

Supplement

RISIKOTHEORIE

Angefertigt am  
Institut für angewandte Mathematik  
in Arbeitsgruppe Stochastik  
bei Univ. Prof. Dr. Barbara Rüdiger-Mastandrea  
getippt in tex von B.Sc. Sergiy Bogdanov

Mathematisch-Naturwissenschaftliche Fakultät der  
Bergischen Universität Wuppertal

Sommersemester 2016

# Inhaltsverzeichnis

0.1	Abkürzungs- und Namensverzeichnis . . . . .	1
<b>1</b>	<b>Einführung</b>	<b>2</b>
1.1	Wert im Risiko . . . . .	2
1.2	Bedingter Erwartungswert . . . . .	4
1.3	Tail-Value at Risk und Conditional Tail-Value at Risk . . . . .	7
1.4	Risikokennzahlen und ihre Eigenschaften . . . . .	8
1.5	Übung . . . . .	11
<b>2</b>	<b>Wahrscheinlichkeitsräume</b>	<b>13</b>
2.1	Wahrscheinlichkeit auf Produkträume . . . . .	13
2.2	Produkt-Wahrscheinlichkeitsmaß auf Produkträume . . . . .	14
<b>3</b>	<b>Copulae</b>	<b>17</b>
3.1	Übung . . . . .	23
3.2	Graph einer 2-dim. Copula . . . . .	23
3.3	Systematisches Risiko . . . . .	23
<b>4</b>	<b>Ruintheorie</b>	<b>37</b>
4.1	Zahlprozesse und Poisson-Prozesse . . . . .	37
4.2	Risikoprozess . . . . .	40
4.2.1	Komponenten des Risikoprozesses . . . . .	40
4.2.2	Ruinwahrscheinlichkeit . . . . .	40
4.2.3	Berechnung der Ruinwahrscheinlichkeit mit Hilfe der Integro- Differentialgleichung . . . . .	44
	Literatur . . . . .	47

## 0.1 Abkürzungs- und Namensverzeichnis

ZV	Zufallsvariable, Zufallsvariablen
$(\Omega, \mathcal{F}, \mathbb{P})$	Wahrscheinlichkeitsraum, W-Raum

# 1 Einführung

## 1.1 Wert im Risiko

Wir notieren wie üblich  $\mu((-\infty, x]) = F_L(x) = \mathbb{P}(L \leq x) = \int_{-\infty}^x f(y)dy$ .

**Definition 1.1.1.** Sei  $L$  ZV auf  $(\Omega, \mathcal{F}, \mathbb{P})$ . Sei  $\alpha \in (0, 1)$  fixiert. Der **Wert im Risiko (Value at Risk)** der ZV  $L$  mit **Konfidenzniveau**  $\alpha$  ist

$$\text{VaR}_\alpha(L) := \inf\{l \in \mathbb{R} \mid \mathbb{P}(L > l) \leq 1 - \alpha\}.$$

**Bemerkung 1.1.2.**  $\alpha$  wird meistens zu 0.95, 0.9, 0.99 gesetzt.

**Interpretation:**  $L$  beschreibt ein Risiko oder Verlust ( $L$  loss). Wir suchen den kleinsten Wert im Risiko  $l$ , s.d. die W-keit, dass der Verlust größer als  $l$  höchstens  $1 - \alpha$  ist.

**Bemerkung 1.1.3.** Sei  $F_L$  die Verteilungsfunktion der ZV  $L$ , dann

$$\text{VaR}_\alpha(L) = \inf\{l \in \mathbb{R} \mid 1 - F_L(l) \leq 1 - \alpha\} = \inf\{l \in \mathbb{R} \mid F_L(l) \geq \alpha\} \equiv q_L(\alpha),$$

ist auch der **Quantil** der ZV  $L$  in  $\alpha$ .

**Bemerkung 1.1.4.** In der Statistik interessiert man wie sich das Quantil  $q_L(\alpha)$  für eine gegebene ZV  $L$  in Abhängigkeit von  $\alpha$  ändert. In der Risikotheorie fixiert man  $\alpha$  und untersucht wie sich  $\text{VaR}_\alpha(L)$  in Abhängigkeit von  $L$  ändert.

**Bemerkung 1.1.5.**

(a) Falls  $F_L$  stetig ist, so gilt

$$\sup\{l \in \mathbb{R} \mid F_L(l) < \alpha\} = \inf\{l \in \mathbb{R} \mid F_L(l) \geq \alpha\} = q_L(\alpha) = \text{VaR}_\alpha(L);$$

(b) Falls  $F_L$  stetig und streng monoton steigend ist, so ist  $F_L$  invertierbar, d.h.

$$\exists F^{-1} : (0, 1) \longrightarrow \mathbb{R} \text{ s.d. } \forall x \in \mathbb{R} F^{-1}(F(x)) = x \wedge \forall y \in (0, 1) F(F^{-1}(y)) = y;$$

(c) Falls  $F_L$  eine Dichte hat,  $\forall x \in \mathbb{R} f(x) > 0$ , so ist  $F_L(x) = \int_{-\infty}^x f(y)dy$  eindeutige streng monotone Verteilungsfunktion, und folglich existiert wieder die  $F^{-1}$  als Funktion;

(d) Sei  $L$  eine ZV dessen Verteilungsfunktion streng monoton und stetig ist, so ist  $VaR_\alpha(L) = q_L(\alpha) = F_L^{-1}(\alpha)$ .

Generell können wir festhalten, dass eine ZV  $L$  hat ein *großes Restrisiko* falls  $\mathbb{P}(L > l) = 1 - F_L(l)$  auch für große Werte von  $l$  groß ist. Z. B. falls ZV  $L$  eine Dichte hat  $f(x) > 0$ , die langsam nach Null geht für  $|x| \rightarrow \infty$ , so hat sie ein großes Restrisiko.

**Definition 1.1.6.** Verteilungen mit großer Restrisiko nennt man Verteilungen mit *fat tails*.

Damit  $F_L$  ein *fat tail* hat, muß der Abstand von Verteilungsfunktion zu Gerade = 1 "immer sehr groß" bleiben. Das ist z.B. nicht der Fall, falls  $F_L$  eine Dichte hat, die exponential nach Null geht oder allg. falls  $1 - F_L(x) \sim \exp(-x)$  für große Werte von  $x$  oder wenn sogar  $\forall x \geq x_0 F_L(x) = 1$ .

**Beispiel 1.1.7.** Verteilungen die keine fat tails haben:

(a)  $L \sim U_{[a,b]}$  uniforme Verteilung;

(b)  $L \sim \mathcal{N}(\mu, \sigma)$  Normalverteilung;

(c)  $L \sim \mathcal{X}^2$ , wobei  $\mathcal{X}^2 \sim (\mathcal{N}(0, 1))^2$  Chi-Quadrat-Verteilung;

(d)  $L \sim \mathcal{LN}(\mu, \sigma^2)$  Logarithmische Normalverteilung;

(e)  $L \sim \exp(\lambda)$ ,  $\lambda > 0$  Exponentialverteilung;

(f)  $L \sim WB(b, T)$ ,  $b \geq 0$ ,  $T > 0$  Weibull-Verteilung;

(g)  $L \sim \text{Gamma}(\kappa, \beta)$  Gammaverteilung.

**Beispiel 1.1.8.** Verteilung, die fat tail hat ist die Pareto-Verteilung. Eine Pareto-verteilte ZV  $L \sim \text{Par}(x_0, a)$ ,  $x_0 > 0$ ,  $a > 0$  hat folgende Dichte bzw. Verteilungsfunktion

$$f(x) = \begin{cases} ax_0^a x^{-a-1} & \text{falls } x \geq x_0 \\ 0 & \text{sonst} \end{cases} \quad \text{bzw.} \quad F(x) = \begin{cases} 1 - \left(\frac{x}{x_0}\right)^{-a} & \text{falls } x \geq x_0 \\ 0 & \text{sonst.} \end{cases}$$

## 1.2 Bedingter Erwartungswert

**Satz 1.2.1.** Sei  $\mathbb{P}$  ein  $W$ -Maß auf einem messbaren Raum  $(\Omega, \mathcal{F})$  und  $A \in \mathcal{F}$  mit  $\mathbb{P}(A) > 0$ . Dann wird durch  $\mathbb{P}(\cdot | A) : \mathcal{F} \rightarrow [0, 1]$ ,  $B \mapsto P(B|A) := \frac{\mathbb{P}(B \cap A)}{\mathbb{P}(A)}$  einen neuen  $W$ -Maß auf  $(\Omega, \mathcal{F})$  definiert.

**Beweis.** Es ist  $P(\emptyset|A) = \frac{\mathbb{P}(\emptyset \cap A)}{\mathbb{P}(A)} = \frac{\mathbb{P}(\emptyset)}{\mathbb{P}(A)} = 0$  und  $P(\Omega|A) = \frac{\mathbb{P}(\Omega \cap A)}{\mathbb{P}(A)} = \frac{\mathbb{P}(A)}{\mathbb{P}(A)} = 1$ . Dazu ist  $\mathbb{P}(\cdot | A)$  additiv und  $\sigma$ -additiv, da für  $(B_n)_{n \in \mathbb{N}}$  paarweise disjunkt, ist auch  $(B_n \cap A)_{n \in \mathbb{N}}$  paarweise disjunkt.  $\square$

**Definition 1.2.2.**  $\mathbb{P}(\cdot | A)$  ist die **Wahrscheinlichkeit bedingt des Ereignis**  $A$ .

**Bemerkung 1.2.3.**  $\mathbb{P}(\cdot | A)$  hat folgende Eigenschaften:

(a)  $\mathbb{P}(B|A) = 0$  falls  $B \subseteq A^c$ ;

(b)  $\mathbb{P}(A|A) = 1$ ;

(c)  $\mathbb{P}(C|A) = \frac{\mathbb{P}(C)}{\mathbb{P}(A)}$  falls  $C \subseteq A$ .

**Definition 1.2.4.** Sei  $(\Omega, \mathcal{F}, \mathbb{P})$  ein  $W$ -Raum.  $A, B \in \mathcal{F}$  heißen **stochastisch unabhängig**,  $A \perp B$ , falls  $\mathbb{P}(A \cap B) = \mathbb{P}(A)\mathbb{P}(B)$ .

**Bemerkung 1.2.5.** Es gilt  $A \perp B \Leftrightarrow \mathbb{P}(A|B) = \mathbb{P}(A) \wedge \mathbb{P}(B|A) = \mathbb{P}(B)$ , falls  $\mathbb{P}(A) > 0$  und  $\mathbb{P}(B) > 0$  gilt.

**Bemerkung 1.2.6.** Aus  $A \cap B \subseteq A$  und  $A \cap B \subseteq B$  folgt  $\mathbb{P}(A \cap B) \leq \mathbb{P}(A)$  und  $\mathbb{P}(A \cap B) \leq \mathbb{P}(B)$ , ist also  $\mathbb{P}(A) = 0$  oder  $\mathbb{P}(B) = 0$ , so folgt  $\mathbb{P}(A \cap B) = 0$  und demnach  $A \perp B$ .

**Notation:** Sei  $X : \Omega \rightarrow \mathbb{R}$  eine ZV auf  $(\Omega, \mathcal{F}, \mathbb{P})$  und  $B \in \mathcal{B}(\mathbb{R})$ , dann schreiben wir  $X^{-1}(B) = \{\omega \in \Omega | X(\omega) \in B\}$ .

**Erinnerung:** Eine Funktion  $X : \Omega \rightarrow \mathbb{R}^d$  ist eine ZV auf  $(\Omega, \mathcal{F}, \mathbb{P})$  falls  $X^{-1}(B) \in \mathcal{F}$  für alle  $B \in \mathcal{B}(\mathbb{R}^d)$ , d.h. falls  $X$   $\mathcal{F}$ - $\mathcal{B}(\mathbb{R}^d)$ -messbar.

**Definition 1.2.7.** Seien  $X, Y$  reellwertige ZV auf  $(\Omega, \mathcal{F}, \mathbb{P})$ . Dann heißen  $X, Y$  **stochastisch unabhängig**,  $X \perp\!\!\!\perp Y$ , falls  $\forall A, B \in \mathcal{B}(\mathbb{R})$   $X^{-1}(A) \perp Y^{-1}(B)$ , d.h.  $\mathbb{P}(X^{-1}(A) \cap Y^{-1}(B)) = \mathbb{P}(X^{-1}(A))\mathbb{P}(Y^{-1}(B)) = \mu_X(A)\mu_Y(B)$ .

**Definition 1.2.8.** Sei  $(A_n)_{n \in \mathbb{N}}$  eine Folge von Ereignissen auf  $(\Omega, \mathcal{F}, \mathbb{P})$ .

(a)  $(A_n)_{n \in \mathbb{N}}$  heißt **stochastisch unabhängig**, falls für alle  $n_1, \dots, n_l, l \in \mathbb{N}$  gilt  $\mathbb{P}(A_{n_1} \cap \dots \cap A_{n_l}) = \mathbb{P}(A_{n_1}) \dots \mathbb{P}(A_{n_l})$ ;

(b)  $(A_n)_{n \in \mathbb{N}}$  heißt **paarweise stochastisch unabhängig**, falls für alle  $i, j \in \mathbb{N}$ ,  $i \neq j$  gilt  $A_i \perp A_j$ .

**Bemerkung 1.2.9.** Die stochastische Unabhängigkeit impliziert paarweise stochastische Unabhängigkeit, die Rückrichtung ist aber im Allgemeinen falsch.

**Definition 1.2.10.** Sei  $(X_n)_{n \in \mathbb{N}}$  eine Folge von reellwertigen ZV auf  $(\Omega, \mathcal{F}, \mathbb{P})$ .

(a)  $(X_n)_{n \in \mathbb{N}}$  heißt **stochastisch unabhängig**, falls für alle  $n_1, \dots, n_l \in \mathbb{N}$  und für alle  $A_{n_1}, \dots, A_{n_l} \in \mathcal{B}(\mathbb{R})$ ,  $l \in \mathbb{N}$  gilt

$$\mathbb{P}(X_{n_1}^{-1}(A_{n_1}) \cap \dots \cap X_{n_l}^{-1}(A_{n_l})) = \mathbb{P}(X_{n_1}^{-1}(A_{n_1})) \dots \mathbb{P}(X_{n_l}^{-1}(A_{n_l}));$$

(b)  $(X_n)_{n \in \mathbb{N}}$  heißt **paarweise stochastisch unabhängig**, falls für alle  $i, j \in \mathbb{N}$ ,  $i \neq j$  und für alle  $A, B \in \mathcal{B}(\mathbb{R})$  gilt

$$\mathbb{P}(X_i^{-1}(A) \cap X_j^{-1}(B)) = \mathbb{P}(X_i^{-1}(A))\mathbb{P}(X_j^{-1}(B)).$$

**Definition 1.2.11.** Zwei ZV  $X, Y$  heißen **unkorreliert**, falls  $\mathbb{E}[X, Y] = \mathbb{E}[X] \mathbb{E}[Y]$ .

**Bemerkung 1.2.12.**  $X \perp\!\!\!\perp Y$  impliziert Unkorreliertheit, die Rückrichtung ist aber im Allgemeinen falsch.

**Bemerkung 1.2.13.** Sei  $(X_n)_{n \in \mathbb{N}}$  eine Folge von ZV auf  $(\Omega, \mathcal{F}, \mathbb{P})$ , die paarweise unkorreliert ist und sei  $X_n \in \mathcal{L}^2(\Omega, \mathcal{F}, \mathbb{P})$  für alle  $n \in \mathbb{N}$ . Dann gilt

$$\text{Var}\left(\sum X_n\right) = \sum \text{Var}(X_n).$$

**Definition 1.2.14.** Sei  $(\Omega, \mathcal{F}, \mathbb{P})$  ein W-Raum,  $A \in \mathcal{F}$ ,  $\mathbb{P}(A) > 0$ . Sei  $X$  eine ZV auf  $(\Omega, \mathcal{F}, \mathbb{P})$  dann ist  $\mathbb{E}[X|A]$  der **Erwartungswert von  $X$  bzgl.  $\mathbb{P}$  bedingt  $A$**  oder **Erwartungswert bedingt der W-keit  $\mathbb{P}$ , dass Ereignis  $A$  statt findet**,  $\mathbb{E}[X|A] := \int X d\mathbb{P}(\cdot | A)$ .

