \dots, X_n$  u.i.v.  $X_i \sim N(0, \sigma^2)$

$$\Rightarrow \mathbb{E}(X_i^2) = \sigma^2, \quad \mathbb{V}(X_i^2) = 2\sigma^4$$

$$\stackrel{\text{ZGWS}}{\Rightarrow} \sqrt{n} \left( \frac{1}{n} \sum X_i^2 - \sigma^2 \right) \xrightarrow{D} N(0, 2(\sigma^2)^2)$$

Gesucht:  $f$  mit  $\frac{\partial f(\sigma^2)}{\partial \sigma^2} = \frac{c}{\sqrt{2}\sigma^2}$

$$f = \int \frac{\partial f(\sigma^2)}{\partial \sigma^2} d\sigma^2 = \frac{c}{\sqrt{2}} \int \frac{1}{\sigma^2} d\sigma^2 = \frac{c}{\sqrt{2}} \log(\sigma^2)$$

Setzt  $c = 1 \Rightarrow$

$$\sqrt{\frac{n}{2}} \log \left( \frac{\frac{1}{n} \sum X_i^2}{\sigma^2} \right) \xrightarrow{D} N(0, 1)$$

### Definition 9.17

Seien  $X_1, \dots, X_n$  u.i.v. mit Verteilungsfunktion  $F$ . Dann heißt

$$\widehat{F}(x) = \frac{1}{n} \sum_{i=1}^n I_{(-\infty, x]}(X_i)$$

die empirische Verteilungsfunktion von  $X_1, \dots, X_n$ .

### Satz 9.18 (Satz von Glivenko-Cantelli)

- a)  $\widehat{F}(x) \xrightarrow{\text{f.s.}} F(x) \quad \forall x \in \mathbb{R}$
- b)  $\sqrt{n}(\widehat{F}_n(x) - F(x)) \xrightarrow{D} N(0, F(x)(1 - F(x))) \quad \forall x \in \mathbb{R}$
- c)  $\sup_{x \in \mathbb{R}} |\widehat{F}_n(x) - F(x)| \xrightarrow{\text{f.s.}} 0$

*Beweis.*

$I_{X_i \leq x} \sim B(1, F(x))$  u.i.v.  $\forall i = 1, \dots, n$  und  $x \in \mathbb{R}$ .

$$\stackrel{\text{ZGWS}}{\Rightarrow} \underbrace{\sqrt{n} \left( \frac{1}{n} \sum_{i=1}^n I_{X_i \leq x} - F(x) \right)}_{= \sqrt{n}(\widehat{F}_n(x) - F(x))} \xrightarrow{d} N(0, F(x)(1 - F(x)))$$

## Beispiel 9.16 (Glivenko-Cantelli)

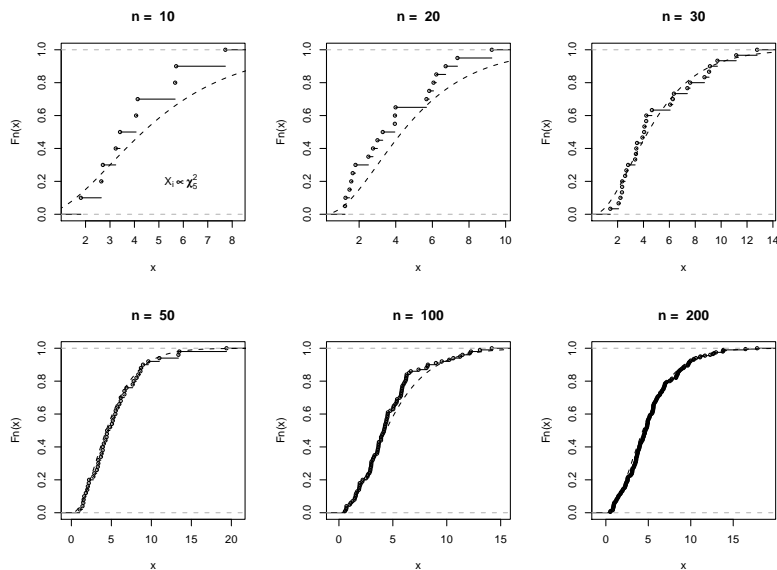


Abbildung 9.4: Approximation der Verteilungsfunktion der  $\chi_5^2$  Verteilung durch die empirische Verteilungsfunktion.