**Bemerkung 1.2.15.** Es gilt

(a)  $\mathbb{E}[X] = \int X d\mathbb{P} = \int x d\mu;$

(b)  $\mathbb{E}[X|A] = \int X d\mathbb{P}(\cdot | A) = \int x d\mu_X^A$ , wobei  $\mu_X^A$  ist die durch  $\mathbb{P}(\cdot | A)$  induzierte Verteilung von  $X$ .

**Bemerkung 1.2.16.**  $X \perp\!\!\!\perp \mathbb{1}_A \iff \forall B \in \mathcal{B}(\mathbb{R}) X^{-1}(B) \perp A$ .

**Bemerkung 1.2.17.** Ist  $X \perp\!\!\!\perp \mathbb{1}_A$ , so wegen  $\mathbb{P}(X^{-1}(B) \cap A) = \mathbb{P}(X^{-1}(B))\mathbb{P}(A)$  gilt  $\mathbb{P}(X^{-1}(B)|A) = \mathbb{P}(X^{-1}(B))$  und somit  $\mathbb{E}[X|A] = \mathbb{E}[X]$ .



### 1.3 Tail-Value at Risk und Conditional Tail-Value at Risk

**Definition 1.3.1.** Sei  $L$  eine ZV. Der **Tail Value at Risk** von  $L$  definiert durch  $TVaR_\alpha(L) := \frac{1}{1-\alpha} \int_\alpha^1 VaR_s(L) ds$ .

**Lemma 1.3.2.** Sei  $F_L$  streng monoton und stetig, so gilt

$$TVaR_\alpha(L) = \frac{1}{\mathbb{P}(L > VaR_\alpha(L))} \int_\alpha^1 VaR_s(L) ds.$$

*Beweis.* Es ist  $VaR_\alpha(L) = F_L^{-1}(\alpha)$ , folglich

$$\mathbb{P}(L > VaR_\alpha(L)) = 1 - F_L(VaR_\alpha(L)) = 1 - F_L(F_L^{-1}(\alpha)) = 1 - \alpha.$$

□

**Definition 1.3.3.** Sei  $L$  ZV auf  $(\Omega, \mathcal{F}, \mathbb{P})$ .  $CTVaR_\alpha(L) := \mathbb{E}[L | L > VaR_\alpha(L)]$  wird **Conditional Tail-Value at Risk**  $\alpha$  genannt.

**Lemma 1.3.4.** Sei  $L$  ZV,  $L \in \mathcal{L}^1(\Omega, \mathcal{F}, \mathbb{P})$ . Dann gilt  $\mathbb{E}[L] = \int_{-\infty}^{\infty} \mathbb{P}(L > s) ds$ .

*Beweis.* Wir beweisen den Fall, wo  $L$  eine Dichte  $f(x)$  hat. Der Satz gilt allerdings allgemein.  $\int_{-\infty}^{\infty} \mathbb{P}(L > s) ds = \int_{\mathbb{R}} 1 - F_L(s) ds = \int_{\mathbb{R}} \int_s^{\infty} f(x) dx ds = \int_{\mathbb{R}} f(s) \int_0^s dx ds = \int_{\mathbb{R}} s f(s) ds = \mathbb{E}[L]$ . □

**Satz 1.3.5.** Sei  $F_L$  streng monoton und stetig, dann gilt

$$TVaR_\alpha(L) = CTVaR_\alpha(L).$$

*Beweis.*

$$\begin{aligned}
TVaR_\alpha(L) &= \frac{1}{1-\alpha} \int_\alpha^1 VaR_\alpha(L) ds = \frac{1}{\mathbb{P}(L > VaR_\alpha(L))} \int_\alpha^1 VaR_s(L) ds \\
&= \frac{1}{\mathbb{P}(L > VaR_\alpha(L))} \int_\alpha^1 q_L(s) ds = \frac{1}{\mathbb{P}(L > VaR_\alpha(L))} \int_\alpha^1 F_L^{-1}(s) ds \\
&= \frac{1}{\mathbb{P}(L > VaR_\alpha(L))} \int_{VaR_\alpha(L)}^\infty 1 - F_L(s) ds \\
&= \frac{1}{\mathbb{P}(L > VaR_\alpha(L))} \int_{VaR_\alpha(L)}^\infty \mathbb{P}(L > s) ds \\
&= \frac{1}{\mathbb{P}(L > VaR_\alpha(L))} \int_{-\infty}^\infty \mathbb{P}(L > s \wedge L > VaR_\alpha(L)) ds \\
&= \int_{-\infty}^\infty \mathbb{P}(L > s | L > VaR_\alpha(L)) ds \\
&= \mathbb{E} [L > s | L > VaR_\alpha(L)] ds.
\end{aligned}$$

□

## 1.4 Risikokennzahlen und ihre Eigenschaften

**Notation:** Sei  $ZV(\Omega, \mathcal{F}, \mathbb{P})$  die Menge aller reellwertigen ZV auf  $(\Omega, \mathcal{F}, \mathbb{P})$ .

**Definition 1.4.1.** Eine **Risikokennzahl** auf einem  $W$ -Raum  $(\Omega, \mathcal{F}, \mathbb{P})$  ist eine Funktion  $\varphi : ZV(\Omega, \mathcal{F}, \mathbb{P}) \rightarrow \mathbb{R}$ ,  $L \mapsto \varphi(L)$ .

**Definition 1.4.2.** Seien  $L, L_1, L_2 \in ZV(\Omega, \mathcal{F}, \mathbb{P})$ . Eine Risikokennzahl  $\varphi$  auf  $(\Omega, \mathcal{F}, \mathbb{P})$  heißt **kohärent**, falls sie folgende Eigenschaften hat:

- (1)  $\varphi$  ist **monoton**,  $[L_1 \leq L_2 \text{ f.s.} \implies \varphi(L_1) \leq \varphi(L_2)]$ , d.h. ist der Verlust  $L_1$  mit Sicherheit kleiner-gleich als der Verlust  $L_2$ , so soll dies für entsprechende Risiken gelten;
- (2)  $\varphi$  ist **homogen**,  $[\forall \lambda > 0 \varphi(\lambda L) = \lambda \varphi(L)]$ , d.h. das Risiko des  $\lambda$ -fachen Verlustes  $L$  soll auch  $\lambda$ -fach mal größer sein;

(3)  $\varphi$  ist **translationsinvariant**,  $[\forall c \in \mathbb{R} \varphi(L + c) = \varphi(L) + c]$ , d.h. falls der Verlust sich um eine Konstante  $c \in \mathbb{R}$  erhöht, so steigt auch das Risiko um  $c$  an;

(4)  $\varphi$  ist **subadditiv**,  $[\varphi(L_1 + L_2) \leq \varphi(L_1) + \varphi(L_2)]$ , d.h. das Risiko additiver Verluste ist kleiner-gleich als die Summe von einzelnen Risiken.

**Bemerkung 1.4.3.** Die Eigenschaft (4), die Subadditivität, wird in einer Portfoliostrategie für Diversifikation genutzt.

**Beispiel 1.4.4.**

- $\varphi(L) := \mathbb{E}(L)$  ist eine Kohärente Risikokennzahl;
- $\varphi(L) := \text{CTVaR}_\alpha(L)$  ist eine Kohärente Risikokennzahl.

**Behauptung 1.4.5.**  $\text{VaR}_\alpha$  ist keine kohärente Risikokennzahl.

**Beweis.**

- $\text{VaR}_\alpha(L) = \inf\{l \mid \mathbb{P}(L > l) \leq \alpha\}$  ist monoton, denn falls  $L_1 \leq L_2$  f.s., so gilt auch für alle  $l \in \mathbb{R}$ , dass  $\mathbb{P}(L_1 > l) \leq \mathbb{P}(L_2 > l)$  f.s., also auch  $\text{VaR}_\alpha(L_1) \leq \text{VaR}_\alpha(L_2)$ .
- $\text{VaR}_\alpha(L)$  ist homogen: falls  $F_L$  streng monoton und stetig,  $\text{VaR}_\alpha(\lambda L) = \lambda \text{VaR}_\alpha(L) \Leftrightarrow F_{\lambda L}^{-1}(\alpha) = \lambda F_L^{-1}(\alpha)$ . Also  $F_{\lambda L}(\alpha) = \mathbb{P}(\lambda L \leq x) = \mathbb{P}(L \leq \frac{x}{\lambda}) = F_L(\frac{x}{\lambda})$  impliziert  $F_{\lambda L}(F_L^{-1}(\alpha)) = \alpha$  und folglich  $F_{\lambda L}^{-1}(\alpha) = \lambda F_L^{-1}(\alpha)$ .
- $\text{VaR}_\alpha(L)$  ist translationsinvariant in der Menge der ZV  $L$ , dessen Verteilungsfunktion  $F_L$  streng monoton und stetig sind. Weil  $F_{L+c}(x) = \mathbb{P}(L + c \leq x) = \mathbb{P}(L \leq x - c) = F_L(x - c)$  und  $F_{L+c}^{-1}(x) = F_L^{-1}(x) + c$  für  $c \in \mathbb{R}$  ist, gilt  $\text{VaR}_\alpha(L + c) = \text{VaR}_\alpha(L) + c$ .
- $\text{VaR}_\alpha(L)$  ist aber NICHT subadditiv! D.h.,  $\text{VaR}_\alpha(L_1 + L_2) \leq \text{VaR}_\alpha(L_1) + \text{VaR}_\alpha(L_2)$  gilt i.A. nicht. Auch wenn wir uns nur auf stetige und streng monotone Verteilungsfunktionen einschränken.

**Gegenbeispiel:** Sei  $X \sim \mathcal{N}(0, D_1)$  und  $Y \sim \mathcal{N}(0, D_2)$ , mit  $X \perp\!\!\!\perp Y$ . Dann ist  $X + Y \sim \mathcal{N}(0, D_1 + D_2)$ . Sei  $F_X$  bzw.  $F_Y$  die Verteilungsfunktion von  $X$  bzw.  $Y$ . Wähle dann  $D_1, D_2 > 0$  s.d.

$$\alpha > \int_{-\infty}^{F_X^{-1}(\alpha) + F_Y^{-1}(\alpha)} \frac{\exp\left(\frac{-x^2}{2(D_1 + D_2)}\right)}{\sqrt{2\pi}\sqrt{D_1 + D_2}} dx = F_{X+Y}(F_X^{-1}(\alpha) + F_Y^{-1}(\alpha)).$$

Es existieren solche  $D_1$  und  $D_2$ , s.d. die Ungleichung gilt, weil je kleiner  $D_1$  bzw.  $D_2$  desto kleiner  $F_X^{-1}(\alpha)$  bzw.  $F_Y^{-1}(\alpha)$  ist, und um so kleiner ist die  $F_{X+Y}(x)$ . Folglich  $F_{X+Y}^{-1}(\alpha) > F_X^{-1}(\alpha) + F_Y^{-1}(\alpha)$  und entsprechend auch  $VaR_\alpha(X + Y) > VaR_\alpha(X) + VaR_\alpha(Y)$   $\square$

**Definition 1.4.6.** Zwei Verluste  $L_1, L_2$  auf  $(\Omega, \mathcal{F}, \mathbb{P})$  heißen **komoton**, falls es zwei Funktionen  $f_1, f_2$  existieren, und eine ZV  $Z$  auf  $(\Omega, \mathcal{F}, \mathbb{P})$ , s.d.  $L_1 = f_1(Z)$  und  $L_2 = f_2(Z)$ .

**Lemma 1.4.7.**  $VaR_\alpha(\mathcal{N}(m, D)) = m + \sqrt{D}VaR_\alpha(\mathcal{N}(0, 1))$ .

*Beweis.* Folgt wegen Translationsinvarianz und Homogonität von  $VaR_\alpha$ .  $\square$

**Lemma 1.4.8.** Sei eine  $L$  eine ZV mit einer Verteilungsfunktion  $F_L$ , die invertierbar ist. Sei  $g$  eine invertierbare Funktion von  $\mathbb{R}$  nach  $\mathbb{R}$ . Dann gilt:

1.  $VaR_\alpha(g(L)) = g(VaR_\alpha(L))$ ;
2.  $TVaR_\alpha(g(L)) = \frac{1}{1-\alpha} \int_\alpha^1 g(VaR_s(L)) ds$ .

*Beweis.*

1. Sei  $F_{g(L)}$  die Verteilung von  $g(L)$ .  $F_{g(L)}(x) = \mathbb{P}(g(L) \leq x) = \mathbb{P}(L \leq g^{-1}(x)) = F_L(g^{-1}(x))$ , da  $g$  invertierbar. Demnach auch  $g^{-1}$  invertierbar und  $F_{g(L)}^{-1} = g(F_L^{-1})$ . Folglich  $VaR_\alpha(g(L)) = F_{g(L)}^{-1}(\alpha) = g(F_L^{-1}(\alpha)) = g(VaR_\alpha(L))$ .
2. Folgt direkt mit 1. und bisherigen Ergebnissen.  $\square$

**Beispiel 1.4.9.**  $X \sim \mathcal{N}(0, 1)$ ,  $L_1 \sim \mathcal{X}^2 = X^2$ ,  $L_2 = e^{X+a}$  (etwa mit  $Z \sim \mathcal{N}(0, D)$ ,  $D = \sigma^2 t$ ,  $a = \alpha t$ ,  $t \in \mathbb{R}^{++}$  beschreibt  $e^{Z+a}$  eine Wertpapieränderung in Abhängigkeit von der Zeit).

**Behauptung 1.4.10.**  $VaR(L_1) = (VaR_{\frac{1}{2}(\alpha+1)}(X))^2$ .

*Beweis.*  $F_{L_1}$  ist invertierbar. Sei  $y \geq 0$ .  $F_{L_1}(y) = \mathbb{P}(L_1 \leq y) = 2\mathbb{P}(0 \leq X \leq \sqrt{y}) = 2(F_X(\sqrt{y}) - F_X(0)) = 2F_X(\sqrt{y}) - 1$ . Folglich gilt die Identität  $F_{L_1}^{-1}(\alpha) = (F_X^{-1}(\frac{1}{2}(\alpha + 1)))^2$ , weil  $F_{L_1}(y) := h(g(l(y)))$  mit  $l(y) = \sqrt{y}$ ,  $g(y) = F_X(y)$ ,  $h(y) = 2y - 1$ , also  $F_{L_1}^{-1}(z) = l^{-1}(g^{-1}(h^{-1}(z)))$ , also  $l^{-1}(z) = z^2$ ,  $g^{-1}(z) = F_X^{-1}(z)$ ,  $h^{-1}(z) = \frac{1}{2}z + \frac{1}{2}$ . Folglich  $VaR_\alpha(L_1) = F_{L_1}^{-1}(\alpha) = (F_X^{-1}(\frac{1}{2}\alpha + \frac{1}{2}))^2 = (VaR_{\frac{1}{2}\alpha + \frac{1}{2}}(X))^2$   $\square$

**Korollar 1.4.11.**  $TVaR_\alpha(L_1) = \frac{1}{1-\alpha} \int_\alpha^1 (VaR_{\frac{1}{2}(s+1)}(X))^2 ds$ .

**Behauptung 1.4.12.**  $VaR_\alpha(L_2) = \exp(a) \exp(VaR_\alpha(X))$ .

*Beweis.*  $F_{L_2}(x) = \mathbb{P}(L_2 \leq x) = \mathbb{P}(\exp(X + a) \leq x) = \mathbb{P}(X + a \leq \ln(x)) = \mathbb{P}(X \leq x - a) = F_X(\ln x - a)$ . Und folglich  $F_{L_2}^{-1}(\alpha) = \exp(F_X^{-1}(\alpha) + a) = \exp(a) \exp(VaR_\alpha(X))$ . Oder alternativ können wir die Homogenität verwenden:  $VaR_\alpha(\exp(X + a)) = \exp(a) VaR_\alpha(\exp(X)) = \exp(a) \exp(VaR_\alpha(X)) = \exp(a) F_{L_2}^{-1}(\alpha)$ .  $\square$

**Korollar 1.4.13.**  $TVaR_\alpha(L_2) = TVaR_\alpha(\exp(X+a)) = \exp(a) TVaR_\alpha(\exp(X)) = \frac{\exp(a)}{1-\alpha} \int_\alpha^1 VaR_s(\exp(X)) ds = \frac{\exp(a)}{1-\alpha} \int_\alpha^1 \exp(VaR_s(X)) ds$

## 1.5 Übung

Sei  $X \sim \mathcal{N}(\mu, \sigma^2)$  und sei  $Z \sim \mathcal{N}(0, 1)$  mit zugehöriger Dichte  $\phi$  und Verteilungsfunktion  $\Phi$ .

Wir wollen beweisen

$$TVaR_\alpha(X) = \mu + \sigma \frac{\phi(\Phi^{-1}(\alpha))}{(1-\alpha)}.$$

*Beweis.*

**Bemerkung 1.5.1.** Es gilt  $\mu + \sigma Z \sim X$ .

**Bemerkung 1.5.2.** Da  $TVaR_\alpha(X)$  eine koherente Risikokennzahl, also translationinvariant und homogen, gilt

$$TVaR_\alpha(X) = \mu + \sigma TVaR_\alpha(Z).$$

Folglich, es genügt zu zeigen

$$(1 - \alpha)TVaR_\alpha(Z) = \phi(\Phi^{-1}(\alpha)).$$

**Bemerkung 1.5.3.** Es gilt

$$\begin{aligned} -\phi'(t) &= -\left(\frac{1}{\sqrt{2\pi}}\exp\left(-\frac{t^2}{2}\right)\right)' = -\left(-\frac{2t}{2}\right)\frac{1}{\sqrt{2\pi}}\exp\left(-\frac{t^2}{2}\right) \\ &= \frac{t}{\sqrt{2\pi}}\exp\left(-\frac{t^2}{2}\right) \\ &= t\phi(t). \end{aligned}$$

Wir verwenden noch, dass für eine ZV  $L$ , welche streng monoton wachsende und stetige Verteilung hat,  $CTVaR_\alpha(L) = TVaR_\alpha(L)$  ist und berechnen

$$\begin{aligned} (1 - \alpha)TVaR_\alpha(Z) &= \int_\alpha^1 VaR_\alpha(Z) ds = (1 - \alpha) \mathbb{E}[Z > s \mid Z > VaR_\alpha(Z)] \\ &= \int_{q_\alpha(Z)}^\infty \mathbb{P}(Z > t) dt \\ &= \int_{q_\alpha(Z)}^\infty t\phi(t) dt \\ &= \int_{\Phi^{-1}(\alpha)}^\infty -\phi'(t) dt \\ &= \phi(\Phi^{-1}(\alpha)). \end{aligned}$$

□

## 2 Wahrscheinlichkeitsräume

### 2.1 Wahrscheinlichkeit auf Produkträume

Seien  $\Omega_1, \dots, \Omega_N$ . Die Menge  $\times_{n=1}^N \Omega_n = \{(\omega_1, \dots, \omega_N) \mid \omega_i \in \Omega_N\}$  ist dann **Produkttraum**. Seien  $(\Omega_1, \mathcal{F}_1), \dots, (\Omega_N, \mathcal{F}_N)$  Messräume. Sei  $C_N = \mathcal{F}_1 \times \dots \times \mathcal{F}_N = \{A_1 \times \dots \times A_N \mid A_i \in \mathcal{F}_i\}$ , Menge aller  $N$ -dimensionalen Zylinder,  $C_N = \times_i \mathcal{F}_i \subseteq 2^{\times_i \Omega_i}$ . Die **Produkt- $\sigma$ -Algebra**  $\otimes_{n=1}^N \mathcal{F}_n$  auf  $\times_{n=1}^N \Omega_n$  ist die kleinste  $\sigma$ -Algebra welche alle Zylinder enthält, d.h.  $\otimes_{n=1}^N \mathcal{F}_n = \sigma(C_N) = \sigma(\times_i \mathcal{F}_i)$ .

**Bemerkung 2.1.1.** *Im Allgemeinen  $C_N \subset \otimes_{n=1}^N \mathcal{F}_n$ .*

**Beispiel 2.1.2.** *Sei  $N = 2$ ,  $\Omega_1 = \Omega_2 = \mathbb{R}$ ,  $\mathcal{F}_1 = \mathcal{F}_2 = \mathcal{B}(\mathbb{R})$ . Dann  $\mathcal{B}(\mathbb{R}) \times \mathcal{B}(\mathbb{R}) \neq \sigma(\mathcal{B}(\mathbb{R}) \times \mathcal{B}(\mathbb{R})) = \mathcal{B}(\mathbb{R}) \otimes \mathcal{B}(\mathbb{R}) = \mathcal{B}(\mathbb{R}^2)$ . Denn für die Menge  $B_r = \{(x, y) \in \mathbb{R}^2 \mid x^2 + y^2 < r\}$  existieren  $A_j \in C_N$ ,  $j \in \mathbb{N}$ , s.d.  $\cup A_j = B_r$ , also  $B_r \in \sigma(\mathcal{B}(\mathbb{R}) \times \mathcal{B}(\mathbb{R}))$ , aber  $B_r$  lässt sich nicht als Produkt darstellen.*

**Definition 2.1.3.** *Ein **Ring**  $R$  auf einer Menge  $\Omega$  ist eine Menge  $R \subseteq 2^\Omega = \{A \mid A \subseteq \Omega\}$  mit folgenden Eigenschaften:*

- 1)  $\emptyset \in R$ ,  $\Omega \in R$ ;
- 2)  $A, B \in R \implies A \setminus B \in R$ ;
- 3)  $A, B \in R \implies A \cup B \in R$ .

**Bemerkung 2.1.4.**

- 1)  $\mathcal{F}$   $\sigma$ -Algebra  $\implies \mathcal{F}$  Ring;
- 2)  $\mathcal{F}$   $\sigma$ -Algebra  $\not\Leftarrow \mathcal{F}$  Ring;
- 3)  $R$  Ring,  $A_n \in R$ ,  $n \in \mathbb{R} \not\Rightarrow \cup_{n \in \mathbb{N}} A_n \in R$
- 4)  $R(C_N) = \{\cup_l A_l \mid A_l \in C_N, A_l \text{ disjunkt}, l = 1, \dots, n, n \in \mathbb{R}\}$  bildet ein Ring.

**Lemma 2.1.5.** *Falls  $\Omega_1 = \dots = \Omega_N$  und  $|\Omega| = n$  und  $2^{\Omega_1} = \mathcal{F}_1 = \mathcal{F}_2 = \dots = \mathcal{F}_N$ , dann ist  $R(C_N) = C_N$ . (ohne Beweis)*

**Definition 2.1.6.** Sei  $R$  ein Ring auf einer Menge  $\Omega$ . Eine Funktion  $\hat{P} : \mathbb{R} \rightarrow [0, 1]$ , welche folgende Eigenschaften

1)  $\hat{P}(\emptyset) = 0, \hat{P}(\Omega) = 1;$

2)  $\hat{P}$  ist additiv;

3)  $\hat{P}$  ist  $\sigma$ -additiv

erfüllt, heißt ein **Pre-W-Maß** auf  $(\Omega, R)$ .

**Satz 2.1.7** (Caratheodory). Ein Pre-W-Maß auf  $(\Omega, R)$  kann eindeutig zu einem W-Maß  $P$  auf  $(\Omega, \sigma(R))$  erweitert werden. (ohne Beweis)

**Bemerkung 2.1.8.** Es ist  $\sigma(C_N) = \sigma(R(C_N))$ , da  $R(C_N) \subseteq \sigma(C_N)$ .

**Korollar 2.1.9.** Jedes Pre-W-Maß  $\hat{P} : R(C_N) \rightarrow [0, 1]$  kann eindeutig auf  $\bigotimes_{n=1}^N \mathcal{F}_n$  als W-Maß  $P$  erweitert werden, d.h. auf  $(\times_{n=1}^N \Omega_n, \bigotimes_{n=1}^N \mathcal{F}_n)$ .

**Bemerkung 2.1.10.** Sei  $\mathcal{S}_d = \{(a_1, b_1] \times \dots \times (a_d, b_d] \mid a_i < b_i, a_i, b_i \in \mathbb{R}\}$ . Dann gilt es:  $R(\mathcal{S}_d) = \{\dot{\cup}_j A_j \mid A_j \in \mathcal{S}_d, j = 1, \dots, n\}$  ist ein Ring und  $\sigma(\mathcal{S}_d) = \sigma(R(\mathcal{S}_d)) = \sigma(\mathcal{B}(\mathbb{R}) \times \dots \times \mathcal{B}(\mathbb{R})) = \mathcal{B}(\mathbb{R}) \otimes \dots \otimes \mathcal{B}(\mathbb{R}) = \mathcal{B}(\mathbb{R}^d)$  ist eine  $\sigma$ -Algebra.

## 2.2 Produkt-Wahrscheinlichkeitsmaß auf Produkträume

**Satz 2.2.1.** Sei  $(\Omega_1, \mathcal{F}_1, \mathbb{P}_1), \dots, (\Omega_N, \mathcal{F}_N, \mathbb{P}_N)$  W-Räume. Dann existiert eindeutig ein W-Maß  $\bigotimes_{n=1}^N \mathbb{P}_n$  auf  $(\times_{n=1}^N \Omega_n, \bigotimes_{n=1}^N \mathcal{F}_n)$ , s.d. für alle  $A = A_1 \times \dots \times A_N \in C_N = \mathcal{F}_1 \times \dots \times \mathcal{F}_N$  gilt:  $\bigotimes_{n=1}^N \mathbb{P}_n(A) = \prod_{n=1}^N \mathbb{P}_n(A_n)$ .

**Beweis.** [Skizze] Man definiere zuerst  $\bigotimes_{l=1}^N \hat{P}_l(\dot{\cup}_l B_l) = \prod_{l=1}^N \hat{P}_l(B_l)$  für alle  $\cup B_l \in R(C_N), B_l \in C_N, B_l$  paarweise disjunkt. Dann zeigt man, dass  $\bigotimes_{l=1}^N \hat{P}_l$  ein Pre-W-Maß auf  $(\times_{l=1}^N \Omega_l, R(C_N))$  ist und verwendet folglich den Satz von Caratheodory. □

**Definition 2.2.2.** Sei  $d \in \mathbb{N}$ . Eine  **$d$ -Verteilung** ist ein W-Maß auf  $(\mathbb{R}^d, \mathcal{B}(\mathbb{R}^d)) = (\times_{i=1}^d \mathbb{R}, \bigotimes_{i=1}^d \mathcal{B}(\mathbb{R}))$ .



**Satz 2.2.3.** Für jede 1-dim. Verteilungen  $\mu_1, \dots, \mu_d$  auf  $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$  existiert es eine eindeutige  $d$ -dim. Verteilung  $\mu_1 \otimes \dots \otimes \mu_d = \bigotimes_{i=1}^d \mu_i$ , s.d.  $\mu_1 \otimes \dots \otimes \mu_d((a_1, b_1] \times \dots \times (a_d, b_d]) = \prod_{i=1}^d \mu_i((a_i, b_i])$ . Das ist die **Produktverteilung** von  $\mu_1, \dots, \mu_d$ . (ohne Beweis)

**Lemma 2.2.4.** Sei  $\mathbb{P}$  ein  $W$ -Maß auf  $(\times_{n=1}^N \Omega_n, \bigotimes_{n=1}^N \mathcal{F}_n)$  und für  $j = 1, \dots, N$  sei  $\pi_j \mathbb{P} : \mathcal{F}_j \rightarrow [0, 1]$ ,  $A_j \mapsto \mathbb{P}(C_{A_j}^j)$ , wobei  $C_{A_j}^j = \Omega \times \dots \times \Omega \times A_j \times \Omega \times \dots \times \Omega$ . Dann ist  $\pi_j \mathbb{P}$  ein  $W$ -Maß auf  $(\Omega, \mathcal{F}_j)$ .

**Beweis.**  $\pi_j \mathbb{P}(\emptyset) = 0$ ,  $\pi_j \mathbb{P}(\Omega) = 1$ ,  $\pi_j \mathbb{P}$  ist additiv. Wende den Satz von Caratheodory an.  $\square$

**Definition 2.2.5.**  $\pi_j \mathbb{P}$  ist die **marginale** oder **projektive**  $W$ -keit von  $\mathbb{P}$  auf  $(\Omega, \mathcal{F}_j)$ .

**Bemerkung 2.2.6.** Es gibt mehrere  $W$ -Maße  $\mathbb{P}$ , welche unterschiedlich sind, die aber gleiche marginale  $W$ -keiten haben.

**Beispiel 2.2.7.** Sei  $N = 2$ . Seien  $P_1$  die Verteilung von  $(X, Y)$  auf  $(\mathbb{R}^2, \mathcal{B}(\mathbb{R}^2))$ , wobei  $X \sim Y \sim U_{[0,1]}$  unabhängig, und  $P_2$  die Verteilung von  $(X, -X)$  auf  $(\mathbb{R}^2, \mathcal{B}(\mathbb{R}^2))$ . Es ist  $\pi_1 P_1((-\infty, x)) = \pi_2 P_1((-\infty, x)) = F_{U_{[0,1]}}(x)$  und  $\pi_1 P_2((-\infty, x)) = \pi_2 P_2((-\infty, x)) = F_{U_{[0,1]}}(x)$ . Weiterhin gilt  $P_1((a, b] \times (c, d]) = P_1(X \in (a, b], Y \in (c, d]) = P_1(X \in (a, b])P_1(Y \in (c, d]) = \pi_1 P_1((a, b])\pi_2 P_1((c, d])$ , also  $P_1$  ist die Produktwahrscheinlichkeit von zwei uniforme verteilte ZV. Aber  $P_2(X \in (a, b], -X \in (c, d]) \neq \pi_1 P_2(X \in (a, b])\pi_2 P_2(-X \in (c, d])$ , also  $P_1 \neq P_2$ .

**Korollar 2.2.8.** Sei  $\mu^d$  eine  $d$ -dim. Verteilung, dann ist  $\pi_j \mu^d : \mathcal{B}(\mathbb{R}^d) \rightarrow [0, 1]$ ,  $B \mapsto \mu^d(\mathbb{R} \times \dots \times \mathbb{R} \times B \times \mathbb{R} \times \dots \times \mathbb{R})$  Verteilung auf  $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ .

**Definition 2.2.9.**  $\pi_j \mu^d$  wird auch **Randverteilung** von  $\mu^d$  genannt. Dessen Verteilungsfunktion wird **Randverteilungsfunktion** genannt.

**Definition 2.2.10.** Die Funktion  $H : \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$ ,  $(x, y) \mapsto \mu^2(x, y)$  heißt **2-dim. Verteilungsfunktion** von  $\mu^2$ .