⇒ b)

$$\widehat{F}_n(x) = \frac{1}{n} \sum_{X_i \leq x} \mathbb{P} \rightarrow \mathbb{E}(I_{X_i \leq x}) = \mathbb{P}(X_i \leq x) = F(x)$$

⇒  $\widehat{F}_n(x) \xrightarrow{\mathbb{P}} F(x)$  (f.s. braucht ein starkes Gesetz der großen Zahlen mit  $\xrightarrow{\text{f.s.}}$  statt  $\xrightarrow{\mathbb{P}}$ ).

c) ohne Beweis

□

**Waleri Iwanowitsch Gliwenko (2. Januar 1897 bis 15. Februar 1940).** Russischer Mathematiker und Logiker.

[http://de.wikipedia.org/wiki/Waleri\\_Iwanowitsch\\_Gliwenko](http://de.wikipedia.org/wiki/Waleri_Iwanowitsch_Gliwenko)

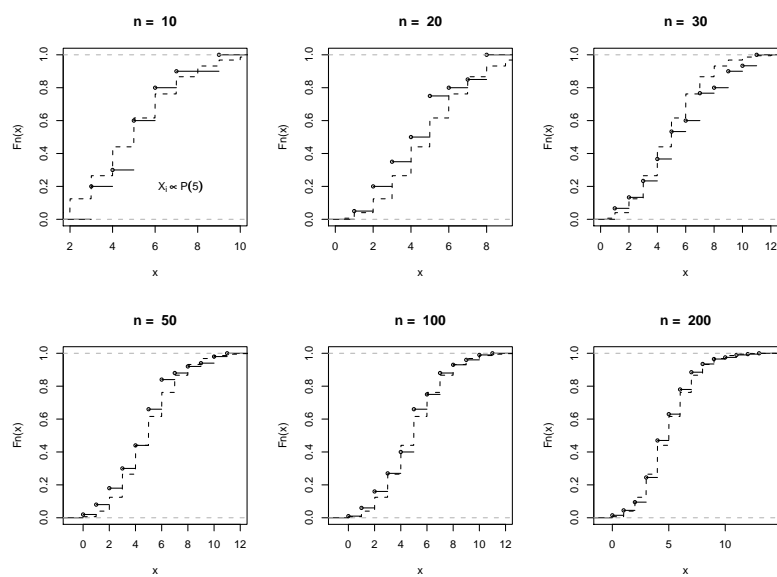


Abbildung 9.5: Approximation der Verteilungsfunktion der  $P(5)$  Verteilung durch die empirische Verteilungsfunktion.

# Lizenz

**Copyright (C) Torsten Hothorn, Institut für Statistik, LMU München, 2007, 2008, 2009, 2010, 2011**

Es ist erlaubt, dieses Dokument zu vervielfältigen, zu verbreiten und/oder zu verändern unter den Bedingungen der "GNU Free Documentation License", Version 1.2 oder jeder späteren Version, die von der Free Software Foundation veröffentlicht wird; es gibt keine unveränderlichen Abschnitte, keinen vorderen Umschlagtext und keinen hinteren Umschlagtext. Eine Kopie der Lizenz ist unter <http://www.gnu.org/copyleft/fdl.html> oder (in der deutschen Übersetzung) unter [http://www.zeno.org/Zeno/-/GFDL+\(deutsch\)](http://www.zeno.org/Zeno/-/GFDL+(deutsch)) zu erhalten.

# Literaturverzeichnis

Andrej Nikolaevic Kolmogorov. *Grundbegriffe der Wahrscheinlichkeitsrechnung*. Springer, Berlin, 1933.

Erich Lehmann. *Elements of Large-Sample Theory*. Springer, Berlin, 2001.

David Meintrup and Stefan Schäffler. *Stochastik: Theorie und Anwendungen*. Springer Verlag, Berlin, Heidelberg, 2005.

Johann Pfanzagl. *Elementare Wahrscheinlichkeitsrechnung*. de Gruyter, Berlin, 2. edition, 1991.

Klaus D. Schmidt. *Maß und Wahrscheinlichkeit*. Springer Verlag, Berlin, Heidelberg, 2009.

William F. Trench. *Introduction to Real Analysis*. William F. Trench, Free Edition 1.03 edition, 2010. ISBN 0-13-045786-8. URL <http://ramanujan.math.trinity.edu/wtrench/misc/index.shtml>.