**Lemma 2.2.11.** Sei  $\mu^2$  eine 2-dim. Verteilung mit Randverteilungsfunktionen  $F : \mathbb{R} \rightarrow \mathbb{R}$ ,  $G : \mathbb{R} \rightarrow \mathbb{R}$  und 2-dim. Verteilungsfunktion  $H$ ,  $H(x, y) = \mu^2((-\infty, x], (-\infty, y])$ . Dann gilt für alle  $x_1 < y_1, x_2 < y_2$ :  $|H(x_2, y_2) - H(x_1, y_1)| \leq |F(x_2) - F(x_1)| + |G(y_2) - G(y_1)|$ .

**Beweis.**  $|H(x_2, y_2) - H(x_1, y_1)| \leq |H(x_2, y_2) - H(x_1, y_2)| + |H(x_1, y_2) - H(x_1, y_1)| \leq \lim_{y_2 \rightarrow \infty} |H(x_2, y_2) - H(x_1, y_2)| + \lim_{x_1 \rightarrow \infty} |H(x_1, y_2) - H(x_1, y_1)| = |F(x_2) - F(x_1)| + |G(y_2) - G(y_1)|. \quad \square$

**Errinerung:** Sei  $\mu^2$  eine 2-dim. Verteilung, sei  $H : \mathbb{R}^2 \rightarrow [0, 1]$ ,  $(x, y) \mapsto \mu^2((-\infty, x], (-\infty, y])$ . Dann gilt:

- 1)  $H(x_y)$  ist in jedem Argument monoton wachsend;
- 2)  $H(x_y)$  ist in jedem Argument rechtsstetig;
- 3)  $F : x \mapsto \lim_{y \rightarrow \infty} H(x, y)$  ist eine Verteilungsfunktion (und zwar Randverteilungsfunktion);
- 4)  $G : y \mapsto \lim_{x \rightarrow \infty} H(x, y)$  ist eine Verteilungsfunktion (und zwar Randverteilungsfunktion);
- 5) Falls  $a < b, c < d$  so ist  $H(b, d) - H(b, c) - H(a, d) + H(a, c) \geq 0$ .

**Beweis.**

1)  $H_x : \mathbb{R} \rightarrow \mathbb{R}, y \mapsto H(x, y) = \mu^2((-\infty, x], (-\infty, y])$  ist monoton wachsend, weil  $\mu^2$  ein W-Maß ist und für  $y < y'$   $(-\infty, x], (-\infty, y] \subset (-\infty, x], (-\infty, y']$  gilt. Analog  $H_y$ ;

2)  $H_x(y) = \mu^2((-\infty, x], (-\infty, y]) = \mu^2(\bigcap_{n \in \mathbb{N}} (-\infty, x], (-\infty, y + \frac{1}{n}])$ , folglich, wegen Monotonie von Maße,  $H(x, y) = \lim_{n \rightarrow \infty} \mu^2((-\infty, x], (-\infty, y + \frac{1}{n}]) = \lim_{n \rightarrow \infty} H_x(y + \frac{1}{n})$ , da  $H_x$  monoton ist;

3)  $\checkmark$ ;

4) ✓;

5) Folgt wegen  $(a, b] \times (c, d] = \{(-\infty, b] \times (-\infty, d] \setminus (-\infty, b] \times (-\infty, c]\} \setminus \{(-\infty, a] \times (-\infty, d] \setminus (-\infty, a] \times (-\infty, c]\}$ .

□

**Satz 2.2.12.** Sei  $H : \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$  eine Funktion, die Eigenschaften 1)-5) von oben erfüllt, dann existiert eine 2-dim. Verteilung  $\mu^2$ , s.d.  $\mu^2((-\infty, x], (-\infty, y]) = H(x, y)$ , d.h.  $H$  ist die Verteilungsfunktion von  $\mu^2$ .

*Beweis.* Via Satz von Carathéodory. □

**Definition 2.2.13.** Im Allgemeinen nennt man eine Funktion  $H : \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$ , die Eigenschaften 1)-5) von oben erfüllt, eine **2-dim. Verteilungsfunktion**.

**Bemerkung 2.2.14.** Es gibt 1 : 1 Zuordnung: 2-dim. Verteilungen  $\leftrightarrow$  2-dim. Verteilungsfunktionen.

**Lemma 2.2.15.** Sei  $\mu^2$  eine 2-dim. Verteilung, dann existiert immer (unendlich viele) ZV  $(X, Y)$  mit Wertebereich  $(\mathbb{R}^2, \mathcal{B}(\mathbb{R}^2))$ , s.d.  $(X, Y)$  die Verteilung  $\mu^2$  hat, d.h. es existiert mindestens ein  $(\Omega, \mathcal{F}, \mathbb{P})$  W-Raum mit einer ZV  $(X, Y)$ , s.d.  $\mathbb{P}(X \leq x, Y \leq y) = \mu^2((-\infty, x], (-\infty, y])$ .

*Beweis.*  $(\Omega, \mathcal{F}, \mathbb{P}) = (\mathbb{R}^2, \mathcal{B}(\mathbb{R}^2), \mu^2)$ ,  $(X, Y) = Id^2$ . □

### 3 Copulae

**Definition 3.0.16.** Sei  $\bar{\mathbb{R}} = [-\infty, \infty]$  und seien  $S_1, \dots, S_n$  nichtleere Teilmengen von  $\bar{\mathbb{R}}$ . Sei  $H$  eine  **$n$ -dim. reelle Funktion** mit  $\text{dom}(H) = S_1 \times \dots \times S_n$ . Es gelte  $a \leq b$  für  $a, b \in \mathbb{R}^n$  falls  $a_k \leq b_k$  für alle  $k = 1, \dots, n$  ist. Für  $a \leq b$  sei ein  **$n$ -Quadrat**  $B$  definiert als das kartesische Produkt über  $n$  abgeschlossene Intervalle, deren  $2^n$  Eckpunkte in  $\text{dom}(H)$  liegen, d.h.  $B = [a, b] = [a_1, b_1] \times \dots \times [a_n, b_n]$ . Mit  $I^n = I \times \dots \times I$ , wobei  $I = [0, 1]$ , bezeichnen wir das **Einheitsquadrat** in  $\mathbb{R}^n$ .

**Definition 3.0.17.** Das *H-Volumen* von einem Quadrat  $B$  ist definiert als  $V_H(B) = \sum \text{sgn}(c)H(c)$ , wobei die Summe über alle Ecken  $c = (c_1, \dots, c_n)$  läuft, mit  $c_i \in \{a_i, b_i\}$  für alle  $i = 1, \dots, n$ . Die Funktion  $\text{sgn}(c)$  ist definiert durch

$$\text{sgn}(c) = \begin{cases} 1 & \text{falls } c_k = a_k \text{ fuer eine gerade Anzahl von } k\text{'s,} \\ -1 & \text{sonst.} \end{cases}$$

**Lemma 3.0.18.** Äquivalent zur obigen Darstellung von  $H$ -Volumen des  $n$ -Quadrates  $B$  ist die Darstellung als Differenz  $n$ -ter Ordnung von  $H$  auf  $B$ , d.h.

$V_H(B) = \Delta_a^b H(t) = \Delta_{a_1}^{b_1} \dots \Delta_{a_n}^{b_n} H(t)$ , wobei die Differenz der  $k$ -ter Ordnung definiert als  $\Delta_{a_k}^{b_k} H(t_1, \dots, t_{k-1}, t, t_{k+1}, \dots, t_n) = H(t_1, \dots, t_{k-1}, b_k, t_{k+1}, \dots, t_n) - H(t_1, \dots, t_{k-1}, a_k, t_{k+1}, \dots, t_n)$ .

**Beweis.** Falls  $n = 2$  gilt:  $V_H(B) = \Delta_{a_1}^{b_1} \Delta_{a_2}^{b_2} H(t_1, t_2) = H(b_1, b_2) - H(b_1, a_2) - H(a_1, b_2) + H(a_1, a_2) = \sum \text{sgn}(c)H(c)$ . Dann läuft die Behauptung durch Induktion. □

**Definition 3.0.19.** Eine  $n$ -dim. reelle Funktion  $H$  heißt  *$n$ -steigend*, falls  $V_H(B) \geq 0$  für alle  $n$ -Quadrate  $B$ , dessen Ecken in  $\text{dom}(H)$  liegen.

**Bemerkung 3.0.20.** Die folgende Beispiele zeigen: falls  $H$  eine  $n$ -stegende Funktion ist, dann folgt daraus NICHT, dass  $H$  monoton steigend in jeder Variable ist. Der Umkehrschluss ist auch nicht möglich.

**Beispiel 3.0.21.** Sei  $H$  eine Funktion auf dem Einheitsquadrat  $I^2$  definiert durch  $H(a, b) = \{a, b\}$ , so ist  $H$  monoton steigend in jeder Variable. Jedoch ist  $H$  nicht 2-steigend, da  $V_H(I^2) = H(1, 1) - H(0, 1) - H(1, 0) + H(0, 0) = -1$ .

**Beispiel 3.0.22.** Sei  $H$  eine Funktion definiert auf  $I^2$  durch  $H(a, b) = (2a - 1)(2b - 1)$ . Dann ist  $H$  2-steigend, denn sei  $B = [a_1, a_2] \times [b_1, b_2]$ . Dann gilt  $V_H(B) = H(a_2, b_2) - H(a_2, b_1) - H(a_1, b_2) + H(a_1, b_1) = 4(a_2 - a_1)(b_2 - b_1) \geq 0$ . Weiter ist  $H$  nicht monoton steigend in jeder Variable, denn für  $a < \frac{1}{2}$  ist  $H$  monoton fallend falls  $b \in (\frac{1}{2}, 1)$ .

**Definition 3.0.23.** Sei  $a_k$  jeweils das kleinste Element der nichtleeren Teilmengen  $S_k \subseteq \bar{\mathbb{R}}$  mit  $k = 1, \dots, n$ . Man nennt eine Funktion  $H : S_1 \times \dots \times S_n \rightarrow \bar{\mathbb{R}}$  **geerdet**, falls  $H(x_1, \dots, x_n) = 0$  gilt, wenn für mindestens ein  $x_i$  mit  $i = 1, \dots, n$  gilt  $x_i = a_i$ .

**Lemma 3.0.24.** Seien  $S_1, \dots, S_n$  nichtleere Teilmengen von  $\bar{\mathbb{R}}$  und sei  $H$  eine  $n$ -steigende Funktion mit  $\text{dom}(H) = S_1 \times \dots \times S_n$ , dann ist die Funktion  $t \mapsto H(x_1, \dots, x_{l-1}, s, x_{l+1}, \dots, x_{k-1}, t, x_{k+1}, \dots, x_n) - H(x_1, \dots, x_{l-1}, r, x_{l+1}, \dots, x_{k-1}, t, x_{k+1}, \dots, x_n)$  monoton steigend (in jeder Variable),  $k \neq l$ , und  $k, l \in \{1, \dots, n\}$ . Hierbei ist  $x_i \in S_i$  für  $i = 1, \dots, n$  und  $r, s \in S_l$  mit  $r \leq s$ .

**Beweis.** Es gilt für  $t_1 \leq t_2$ :  $H(x_1, \dots, x_{l-1}, s, x_{l+1}, \dots, x_{k-1}, t_2, x_{k+1}, \dots, x_n) - H(x_1, \dots, x_{l-1}, r, x_{l+1}, \dots, x_{k-1}, t_2, x_{k+1}, \dots, x_n) - H(x_1, \dots, x_{l-1}, s, x_{l+1}, \dots, x_{k-1}, t_1, x_{k+1}, \dots, x_n) + H(x_1, \dots, x_{l-1}, r, x_{l+1}, \dots, x_{k-1}, t_1, x_{k+1}, \dots, x_n) = \Delta_r^s \Delta_{t_1}^{t_2} \geq 0$ , da  $H$   $n$ -steigend.

Also gilt die Behauptung.  $\square$

**Lemma 3.0.25.** Seien  $S_1, \dots, S_n$  nichtleere abgeschlossene Teilmengen von  $\bar{\mathbb{R}}$ , wobei jede  $S_i$  seines kleinsten Element  $a_i$  enthält. Sei  $H$  eine geerdete und  $n$ -steigende Funktion mit  $\text{dom}(H) = S_1 \times \dots \times S_n$ . Dann ist  $H$  monoton steigend in jeder Variable.

**Beweis.** Es ist zu zeigen, dass für  $(x_1, \dots, x_{k-1}, r, x_{k+1}, \dots, x_n), (x_1, \dots, x_{k-1}, s, x_{k+1}, \dots, x_n) \in \text{dom}(H)$  und  $r \leq s$  die folgende Ungleichung gilt:  $H(x_1, \dots, x_{k-1}, r, x_{k+1}, \dots, x_n) \leq H(x_1, \dots, x_{k-1}, s, x_{k+1}, \dots, x_n)$ . Da  $a_k$  jeweils das kleinste Element von  $S_k$  ist, haben wir  $B = [(a_1, \dots, a_{k-1}, r, a_{k+1}, \dots, a_n), (x_1, \dots, x_{k-1}, s, x_{k+1}, \dots, x_n)]$ . Nun ist  $H$   $n$ -steigend,  $V_H(B) \geq 0$ , und es ist geerdet, weshalb  $0 \leq V_H(B) = H(x_1, \dots, x_{k-1}, s, x_{k+1}, \dots, x_n) - H(x_1, \dots, x_{k-1}, r, x_{k+1}, \dots, x_n)$ , da alle andere Summanden mindestens eine  $a_i$  enthalten und somit wegfallen, d.h. die gewünschte Ungleichung gilt und somit die Behauptung.  $\square$

**Definition 3.0.26.** Eine  $n$ -dim. Verteilungsfunktion  $H$  ist eine Funktion mit Definitionsbereich  $\bar{\mathbb{R}}^n$ , für die gilt, dass  $H$  geerdet und  $n$ -steigend und

$H(\infty, \dots, \infty) = 1$  gilt.

**Definition 3.0.27.** Sei  $b_k$  jeweils das größte Element der nichtleeren Teilmengen  $S_k \subseteq \bar{\mathbb{R}}$  mit  $k = 1, \dots, n$  und  $H$  eine Funktion auf  $S_1 \times \dots \times S_n$ . Dann nennen wir  $H_k$  die **eindimensionale Randverteilung** für  $k \in \{1, \dots, n\}$ , falls gilt:

- 1)  $\text{dom}(H_k) = S_k$ ;
- 2)  $H_k(x) = H(b_1, \dots, b_{k-1}, x, b_{k+1}, \dots, b_n)$  für alle  $x \in S_k$ .

Wir erhalten mehrdimensionale Randverteilungen, indem wir weniger Variablen fixieren.

**Lemma 3.0.28.** Sei  $X$  eine ZV mit Verteilungsfunktion  $F$ . Dann gilt für alle  $x$ :  $\mathbb{P}(F(X) \leq F(x)) = F(x)$ .

**Beweis.** Es ist  $\{F(X) \leq F(x)\} = (\{F(X) \leq F(x)\} \cap \{X \leq x\}) \cup (\{F(X) \leq F(x)\} \cap \{X > x\})$ . Nun gilt  $\{X \leq x\} \subseteq \{F(X) \leq F(x)\}$  und  $\{F(X) \leq F(x)\} \cap \{X > x\} \neq \emptyset$ . Also  $\{F(X) \leq F(x)\} = \{X \leq x\} \cup (\{F(X) = F(x)\} \cap \{X > x\})$ . Wenn wir auf beiden Seiten der letzten Gleichung die W-keit berechnen, erhalten wir  $\mathbb{P}(F(X) \leq F(x)) = \mathbb{P}(X \leq x) + \mathbb{P}((F(X) = F(x)) \cap (X > x)) = \mathbb{P}(X \leq x)$ . □

**Satz 3.0.29.** Sei  $X$  eine reellwertige ZV mit Verteilungsfunktion  $F$ . Es gelten folgende Aussagen:

- 1) Falls  $F$  stetig ist, so ist die ZV  $Y = F(X)$  uniform,  $U_{[0,1]}$ , verteilt.
- 2) Falls  $F^{-1} : [0, 1] \rightarrow (-\infty, \infty)$  definiert durch  $F^{-1}(y) = \inf\{x \mid F(x) \geq y\}$  mit  $0 < y < 1$  und  $Y$  eine ZV mit  $U_{[0,1]}$ -Verteilung ist, dann hat  $X = F^{-1}(Y)$  Verteilungsfunktion  $F$ .

**Beweis.**

- 1) Sei  $u \in (0, 1)$ . Da  $F$  stetig ist, existiert es ein  $x \in \mathbb{R}$  mit  $F(x) = u$ . Aus 3.0.28 folgt  $\mathbb{P}(Y \leq u) = \mathbb{P}(F(X) \leq F(x)) = u$ , weshalb  $Y$  uniform verteilt ist.

2) Für ein  $x \in \mathbb{R}$  mit  $0 < F(x) < 1$  und  $u \in [0, 1]$  gilt  $F(x) \geq u$  genau dann, falls  $x \geq F^{-1}(u)$  gilt. Angenommen, es gilt  $x \geq F^{-1}(u) = \inf\{x \mid F(x) \geq u\}$ . Dann gilt, da  $F$  als Verteilungsfunktion monoton steigend und rechtsstetig ist, dass  $\{x \mid F(x) \geq u\}$  ein Intervall ist, das den linken Endpunkt beinhaltet. Also  $F(x) \geq u$  für alle  $x$ . Umgekehrt, falls  $F(x) \geq u$  gilt, so folgt  $x \geq \inf\{x \mid F(x) \geq u\} = F^{-1}(u)$ . Also  $\mathbb{P}(F^{-1}(Y) \leq x) = \mathbb{P}(Y \leq F(x)) = F(x)$ .  $\square$

**Satz 3.0.30.** Seien  $S_1, \dots, S_n$  nichtleere Teilmengen von  $\bar{\mathbb{R}}$ , welche jeweils ihr kleinstes Element  $a_k$  und größtes Element  $b_k$  beinhalten. Sei  $H$  eine  $n$ -steigende und geordnete Funktion mit eindimensionalen Randverteilungen  $H_1, \dots, H_n$ . Dann gilt für  $(x_1, \dots, x_{k-1}, x, x_{k+1}, \dots, x_n) \in \text{dom}(H)$ , dass  $0 \leq H(x_1, \dots, x_{k-1}, x, x_{k+1}, \dots, x_n) \leq H_k(x)$ .

*Beweis.* Definition der Randverteilung und 3.0.25.  $\square$

**Satz 3.0.31.** Seien  $S_1, \dots, S_n$  nichtleere Teilmengen von  $\bar{\mathbb{R}}$ , welche jeweils ihr kleinstes Element  $a_k$  und größtes Element  $b_k$  beinhalten. Sei  $H$  eine  $n$ -steigende und geordnete Funktion mit  $\text{dom}(H) = S_1 \times \dots \times S_n$  und eindimensionalen Randverteilungen  $H_1, \dots, H_n$ . Dann gilt für  $(x_1, \dots, x_n), (y_1, \dots, y_n) \in S_1 \times \dots \times S_n$ , dass  $|H(x_1, \dots, x_n) - H(y_1, \dots, y_n)| \leq \sum_{k=1}^n |H_x(x_k) - H_k(y_k)|$ .

*Beweis.* Mit Dreiecksungleichung folgt:  $|H(x_1, \dots, x_n) - H(y_1, \dots, y_n)| \leq |H(y_1, \dots, y_n) - H(x_1, y_2, \dots, y_n)| + |H(x_1, y_2, \dots, y_n) - H(x_1, x_2, y_3, \dots, y_n)| + \dots + |H(x_1, \dots, x_{n-1}, y_n) - H(x_1, \dots, x_n)|$ . Sei nun oBdA  $x_k \leq y_k$  ( $x_k \geq y_k$  folgt analog). Da  $H$  geordnet und  $n$ -steigend ist, gilt mit 3.0.25, dass  $0 \leq |H(y_1, \dots, y_k, x_{k+1}, \dots, x_n) - H(y_1, \dots, y_{k-1}, x_k, \dots, x_n)|$  für alle  $k = 1, \dots, n$ . Nun folgt aus  $n - 1$  Anwendung von 3.0.24, dass die Randverteilungen von  $H$  existieren und es gilt  $0 \leq |H(y_1, \dots, y_k, x_{k+1}, \dots, x_n) - H(y_1, \dots, y_{k-1}, x_k, \dots, x_n)| \leq |H_k(y_k) - H_k(x_k)|$  für jedes  $k = 1, \dots, n$ . Dies führt man nun so weiter für alle  $k = 1, \dots, n$  und ersetzt in erster Ungleichung die Terme.  $\square$

**Definition 3.0.32.** Eine *n-Subcopula* ist eine Funktion  $C'$  mit den folgenden Eigenschaften:

- (a)  $\text{dom}(c') = S_1 \times \dots \times S_n$ , wobei  $S_1, \dots, S_n$  Teilmengen vom Einheitsintervall  $I$  sind, die die beiden Punkte 0 und 1 enthalten;
- (b)  $c'$  ist geerdet;
- (c)  $C'$  ist  $n$ -steigend;
- (d) Die Randverteilung  $C_k$  mit  $k = 1, \dots, n$  uniform auf  $I$  verteilt.

Eigenschaft (d) heißt, dass z.B. für eine 2-Subcopula gilt  $C'(u, 1) = u$  und  $C'(1, v) = v$  für alle  $u \in S_1$  und  $v \in S_2$ .

**Definition 3.0.33.** Eine *n-Copula*  $C$  ist eine  $n$ -Subcopula mit  $\text{dom}(C) = I^n$ .

**Bemerkung 3.0.34.**

- 1) Ist  $C$  eine  $n$ -Copula, dann ist jede  $k$ -dim. Randverteilung eine  $k$ -Copula.
- 2) Copulas sind Verteilungsfunktionen von  $I^n$  nach  $I$ , d.h. sie induzieren W-maße auf  $I^n$  durch  $V_C([0, u_1] \times \dots \times [0, u_n]) = C(u_1, \dots, u_n)$ .

**Satz 3.0.35.** Jede  $n$ -Copula  $C$  ist gleichmäßig stetig auf ihrem Definitionsbereich, d.h. für alle  $u, v \in I^n$  erfüllt  $C$  die Lipschitz-Eigenschaft:  $|C(v) - C(u)| \leq \sum_{k=1}^n |v_k - u_k|$ .

**Beweis.** Es gilt  $|C(u) - C(v)| \leq \sum_{k=1}^n |C_k(v_k) - C_k(u_k)| = \sum_{k=1}^n |v_k - u_k|$  wegen 3.0.31 und Definition von  $n$ -Subcopula. □

**Satz 3.0.36.** Sei  $C(u_1, \dots, u_n)$  eine Copula. Für beliebige  $u_1, \dots, u_{i-1}, u_{i+1}, \dots, u_n \in I$  existieren die partielle Ableitungen  $\frac{\partial C}{\partial u_i}$  für fast alle  $u_i, i = 1, \dots, n$ , und es gilt  $0 \leq \frac{\partial C(u_1, \dots, u_n)}{\partial u_i} \leq 1$ .

**Beweis.** Monotone Funktionen sind fast überall differenzierbar, weshalb die partiellen Ableitungen  $\frac{\partial C}{\partial u_i}$  existieren. Es ist  $\frac{\partial C(u_1, \dots, u_n)}{\partial u_i} \geq 0$ , da  $C$  streng monoton steigend in jeder Variable ist. Setzen wir in 3.0.35 die  $u_1 = v_1, \dots, u_{i-1} = v_{i-1}, u_{i+1} = v_{i+1}, \dots, u_n = v_n, i = 1, \dots, n$ , so gilt auch  $\frac{\partial C(u_1, \dots, u_n)}{\partial u_i} \leq 1$ . □



### 3.1 Übung

**Beispiel 3.1.1.** Sei  $X \sim U_{[0,1]}$  eine auf  $[0, 1] \subset \mathbb{R}$  uniform verteilte ZV. Dann gilt es für alle  $z = (z_1, z_2) \in [0, 1]^2$  :

(i) Ist  $Z_0 := (X, X)$ , so ist die Wahrscheinlichkeitsverteilung

$\mathbb{P}(Z_0 \leq z) := \mathbb{P}(X \leq z_1 \wedge X \leq z_2) = \mathbb{P}(X \leq \min\{z_1, z_2\}) = \min\{z_1, z_2\}$  eine Copula.

(ii) Ist  $Z_1 := (X, 1 - X)$ , so ist die Wahrscheinlichkeitsverteilung

$\mathbb{P}(Z_1 \leq z) = \mathbb{P}(X \leq z_1 \wedge 1 - X \leq z_2) = \mathbb{P}(1 - z_2 \leq X \leq z_1) = \max\{0, z_1 + z_2 - 1\}$  eine Copula.

(iii) Ist  $Y \sim X, Y \perp\!\!\!\perp X$  und  $Z_2 := (X, Y)$ , so ist die Wahrscheinlichkeitsverteilung  $\mathbb{P}(Z_2 \leq z) = \mathbb{P}(X \leq z_1)\mathbb{P}(Y \leq z_2) = z_1 z_2$  eine Copula.

### 3.2 Graph einer 2-dim. Copula

**Definition 3.2.1.** Sei  $C$  eine 2-dim. Copula und  $a \in I$  beliebig. Der horizontale Abschnitt von  $C$  in  $a$  ist eine Funktion von  $I$  nach  $I$  definiert durch  $t \mapsto C(t, a)$ . Der vertikale Abschnitt von  $C$  in  $a$  ist die Funktion von  $I$  nach  $I$  definiert durch  $t \mapsto C(a, t)$ . Der diagonale Abschnitt von  $C$  ist die Funktion  $\delta_C : I \rightarrow I$  definiert durch  $\delta_C(t) = C(t, t)$ .

**Korollar 3.2.2.** Der horizontale, vertikale und diagonale Abschnitt einer 2-dim. Copula sind monoton steigend und gleichmäßig stetig.

**Beweis.** Folgt wegen 3.0.25 und 3.0.35. □

### 3.3 Systematisches Risiko

Seien  $L_1, \dots, L_n$  ZV die Verluste beschreiben, und die eine gemeinsame Verteilung  $\mu$  haben (und i.A. NICHT stochastisch unabhängig sind). Wir suchen

systematische Risikoeffekte, z. B.  $\mathbb{P}(L_1 > u_1, \dots, L_{n-1} > u_{n-1} \mid L_n > u)$ , wobei  $u$  und  $u_1, \dots, u_{n-1}$  Extremwerte sind. Oder fragen wir uns sogar:  $\mathbb{P}(L_1 > VaR_\alpha(L_1), \dots, L_{n-1} > VaR_\alpha(L_{n-1}) \mid L_n > VaR_\alpha(L_n))$  - ? und um die Fragen zu beantworten benutzen wir Copulas, denn diese geben einen Zusammenhang (siehe Satz von Sklar) zwischen gemeinsamer Verteilungsfunktion  $H(x_1, \dots, x_n)$  von  $L_1, \dots, L_n$  und den Randverteilungen.

**Definition 3.3.1.** Eine  $n$ -dim. Verteilung  $\mu$  ist ein  $W$ -maß auf  $(\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$ .

**Definition 3.3.2.** Eine  $n$ -dim. Verteilung  $\mu$  hat **Träger**  $[A, B] = [A_1, B_1] \times \dots \times [A_n, B_n]$  mit  $A_1, B_1, \dots, A_n, B_n \in \bar{\mathbb{R}}$  falls:

- 1)  $\mu([A, B]) = 1$ ;
- 2)  $\mu([A, B]^c) = 0$ ,
- 3)  $\lambda([A, B]) \leq \lambda([A', B'])$  für alle  $[A', B'] = [A'_1, B'_n] \times \dots \times [A'_n, B'_n]$  für die 1)+2) auch gilt.

**Definition 3.3.3.** Sei  $a_k$  jeweils das kleinste Element der nichtleeren Teilmengen  $S_k \subseteq \bar{\mathbb{R}}$  mit  $k = 1, \dots, n$ . Man nennt eine Funktion  $H : S_1 \times \dots \times S_n \rightarrow \bar{\mathbb{R}}$  **geerdet**, falls  $H(x_1, \dots, x_n) = 0$  gilt, wenn für mindestens ein  $x_i$  mit  $i = 1, \dots, n$  gilt  $x_i = a_i$ .

**Definition 3.3.4.** Eine Funktion  $H : \bar{\mathbb{R}} \rightarrow [0, 1]$  hat **Träger**  $[A, B] = [A_1, B_1] \times \dots \times [A_n, B_n]$  mit  $A_1, B_1, \dots, A_n, B_n \in \bar{\mathbb{R}}$  falls:

- 1)  $V_H([A, B]) = \Delta_{A_1}^{B_1} \dots \Delta_{A_n}^{B_n} H = 1$ ;
- 2)  $H(A_1, x_2, \dots, x_n) = H(x_1, A_2, \dots, x_n) = \dots = H(x_1, x_2, \dots, A_n) = 0$  (d.h.  $H$  ist auf  $[A, B]$  geerdet).

**Definition 3.3.5.** Eine  $n$ -dim. Verteilungsfunktion  $H$  ist eine Funktion  $H : \bar{\mathbb{R}} \rightarrow [0, 1]$  für die gilt, dass

- 1)  $H$  geerdet ist, d.h.  $H(-\infty, x_2, \dots, x_n) = \dots = H(x_1, \dots, x_{n-1}, -\infty) = 0$ ;

2)  $H$  ist  $n$ -monoton steigend;

3)  $H(\infty, \dots, \infty) = 1$ .

**Satz 3.3.6.** Eine  $n$ -dim. Verteilungsfunktion  $H$  induziert eindeutig eine  $n$ -dim. Verteilung  $\mu$  mit der Eigenschaft, dass  $\mu((a_1, b_1] \times \dots \times (a_n, b_n]) = V_H((a_1, b_1] \times \dots \times (a_n, b_n]) = \Delta_{a_1}^{b_1} \dots \Delta_{a_n}^{b_n} H$ , für alle  $a_1, b_1, \dots, a_n, b_n \in \mathbb{R}$ . Umgekehrt, gehört zu jeder  $n$ -dim. Verteilung  $\mu$  eine  $n$ -dim. Verteilungsfunktion  $H$ , für die die Gleichung gilt.

*Beweis.* Siehe W-Theorie. □

**Lemma 3.3.7.** Sei  $H$  eine  $n$ -dim. Verteilungsfunktion mit Verteilung  $\mu$ , dann sind  $H_1(x) = \lim_{(y_2, \dots, y_n) \rightarrow \infty} H(x, y_2, \dots, y_n), \dots, H_n(x) = \lim_{(y_1, \dots, y_{n-1}) \rightarrow \infty} H(y_1, y_2, \dots, x)$  sind 1-dim. Verteilungsfunktionen.

*Beweis.* Siehe W-Theorie. □

**Definition 3.3.8.**  $H_1(x), \dots, H_n(x)$  in Lemma werden **Randverteilungsfunktionen** von  $H$  genannt, dessen Verteilungen  $\mu_1, \dots, \mu_n$  auf  $(\mathbb{R}, (B)(\mathbb{R}))$  sind die **Randverteilungen** von  $\mu$ .

**Bemerkung 3.3.9.** Zu einer  $n$ -dim. Verteilung  $\mu$  gibt es  $(\infty-)$  viele  $n$ -dim. ZV  $(L_1, \dots, L_n)$  mit Verteilung  $\mu$ . Die 1-dim. ZV  $L_1 = \pi_1(L_1, \dots, L_n), \dots, L_n = \pi_n(L_1, \dots, L_n)$  mit  $\pi_i : \bar{\mathbb{R}}^n \rightarrow \mathbb{R}, (x_1, \dots, x_n) \mapsto x_i$ , die **Projektionen**, haben als Verteilung die Randverteilungen  $\mu_1, \dots, \mu_n$ .

*Beweis.* Siehe W-Theorie. □

**Definition 3.3.10.** Eine  $n$ -dim. **Copula** ist eine  $n$ -dim. Funktion  $C : \bar{\mathbb{R}}^n \rightarrow [0, 1]$  mit Träger  $[0, 1]^n$ , s.d.:

1)  $C$   $n$ -monoton steigend;

2)  $C(u, 1, \dots, 1) = C(1, u, 1, \dots, 1) = \dots = C(1, \dots, 1, u) = u$  für alle  $u \in [0, 1]$ .

**Bemerkung 3.3.11.** Da  $C$   $n$ -monoton steigend ist und Träger auf  $[0, 1]^n$  hat, folgt dass  $C$  geerdet ist.

**Beweis.** Da  $C$  Träger auf  $[0, 1]^n$  hat, folgt dass  $C(0, x_2, \dots, x_n) = C(x_1, 0, x_3, \dots, x_n) = \dots = C(x_1, \dots, x_{n-1}, 0) = 0$ . Da außerdem  $C$   $n$ -monoton steigend ist, folgt  $C(-\infty, x_2, \dots, x_n) = C(x_1, -\infty, x_3, \dots, x_n) = \dots = C(x_1, \dots, x_{n-1}, -\infty) = 0$ . D.h.  $C$  ist geerdet.  $\square$

**Satz 3.3.12.** Eine Funktion  $C : \bar{\mathbb{R}}^n \rightarrow [0, 1]$  ist eine Copula, falls und nur falls  $C$  eine  $n$ -dim. Verteilungsfunktion, dessen Randverteilungen die uniforme Verteilungen auf  $[0, 1]$  sind.

**Beweis.** Sei  $H$  eine  $n$ -dim. Verteilungsfunktionen mit uniformen Randverteilungen  $\mu_1, \dots, \mu_n$ . Dann ist  $H$   $n$ -monoton steigend und auch geerdet. Wir zeigen, dass für  $H$  die zweite Eigenschaft der Definition gilt. Sei  $(L_1, \dots, L_n)$  eine ZV mit  $H$  als Verteilungsfunktion, dann gilt  $H(u, 1, \dots, 1) = \mathbb{P}(L_1 \leq u, L_2 \leq 1, \dots, L_n \leq 1) = \mu_1((-\infty, u]) = u$  und ... und  $H(1, \dots, 1, u) = \mu_n((-\infty, u]) = u$  für alle  $u \in [0, 1]$ . Wir zeigen noch, dass  $H$  Träger auf  $[0, 1]^n$  hat. Es ist  $H(1, \dots, 1) = \mathbb{P}(L_1 \leq 1, \dots, L_n \leq 1) = 1$  und  $H(x_1, \dots, x_{i-1}, 0, x_{i+1}, \dots, x_n) = \mathbb{P}(L_1 \leq x_1, \dots, L_{i-1} \leq x_{i-1}, L_i \leq 0, L_{i+1} \leq x_{i+1}, \dots, L_n \leq x_n) = 0$ . Umgekehrt sei  $C$  eine Copula, dann hat  $C$  alle Eigenschaften einer Verteilungsfunktion, dessen Randverteilungen uniform verteilt sind. Mit dem Träger  $[0, 1] \times \dots \times [0, 1]$ .  $\square$

**Definition 3.3.13.** Eine  $n$ -dim. Funktion  $C' : S_1 \times \dots \times S_n \rightarrow [0, 1]$ ,  $S_i \subseteq [0, 1]$  für die gilt:

1.  $C'$   $n$ -monoton steigend;
2.  $C'(u_1, 1, \dots, 1) = u_1, \dots, C'(u_1, 1, \dots, 1) = u_1$  für alle  $u_i \in S_i$  heißt **Subcopula**.  
D.h. eine Subcopula hat alle Eigenschaften einer Copula, aber der Träger liegt auf einer Menge  $S_1 \times \dots \times S_n \subseteq [0, 1] \times \dots \times [0, 1]$

**Bemerkung 3.3.14.** Eine Copula ist auch eine Subcopula.

**Lemma 3.3.15** (Lemma von Sklar). *Sei  $H$  eine  $n$ -dim. Verteilungsfunktion mit marginalen Verteilungsfunktionen  $F_1, \dots, F_n$ . Dann existiert eindeutig eine Subcopula  $C'$  mit Definitionsbereich  $\text{Dom}(C') = \text{Ran}(F_1) \times \dots \times \text{Ran}(F_n)$ , so dass  $C'(F_1(z_1), \dots, F_n(z_n)) = H(z_1, \dots, z_n)$ .*

**Beweis.** Sei  $C' : \text{Ran}(F_1) \times \dots \times \text{Ran}(F_n) \rightarrow [0, 1]$  mit  $(F_1(z_1), \dots, F_n(z_n)) \mapsto H(z_1, \dots, z_n)$ . Da  $H$  geerdet und  $n$ -monoton steigend ist, folgt  $|H(y_1, \dots, y_n) - H(x_1, \dots, x_n)| \leq |F_1(y_1) - F_1(x_1)| + \dots + |F_n(y_n) - F_n(x_n)|$  s.d.  $C'$  eine Funktion ist, die auch eindeutig definiert ist. Wir beweisen, dass  $C'$  eine Subcopula ist:  $C'$  ist geerdet, weil  $0 \in \text{Ran}(F_i)$  und der kleinste Wert in  $\text{Ran}(F_i)$ , für  $i = 1, \dots, n$ . Also  $C'(0, x_2, \dots, x_n) = H(-\infty, x_2, \dots, x_n) = 0$  und ... und  $C'(x_1, \dots, x_{n-1}, 0) = H(x_1, \dots, x_{n-1}, -\infty) = 0$ . Sei  $u \in \text{Ran}(F_1)$  mit  $F_1(z_1) = u$ , dann  $C'(u, 1, \dots, 1) = C'(F_1(z_1), 1, \dots, 1) = H(z_1, 1, \dots, 1) = F_1(z_1) = u$ . ... Sei  $u \in \text{Ran}(F_n)$  mit  $F_n(z_n) = u$ , dann  $C'(1, \dots, 1, u) = C'(1, \dots, 1, F_n(z_n)) = H(1, \dots, 1, z_n) = F_n(z_n) = u$ . Außerdem folgt daraus insbesondere  $C'(1, \dots, 1) = 1$ . Demnach ist  $C'$  geerdet.  $\square$

**Definition 3.3.16.** *Sei  $F$  eine Verteilungsfunktion  $F : \bar{\mathbb{R}} \rightarrow [0, 1]$ . Eine **quasi-inverse Funktion** von  $F$  ist eine Funktion  $F^{-1}$  mit Definitionsbereich  $[0, 1]$ , s.d.:*

- 1)  $\forall t \in \text{Ran}(F) \exists x \in \bar{\mathbb{R}} (F(x) = t)$ , d.h.  $\forall t \in \text{Ran}(F)$  gilt  $F(F^{-1}(t)) = t$ ;
- 2) Falls  $t \in \text{Ran}(F)$ , so gilt  $F^{-1} = \inf\{x | F(x) \geq t\} = \min\{x | F(x) \geq t\} = \sup\{x \in \bar{\mathbb{R}} | F(x) \leq t\}$ .

**Bemerkung 3.3.17.** *Falls die Verteilungsfunktion  $F : \bar{\mathbb{R}} \rightarrow [0, 1]$  invertierbar ist, gilt außer 1) und 2) noch  $F^{-1}(F(x)) = x$  für alle  $x \in \bar{\mathbb{R}}$ .*

**Korollar 3.3.18.** *Sei  $H$   $n$ -dim. Verteilungsfunktion mit marginalen Verteilungsfunktionen  $F_1, \dots, F_n$  und  $C' : \text{Ran}(F_1) \times \dots \times \text{Ran}(F_n) \rightarrow [0, 1]$  die einzige Subcopula, für die gilt, dass  $C'(F_1(z_1), \dots, F_n(z_n)) = H(z_1, \dots, z_n)$  für al-*

le  $(z_1, \dots, z_n) \in \bar{\mathbb{R}}^n$ . Dann gilt  $C'(z_1, \dots, z_n) = H(F_1^{-1}(z_1), \dots, F_n^{-1}(z_n))$ , wobei  $F_1^{-1}, \dots, F_n^{-1}$  die quasi-inverse Funktionen von  $F_1, \dots, F_n$  sind.

**Beweis.** Folgt direkt aus Voraussetzung und Definition von quasi-inverse Funktionen. □

**Lemma 3.3.19.** Jede Subcopula  $C' : S_1 \times \dots \times S_n \rightarrow [0, 1]$  kann, wenn auch nicht eindeutig, zu einer Copula  $C : \bar{\mathbb{R}}^n \rightarrow [0, 1]$  erweitert werden, d.h. falls  $C' : S_1 \times \dots \times S_n \rightarrow [0, 1]$  eine Subcopula ist, existiert (mindestens) eine Copula  $C : \bar{\mathbb{R}}^n \rightarrow [0, 1]$ , s.d.  $C(u_1, \dots, u_n) = C'(u_1, \dots, u_n)$  für alle  $(u_1, \dots, u_n) \in S_1 \times \dots \times S_n$ .

**Beweis.** Siehe Nelsen. □

**Satz 3.3.20** (Satz von Sklar). Sei  $H$  eine  $n$ -dim. Verteilungsfunktion mit marginalen Verteilungsfunktionen  $F_1, \dots, F_n$ . Dann existiert eine  $n$ -dim. Copula  $C$ , s.d.  $H(x_1, \dots, x_n) = C(F_1(x_1), \dots, F_n(x_n))$  für alle  $x_1, \dots, x_n \in \bar{\mathbb{R}}^n$ . Falls  $F_1, \dots, F_n$  invertierbar sind (wenn  $F_i$  streng steigend und stetig sind) dann ist die Copula  $C$  eindeutig gegeben. Ansonsten ist  $C$  eindeutig nur auf  $\text{Ran}(F_1) \times \dots \times \text{Ran}(F_n)$  definiert. Umgekehrt: Sei  $C$  eine Copula, und  $F_1, \dots, F_n$  1-dim. Verteilungsfunktionen, dann ist  $H(x_1, \dots, x_n) := C(F_1(x_1), \dots, F_n(x_n))$  eine  $n$ -dim. Verteilungsfunktion mit Randverteilungsfunktionen  $F_1, \dots, F_n$ .

**Beweis.**

”  $\Leftarrow$  ” Sei  $C$  eine Copula und  $F_1, \dots, F_n$  1-dim. Verteilungsfunktionen. Wir müssen zeigen, dass  $H(x_1, \dots, x_n) = C((F_1(x_1), \dots, F_n(x_n)))$  eine  $n$ -dim. Verteilungsfunktion.

-  $H$  ist monoton steigend, weil  $C$   $n$ -monoton steigend und  $F_1, \dots, F_n$  monoton steigend;

-  $H$  ist geerdet, weil  $F_1(-\infty) = \dots = F_n(-\infty) = 0$  und  $C$  ist auf  $[0, 1]^n$  geerdet;

- Da  $F_1(\infty) = \dots = F_n(\infty) = 1$  gilt  $H(\infty, \dots, \infty) = 1$ .

$H$  hat als Randverteilungsfunktionen  $F_1, \dots, F_n$ , weil  $H(x_1, \infty, \dots, \infty) = C(F_1(x_1), \infty, \dots, \infty) = F_1(x_1)$  und  $\dots$  und  $H(\infty, \dots, \infty, x_n) = C(\infty, \dots, \infty, F_n(x_n)) = F_n(x_n)$ .

"  $\Rightarrow$  " Sei  $H$  eine  $n$ -dim. Verteilungsfunktion mit Randverteilungen  $F_1, \dots, F_n$ .

Sei, gemäß der Lemma von Sklar,  $C' : \text{Ran}(F_1) \times \dots \times \text{Ran}(F_n) \rightarrow [0, 1]$  die

eindeutige Subcopula für die gilt, dass  $C'((F_1(z_1), \dots, F_n(z_n))) = H(z_1, \dots, z_n)$  für

alle  $(z_1, \dots, z_n) \in \text{Ran}(F_1) \times \dots \times \text{Ran}(F_n)$ . Weiterhin kann  $C'$  zu einer Copu-

la  $C : \bar{\mathbb{R}}^n \rightarrow [0, 1]$  erweitert werden, s.d.  $C(F_1(z_1), \dots, F_n(z_n)) = H(z_1, \dots, z_n)$

für alle  $(z_1, \dots, z_n) \in \bar{\mathbb{R}}^n$ . Wir wollen jetzt zeigen, dass  $C$  eindeutig festge-

legt ist auf  $\text{Dom}(C) = \bar{\mathbb{R}}^n$  falls  $F_1, \dots, F_n$  invertierbar sind. Wegen der In-

vertierbarkeit von  $F_1, \dots, F_n$  gilt:  $\forall (u_1, \dots, u_n) \in \bar{\mathbb{R}}^n \exists! (z_1, \dots, z_n)$  mit  $F_i(z_i) =$

$u_i$ ,  $i = 1, \dots, n$  und  $C(u_1, \dots, u_n) = C(F_1(z_1), \dots, F_n(z_n)) = H(z_1, \dots, z_n) =$

$H(F_1^{-1}(u_1), \dots, F_n^{-1}(u_n))$  für alle  $(u_1, \dots, u_n) \in \bar{\mathbb{R}}^n$ . Folglich  $C$  ist auf  $\text{Dom}(C) =$

$\bar{\mathbb{R}}^n$  eindeutig festgelegt. □

**Zusammenfassung:** Falls  $(X_1, \dots, X_n)$  eine  $n$ -dim. ZV mit Verteilungsfunktion  $H : \bar{\mathbb{R}}^n \rightarrow [0, 1]$  und marginale Verteilungsfunktionen  $F_1, \dots, F_n$  so gilt, dass eine (oder mehrere) Copula  $C : \bar{\mathbb{R}}^n \rightarrow [0, 1]$  definiert ist, für die gilt:

1.  $H(z_1, \dots, z_n) = C(F_1(z_1), \dots, F_n(z_n))$ ;
2.  $C$  ist eindeutig auf  $\text{Ran}(F_1) \times \dots \times \text{Ran}(F_n) \subseteq \text{Dom}(C) = \bar{\mathbb{R}}^n$  definiert. Und falls  $F_1, \dots, F_n$  invertierbar sind, dann gilt  $C(u_1, \dots, u_n) = H(F_1^{-1}(u_1), \dots, F_n^{-1}(u_n))$  für alle  $(u_1, \dots, u_n) \in \bar{\mathbb{R}}^n$ .

**Bemerkung 3.3.21.** Es ist  $H(x_1, \dots, x_n) = \mathbb{P}(X_1 \leq x_1, \dots, X_n \leq x_n)$ .

**Bemerkung 3.3.22.** Sei  $X$  mit invertierbaren Verteilungsfunktion  $F_X$ . Sei  $\alpha : \mathbb{R} \rightarrow \mathbb{R}$  eine streng monoton steigende (und invertierbare auf  $\mathbb{R}$ ) Funktion. Dann hat  $\alpha(X)$  auch eine invertierbare Verteilungsfunktion  $F_{\alpha(X)}$ .

**Beweis.** Sei  $\alpha$  streng monoton steigend.  $F_{\alpha(X)}(x) = \mathbb{P}(\alpha(X) \leq x) = \mathbb{P}(X \leq \alpha^{-1}(x)) = F_X(\alpha^{-1}(X))$ .  $\square$

**Notation:** Sei  $(X_1, \dots, X_n)$  eine  $n$ -dim. ZV mit invertierbaren Randverteilungsfunktionen, dann bezeichnen wir dessen eindeutige Copula mit  $C_{X_1, \dots, X_n} : \bar{\mathbb{R}}^n \rightarrow \mathbb{R}$  und dessen  $n$ -dim. Verteilungsfunktion mit  $H_{X_1, \dots, X_n}$

**Bemerkung 3.3.23.** Es ist  $F_{\alpha(X)}(\alpha(x)) = F_X(x)$ , weil  $F_{\alpha(X)}(\alpha(x)) = \mathbb{P}(\alpha(X) \leq \alpha(x)) = \mathbb{P}(X \leq x) = F_X(x)$ .

**Satz 3.3.24.** Sei  $(X_1, \dots, X_n)$  eine  $n$ -dim. ZV mit invertierbaren Randverteilungsfunktionen  $F_{X_1}, \dots, F_{X_n}$ . Seien  $\alpha_1 : \mathbb{R} \rightarrow \mathbb{R}, \dots, \alpha_n : \mathbb{R} \rightarrow \mathbb{R}$  streng monoton wachsende invertierbare auf  $\mathbb{R}$  Funktionen. Dann gilt für die Copula  $C_{X_1, \dots, X_n} : \bar{\mathbb{R}}^n \rightarrow \mathbb{R}$  von  $(X_1, \dots, X_n)$  und für die Copula  $C_{\alpha_1(X_1), \dots, \alpha_n(X_n)} : \bar{\mathbb{R}}^n \rightarrow \mathbb{R}$  von  $(\alpha_1(X_1), \dots, \alpha_n(X_n))$ , dass  $C_{X_1, \dots, X_n}(u_1, \dots, u_n) = C_{\alpha_1(X_1), \dots, \alpha_n(X_n)}(u_1, \dots, u_n)$  für  $(u_1, \dots, u_n) \in \bar{\mathbb{R}}^n$ .

**Beweis.** Da die Randverteilungsfunktionen  $F_{X_1}, \dots, F_{X_n}$  von  $(X_1, \dots, X_n)$  und  $F_{\alpha_1(X_1)}, \dots, F_{\alpha_n(X_n)}$  von  $(\alpha_1(X_1), \dots, \alpha_n(X_n))$  invertierbar sind, folgt dass die Copulas  $C_{X_1, \dots, X_n}$  bzw.  $C_{\alpha_1(X_1), \dots, \alpha_n(X_n)}$  von  $(X_1, \dots, X_n)$  bzw.  $(\alpha_1(X_1), \dots, \alpha_n(X_n))$  eindeutig auf ganz  $\bar{\mathbb{R}}^n$  bestimmt sind. Demnach  $C_{X_1, \dots, X_n}(F_{X_1}(x_1), \dots, F_{X_n}(x_n)) = H_{X_1, \dots, X_n}(x_1, \dots, x_n) = \mathbb{P}(X_1 \leq x_1, \dots, X_n \leq x_n) = \mathbb{P}(\alpha_1(X_1) \leq x_1, \dots, \alpha_n(X_n) \leq x_n) = H_{\alpha_1(X_1), \dots, \alpha_n(X_n)}(\alpha_1(x_1), \dots, \alpha_n(x_n)) = C_{\alpha_1(X_1), \dots, \alpha_n(X_n)}(F_{\alpha_1(X_1)}(x_1), \dots, F_{\alpha_n(X_n)}(x_n)) = C_{\alpha_1(X_1), \dots, \alpha_n(X_n)}(F_{X_1}(x_1), \dots, F_{X_n}(x_n))$ . Da  $\text{Ran}(F_1) \times \dots \times \text{Ran}(F_n) = [0, 1] \times \dots \times [0, 1]$  folgt die Aussage.  $\square$

Wir schränken uns auf der Fall  $n = 2$  ein.

**Erinnerung:**

1. Für alle ZV  $(X, Y)$  mit 2-dim. Verteilungsfunktion  $H$  und marginale Verteilungsfunktion  $F$  und  $G$  gibt es mindestens eine Copula  $C : \bar{\mathbb{R}} \times \bar{\mathbb{R}} \rightarrow [0, 1]$  s.d.  $H(x, y) = C(F(x), G(y))$ ;



2. Auf dem  $\text{Ran}(F) \times \text{Ran}(G)$  ist  $C$  eindeutig definiert, insbesondere ist  $C$  eindeutig definiert auf  $\bar{\mathbb{R}} \times \bar{\mathbb{R}}$  falls  $F$  und  $G$  streng monoton und stetig sind (denn dann ist  $\text{Ran}(F) = \text{Ran}(G) = \bar{\mathbb{R}}$ ).
3. Seien  $F^{-1}$  bzw.  $G^{-1}$  die quasi-inverse Funktionen der marginalen Verteilungsfunktionen  $F$  bzw.  $G$ , dann gilt:  $C(u, v) = H(F^{-1}(u), G^{-1}(v))$  ist eine Copula für  $(X, Y)$ .
4. Die quasi-inverse Funktion  $F^{-1} : [0, 1] \rightarrow \bar{\mathbb{R}}$  ist die Funktion  $F^{-1}(t) = \inf\{x | F(x) \geq t\} = \sup\{x | F(x) \leq t\}$  (es gilt, weil  $F$  rechtsstetig ist).

**Notation:**  $C_{X,Y}$  ist eine Copula die zur bivariaten ZV  $(X, Y)$  gehört.

**Satz 3.3.25.** *Seien  $X$  bzw.  $Y$  ZV mit streng monotone und stetige Verteilungsfunktionen  $F$  bzw.  $G$ . Falls  $\alpha : \mathbb{R} \rightarrow \mathbb{R}$  bzw.  $\beta : \mathbb{R} \rightarrow \mathbb{R}$  stetige (oder linkstetige, oder rechtsstetige) Funktionen sind, die streng monoton wachsend auf  $\text{Ran}(X)$  bzw.  $\text{Ran}(Y)$  sind. Dann gilt  $C_{X,Y}$*

**Bemerkung 3.3.26.** *Die Menge  $\text{Ran}(X)$  bzw.  $\text{Ran}(Y)$  ist kein Kompaktum. Die ZV  $\alpha(X)$  hat eine streng monotone Verteilungsfunktion und zwar  $F_2(x) = F(\alpha^{-1}(x))$ , weil  $F_2(x) = \mathbb{P}(\alpha(X) \leq x) = \mathbb{P}(X \leq \alpha^{-1}(x)) = F(\alpha^{-1}(x))$ . Natürlich gilt auch, dass  $\beta(Y)$  eine streng monotone Verteilungsfunktion  $G_2(y) = G(\beta^{-1}(y))$  hat. Falls  $\alpha, \beta$  stetig sind, folgt  $\text{Ran}(F_2) = \text{Ran}(G_2) = \bar{\mathbb{R}}$ .*

**Beweis des Satzes.**  $C_{\alpha(X), \beta(Y)}(F_2(x), G_2(y)) = \mathbb{P}(\alpha(X) \leq x, \beta(Y) \leq y) = \mathbb{P}(X \leq \alpha^{-1}(x), Y \leq \beta^{-1}(y)) = C_{X,Y}(F(\alpha^{-1}(x)), G(\beta^{-1}(y))) = C_{X,Y}(F_2(x), G_2(y))$ .  
Folglich  $C_{X,Y}(u, v) = C_{\alpha(X), \beta(Y)}(u, v)$  für alle  $(u, v) \in \text{Ran}(F) \times \text{Ran}(G)$ .  $\square$

**Satz 3.3.27.** *Sei  $(X, Y)$  eine bivariate ZV mit marginalen Verteilungsfunktionen  $F$  und  $G$ , die streng monoton und stetig. Seien  $\alpha : \mathbb{R} \rightarrow \mathbb{R}$  bzw.  $\beta : \mathbb{R} \rightarrow \mathbb{R}$  stren monotone Funktionen auf  $\text{Ran}(X)$  bzw.  $\text{Ran}(Y)$ , die stetig (oder linkstetig, oder rechtsstetig) sind. Dann gilt für alle  $(u, v) \in \text{Ran}(F_2) \times \text{Ran}(G_2)$ , wobei  $F_2(x)$  bzw.  $G_2(x)$  die Verteilungsfunktionen von  $\alpha(X)$  bzw.  $\beta(Y)$  sind, dass:*

A. Falls  $\alpha$  streng monoton wachsend und  $\beta$  streng monoton sinkend, dann gilt

$$C_{\alpha(X),\beta(Y)}(u, v) = u - C_{X,Y}(u, 1 - v);$$

B. Falls  $\alpha$  streng monoton sinkend und  $\beta$  streng monoton steigend, dann gilt

$$C_{\alpha(X),\beta(Y)}(u, v) = v - C_{X,Y}(1 - u, v);$$

C. Falls  $\alpha, \beta$  streng monoton sinkend  $C_{\alpha(X),\beta(Y)}(u, v) = u + v - 1 + C_{X,Y}(1 - u, 1 - v)$

**Bemerkung 3.3.28.** Falls  $\beta$  streng monoton sinkend, so gilt für die Verteilungsfunktion  $G_2(y)$  von  $\beta(Y)$ , dass  $G_2(y) = 1 - G(\beta^{-1}(y))$  weil  $G_2(y) = \mathbb{P}(\beta(Y) \leq y) = \mathbb{P}(Y \geq \beta^{-1}(y)) = 1 - \mathbb{P}(Y \leq \beta^{-1}(y)) = 1 - G(\beta^{-1}(y))$ . Es folgt dann auch  $G_2^{-1}(v) = \beta(G^{-1}(v)) + 1$ .

**Beweis des Satzes.**  $C_{\alpha(X),\beta(Y)}(F_2(x), G_2(y)) = \mathbb{P}(\alpha(X) \leq x, \beta(Y) \leq x) = \mathbb{P}(\alpha(X) \leq x, Y \geq \beta^{-1}(y)) = \mathbb{P}(\alpha(X) \leq x) - \mathbb{P}(\alpha(X) \leq x, Y \leq \beta^{-1}(y)) = F_2(x) - C_{\alpha(X),Y}(F_2(x), G(\beta^{-1}(y))) = F_2(x) - C_{\alpha(X),Y}(F_2(x), 1 - G_2(y)) = F_2(x) - C_{X,Y}(F_2(x), 1 - G_2(y))$ . Folglich  $C_{\alpha(X),\beta(Y)}(u, v) = u - C_{X,Y}(u, 1 - v)$  für alle  $(u, v) \in \text{Ran}(F_2) \times \text{Ran}(G_2)$ .  $\square$

**Definition 3.3.29.** Für alle  $(u, v) \in [0, 1]^2$  nennen wir  $M(u, v) = \min(u, v)$  die **Komonotoniecopula** und  $W(u, v) = \max(u + v - 1, 0)$  die **Kontromonotoniecopula**.

**Bemerkung 3.3.30.**  $W(u, v) = \max(u + v - 1, 0) = u - \min(u, 1 - v) = u - M(u, 1 - v)$  und  $M(u, v) = u - W(u, 1 - v)$ . Dazu haben wir gesehen, ist  $X$  uniform, so  $C_{X,X}(u, v) = M(u, v)$  und  $C_{X,1-X}(u, v) = W(u, v)$ .

**Satz 3.3.31** (Frechet-Hoeffding-Ungleichung). Für alle Copulas  $C : \bar{\mathbb{R}} \rightarrow [0, 1]$  für alle  $(u, v) \in [0, 1]^n$  gilt  $W(u, v) \leq C(u, v) \leq M(u, v)$ .

**Beweis.** Siehe Nelson.  $\square$

**Korollar 3.3.32.** Sei  $H$  eine bivariate Verteilungsfunktion mit marginalen Verteilungsfunktionen  $F, G$ , dann gilt  $\max(F(x) + G(y) - 1, 0) \leq H(x, y) \leq \min(F(x), G(y))$ .

**Beweis.** Folgt aus dem Satz von Sklar. □

**Bemerkung 3.3.33.** *Streng monotone Funktionen auf  $\mathbb{R}$  sind in jedem Punkt links- oder rechts-stetig.*

**Bemerkung 3.3.34.** *Die Copula  $C_{X,Y}$  ist durch die bivariate Verteilung und Randverteilungen definiert, d.h. ist  $(X, Y) \sim (Z, \tilde{Z})$ , so ist  $C_{X,Y} = C_{Z,\tilde{Z}}$ .*

**Satz 3.3.35** (von Frechet-Hoeffding). *Sei  $(X, Y)$  eine bivariate ZV.*

(i) *Falls  $C_{X,Y} = M(u, v)$ , dann existieren zwei streng monoton wachsende Funktionen  $\alpha : \mathbb{R} \rightarrow \mathbb{R}$ ,  $\beta : \mathbb{R} \rightarrow \mathbb{R}$  und eine ZV, s.d.  $(X, Y) \sim (\alpha(Z), \beta(Z))$ ;*

(ii) *Falls  $C_{X,Y}(u, v) = W(u, v)$  dann existieren eine streng monoton wachsende Funktionen  $\alpha : \mathbb{R} \rightarrow \mathbb{R}$  und streng monoton sinkende Funktionen  $\beta : \mathbb{R} \rightarrow \mathbb{R}$  und eine ZV  $Z$ , s.d.  $(X, Y) \sim (\alpha(Z), \beta(Z))$ .*

*Umgekehrt: Falls  $(X, Y) \sim (\alpha(Z), \beta(Z))$  mit einer ZV  $Z$  und*

(a)  *$\alpha : \mathbb{R} \rightarrow \mathbb{R}$ ,  $\beta : \mathbb{R} \rightarrow \mathbb{R}$  streng monoton wachsende Funktionen, dann gilt  $C_{X,Y} = M(u, v)$ ;*

(b)  *$\alpha : \mathbb{R} \rightarrow \mathbb{R}$  streng monoton wachsend und  $\beta : \mathbb{R} \rightarrow \mathbb{R}$  streng monoton sinkend, dann gilt  $C_{X,Y}(u, v) = W(u, v)$ .*

*(Aussage des Satzes im Nelson oder Embrecht&Co ohne Beweis)*

**Beweis.**

" $\Leftarrow$ " Wir beweisen das in dieser Vorlesung nur für den Fall, wo die Verteilungsfunktion  $K : \mathbb{R} \rightarrow \mathbb{R}$  von  $Z$  streng monoton und stetig ist.

(a) Seien also  $\alpha$  und  $\beta$  streng monoton steigend. Dann  $C_{X,Y}(u, v) = C_{\alpha(X),\beta(Y)}(u, v) = C_{Z,Z}(u, v) = C_{K(Z),K(Z)}(u, v) = M(u, v)$ , weil  $K(Z)$  uniform ist.

(b) Sei also  $\alpha$  streng monoton steigend,  $\beta$  streng monoton sinkend.  $C_{X,Y}(u, v) = C_{\alpha(Z),\beta(Z)}(u, v) = u - C_{Z,Z}(u, 1-v) = u - C_{K(Z),K(Z)}(u, 1-v) = u - M(u, 1-v) = W(u, v)$ .

" $\Rightarrow$ " In dieser Vorlesung beweisen wir es für den Fall, wo die Randverteilungsfunktion  $F, G$  streng monoton und stetig sind.

(i) Sei  $C_{X,Y}(u, v) = M(u, v)$ , dann folgt  $C_{F(X),G(Y)}(u, v) = C_{X,Y}(u, v) = M(u, v)$  und da  $F(X)$  bzw.  $G(Y)$  uniform verteilt ist, folgt es  $(F(X), G(Y)) \sim (Z, Z)$ , wobei  $Z$  uniform ist, weil die Verteilungsfunktion  $H$  von  $(F(X), G(Y))$  mit  $M$  übereinstimmt. Folglich  $(X, Y) \sim (F^{-1}(Z), G^{-1}(Z))$  da  $F^{-1}, G^{-1}$  streng monoton, also folgt die Aussage.

(ii) Sei  $C_{X,Y}(u, v) = W(u, v)$ , dann  $C_{F(X),G(Y)}(u, v) = W(u, v)$ . Da  $F(X)$  bzw.  $G(Y)$  uniform verteilt ist folgt mit dem Satz von Sklar  $(X, Y) \sim (F^{-1}(Z), G^{-1}(1 - Z))$ . Die  $F^{-1}$  ist streng monoton steigend,  $F^{-1}(1 - Id)$  streng monoton sinkend, also folgt die Aussage.  $\square$

**Satz 3.3.36.** *Sei  $(X, Y)$  eine bivariate ZV mit streng monotonen und stetigen Randverteilungsfunktionen  $F$  und  $G$ .*

I.  $C_{X,Y}(u, v) = M(u, v) \Leftrightarrow Y = G^{-1}(F(X))$   $\mathbb{P}$ -f.s.

II.  $C_{X,Y}(u, v) = W(u, v) \Leftrightarrow Y = G^{-1}(1 - F(X))$   $\mathbb{P}$ -f.s.

**Bemerkung 3.3.37.** *Falls  $Y = G^{-1}(F(X))$   $\mathbb{P}$ -f.s. mit  $F, G$  streng monotone und stetige Verteilungsfunktionen, so folgt, dass  $Y$  die  $G$  als Verteilungsfunktion hat, denn  $\mathbb{P}(Y \leq y) = \mathbb{P}(G^{-1}(F(X)) \leq y) = \mathbb{P}(X \leq F^{-1}(G(y))) = F(F^{-1}(G(y))) = G(y)$ .*

**Beweis des Satzes.**

I. " $\Rightarrow$ " Wir haben gesehen  $(F(X), G(Y)) \sim (Z, Z)$ , wobei  $Z$  uniform verteilt ist. Wir zeigen  $F(X) = G(Y)$   $\mathbb{P}$ -f.s. und folglich  $Y = G^{-1}(F(X))$   $\mathbb{P}$ -f.s. Es ist  $\mathbb{P}(F(X) = G(Y)) = \mathbb{P}(\cup_n \cap_{k \geq n} |F(X) - G(Y)| \leq \frac{1}{k}) = \mathbb{P}(\liminf_n |F(X) - G(Y)| \leq \frac{1}{n}) = 1 - \mathbb{P}(\limsup_n |F(X) - G(Y)| > \frac{1}{n})$ . Weiter ist  $\mathbb{P}(\limsup_n |F(X) - G(Y)| > \frac{1}{n}) \leq \lim_{n \rightarrow \infty} \mathbb{P}(|F(X) - G(Y)| > \frac{1}{n}) = \lim_{n \rightarrow \infty} \mathbb{P}(|Z - Z| > \frac{1}{n}) = 0$ .

" $\Leftarrow$ " Sei  $Y = G^{-1}(F(X))$   $\mathbb{P}$ -f.s. mit  $F, G$  streng monotone stetige Verteilungsfunktionen, wobei  $F$  die Verteilungsfunktion von  $X$ . Also  $G$  ist die Verteilungsfunktion von  $Y$ . Und  $C_{X,Y}(u, v) = C_{X, F^{-1}(G(X))}(u, v) = C_{F(X), G(Y)}(u, v) = M(u, v)$ .

II. " $\Rightarrow$ " Sei  $C_{X,Y}(u, v) = W(u, v)$ . Folglich  $C_{F(X), 1-G(Y)}(u, v) = u - C_{X,Y}(u, 1-v) = u - W(u, 1-v) = M(u, v)$ . Es ist  $F(X) \sim U_{[0,1]} \sim Z, 1 - G(Y) \sim 1 - Z \sim Z$  und  $C_{F(X), 1-G(Y)}(u, v) = M(u, v)$ . Nun  $(F(X), 1 - G(Y)) \sim (Z, Z)$  mit  $Z \sim U_{[0,1]}$ . Also  $F(X) = 1 - G(Y)$   $\mathbb{P}$ -f.s. und es folgt die Behauptung.

" $\Leftarrow$ " Sei  $Y = G^{-1}(1 - F(X))$   $\mathbb{P}$ -f.s., dann  $C_{X,Y}(u, v) = C_{X, G^{-1}(1-F(X))}(u, v) = C_{G(X), 1-F(X)}(u, v) = C_{X, 1-F(X)}(u, v) = u - C_{X,X}(u, 1-v) = u - M(u, 1-v) = W(u, v)$ .  $\square$

Copula sind nützlich um **systematischen Risiko** zu untersuchen, d.h. gegeben z.B. zwei Verluste  $V, L$ , wobei  $L$  und  $V$  meistens nicht stochastisch unabhängig sind. Wie groß ist die Wahrscheinlichkeit, dass  $L$  ein Schwellenrisiko  $l$  überschreitet, falls  $V$  den Schwellenrisiko  $v$  überschreitet, wir sind interessiert an  $\mathbb{P}(L > l | V > v)$ . Seien  $F_V$  und  $F_L$  die Randverteilungen von  $(V, L)$ . Wir fixieren:

$$\mathbb{P}(L \leq l | V \leq v) = \frac{\mathbb{P}(L \leq l, V \leq v)}{\mathbb{P}(V \leq v)} \stackrel{1}{=} \frac{C_{L,V}(F_L(l), F_V(v))}{F_V(v)};$$

$$\mathbb{P}(L \leq l | V > v) = \frac{\mathbb{P}(L \leq l) - \mathbb{P}(L \leq l, V \leq v)}{\mathbb{P}(V > v)} \stackrel{2}{=} \frac{F_L(l) - C_{L,V}(F_L(l), F_V(v))}{1 - F_V(v)};$$

$$\begin{aligned} \mathbb{P}(L > l | V > v) &= \frac{\mathbb{P}(L > l, V > v)}{\mathbb{P}(V > v)} = \frac{\mathbb{P}(L > l) - \mathbb{P}(L > l, V \leq v)}{1 - F_V(v)} \\ &= \frac{\mathbb{P}(L > l) - (\mathbb{P}(V \leq v) - \mathbb{P}(L \leq l, V \leq v))}{1 - F_V(v)} \\ &\stackrel{3}{=} \frac{1 - F_L(l) - F_V(v) + C_{L,V}(F_L(l), F_V(v))}{1 - F_V(v)}. \end{aligned}$$

Wir sind insbesondere an der Schwellenwerte  $VaR_\alpha(L), VaR_\beta(V)$  interes-

siert.

**Annahme:** Seien  $F_L, F_V$  streng monoton und stetig.

**Bemerkung 3.3.38.** Es gilt folgendes  $\mathbb{P}(L \leq VaR_\alpha(L)|V \leq VaR_\beta(V)) = \frac{C_{L,V}(F_L(F_L^{-1}(\alpha)), F_V(F_V^{-1}(\beta)))}{F_V(F_V^{-1}(\beta))} = \frac{C_{L,V}(\alpha, \beta)}{\beta}$ . Folglich

$$\mathbb{P}(L \leq VaR_\alpha(L)|V \leq VaR_\beta(V)) \stackrel{!}{=} \frac{C_{L,V}(\alpha, \beta)}{\beta} \stackrel{\alpha=\beta}{=} \frac{C_{L,V}(\alpha, \alpha)}{\alpha}$$

und

$$\begin{aligned} \mathbb{P}(L > VaR_\alpha(L)|V > VaR_\beta(V)) &\stackrel{3}{=} \frac{1 - \alpha - \beta + C_{L,V}(\alpha, \beta)}{1 - \beta} \\ &\stackrel{\alpha=\beta}{=} \frac{1 - 2\alpha + C_{L,V}(\alpha, \alpha)}{1 - \alpha}. \end{aligned}$$

**Definition 3.3.39.** Sei  $C_{L,V}(u, v)$  die Copula von  $(L, V)$ .

- Der *untere Teilabhängigkeitskoeffizient*  $\lambda_{\mathcal{L}}(L, V) = \lim_{\alpha \searrow 0} \frac{C_{L,V}(\alpha, \alpha)}{\alpha}$ ;
- Der *obere Teilabhängigkeitskoeffizient*  $\lambda_{\mathcal{U}}(L, V) = \lim_{\alpha \nearrow 1} \frac{1 - 2\alpha + C_{L,V}(\alpha, \alpha)}{1 - \alpha}$ .

**Bemerkung 3.3.40.** Falls  $F_L$  und  $F_V$  streng monoton und stetig sind, so gilt:

- $\lambda_{\mathcal{L}}(L, V) = \lim_{\alpha \searrow 0} \mathbb{P}(L > VaR_\alpha(L)|V > VaR_\alpha(V))$ ;
- $\lambda_{\mathcal{U}}(L, V) = \lim_{\alpha \nearrow 1} \mathbb{P}(L > VaR_\alpha(L)|V > VaR_\alpha(V))$ .

**Bemerkung 3.3.41.** Falls  $C_{L,V}(u, v) = uv$ , d.h.  $C_{L,V}$  ist die **Unabhängigkeitscopula** ( $L$  und  $V$  sind stochastisch unabhängig), so ist:

- $\lambda_{\mathcal{L}}(L, V) = \lim_{\alpha \searrow 0} \frac{\alpha^2}{\alpha} = 0$ ;
- $\lambda_{\mathcal{U}}(L, V) = \lim_{\alpha \nearrow 1} \frac{1 - 2\alpha + \alpha^2}{1 - \alpha} = 0$ .

**Definition 3.3.42.** Falls  $\lambda_{\mathcal{L}}(L, V) = 0 = \lambda_{\mathcal{U}}(L, V)$ , so sagt man, dass  $(L, V)$  **asymptotisch unabhängig** sind.

**Bemerkung 3.3.43.** Falls  $(L, V)$  asymptotisch unabhängig sind, so beeinflusst die eventuell Fat Tails der Marginale  $V$  nicht die Extremwerte in den Fat Tails der Marginale  $L$ .

## 4 Ruintheorie

### 4.1 Zahlprozesse und Poisson-Prozesse

Sei  $\mathbb{N}_0 := \mathbb{N} \cup \{0\}$  und  $n \in \mathbb{N}_0$ . Die Borel'sche  $\sigma$ -Algebra  $\mathcal{B}(\mathbb{R}^n)$  von  $\mathbb{R}^n$  ist die kleinste  $\sigma$ -Algebra von  $\mathbb{R}^n$ , die alle  $B_1 \times \dots \times B_n$  enthält, wobei  $B_1, \dots, B_n \in \mathbb{R}$  Borelmengen von  $\mathbb{R}$  sind. Sei  $T$  ein Intervall von  $\mathbb{R}_{\geq 0}$ . Dann bezeichnet  $\mathbb{R}^T$  den Raum von Funktionen  $X : T \rightarrow \mathbb{R}$ , mit  $t \mapsto X_t$ . Seien  $t_1 < \dots < t_n \in T$  und  $B^n \in \mathcal{B}(\mathbb{R}^n)$ . Dann ist  $\mathcal{C}_{t_1, \dots, t_n}(B^n) := \{x \in \mathbb{R}^T \mid (x_{t_1}, \dots, x_{t_n}) \in B^n\}$  ein Zylinder in  $\mathbb{R}^T$  mit Basis in  $\mathbb{R}^n$ . Die kleinste  $\sigma$ -Algebra, die alle solche Zylinder enthält, ist die Zylindrische- $\sigma$ -Algebra von  $\mathbb{R}^T$  und wird mit  $\mathcal{B}(\mathbb{R}^T)$  bezeichnet.

**Definition 4.1.1.** Ein  $\mathbb{R}$ -wertiger *stochastischer Prozess* mit stetigem Zeitraum  $T$  ist eine messbare Abbildung  $X_t : (\Omega, \mathcal{F}) \rightarrow (\mathbb{R}^T, \mathcal{B}(\mathbb{R}^T))$ .

**Notation:**  $(X_t)_{t \in T}, (X_t)_{t \geq 0}$ .

**Bemerkung 4.1.2.** Sei  $t \in T$  fest. Dann ist  $X_t : (\Omega, \mathcal{F}) \rightarrow \mathbb{R}$  mit  $\omega \mapsto X_t(\omega)$ ,  $\omega \in \Omega$ , so erhalten wir die Funktion  $t \mapsto X_t(\omega)$  für  $t \in T$ , welche wir der **Pfad** von  $X_t$  nennen.

**Definition 4.1.3.** Die Verteilung von  $(X_t)_{t \in T}$  ist für alle  $B \in \mathcal{B}(\mathbb{R}^T)$  gegeben durch  $\mathbb{P}_{X_t}(B) := \mathbb{P}(X_t \in B)$ .

**Definition 4.1.4.** Die stochastische Prozesse  $X_t^{(1)}, \dots, X_t^{(n)}$  über  $(\Omega, \mathcal{F}, \mathbb{P})$  heißen **unabhängig**, falls für alle  $B_1, \dots, B_n \in \mathcal{B}(\mathbb{R}^T)$  gilt

$$\mathbb{P}(X_t^{(1)} \in B_1, \dots, X_t^{(n)} \in B_n) = \mathbb{P}(X_t^{(1)} \in B_1) \cdots \mathbb{P}(X_t^{(n)} \in B_n).$$

**Definition 4.1.5.** Die **endlich-dimensionale Verteilung [fdd]** eines stoch. Prozesses  $(X_t)_{t \in T}$  ist gegeben durch  $\mathbb{P}_{t_1, \dots, t_n}(B^{(n)}) = \mathbb{P}(X_{t_1}, \dots, X_{t_n} \in B^{(n)})$  für alle  $t_1 < t_2 < \dots < t_n \in T$ ,  $B^{(n)} \in \mathcal{B}(\mathbb{R}^T)$ ,  $n \in \mathbb{N}_0$ . Ein stoch. Prozess kann durch die Klasse seiner fdd vollständig bestimmt werden.

**Satz 4.1.6** (Kolmogorov/Existenz). Für jede Klasse von fdd  $\{\mathbb{P}_{t_1, \dots, t_n}\}_{t_1 < \dots < t_n \in T}$ ,  $n \in \mathbb{N}_0$  existiert ein W-Raum  $(\Omega, \mathcal{F}, \mathbb{P})$  und ein stoch. Prozess  $X = (X_t)_{t \in T}$  der über  $(\Omega, \mathcal{F}, \mathbb{P})$  definiert ist, s.d.  $\mathbb{P}(X_{t_1}, \dots, X_{t_n} \in B^{(n)}) = \mathbb{P}_{t_1, \dots, t_n}(B^{(n)})$  für alle  $t_1 < \dots < t_n \in T$ ,  $B^{(n)} \in \mathcal{B}(\mathbb{R}^T)$ ,  $n \in \mathbb{N}_0$ . (ohne Beweis)

**Definition 4.1.7.** Ein stoch. Prozess  $X$  hat **stationäre Zuwächse** falls die Verteilung von  $X_t - X_s = \Delta_{s,t}$  von  $s$  und  $t$  nur durch  $t - s$  abhängig ist für alle  $s < t \in T$ , also  $X_t - X_s = X_{t-s}$ .

**Definition 4.1.8.** Ein stoch. Prozess  $X$  hat **unabhängige Zuwächse**, falls für alle  $s_1 < t_1 < s_2 < t_2 < \dots < s_k < t_k \in T$ ,  $k \in \mathbb{N}_0$ , gilt, dass  $X_{t_1} - X_{s_1}, \dots, X_{t_k} - X_{s_k}$  unabhängig sind.

**Definition 4.1.9.** Ein **Zählprozess** mit Zeitraum  $T = \mathbb{R}^+$  ist ein  $\mathbb{N}$ -wertiger Prozess  $(N_t)_{t \geq 0}$  mit der Eigenschaft  $N_s \leq N_t$  fast sicher,  $0 \leq s \leq t < \infty$ .

Wenn nun  $X$  eine Poisson-verteilte ZV mit Parameter  $\lambda \geq 0$  ist, dann ist für  $n \in \mathbb{N}$  die W-keitsverteilung gegeben durch  $\mathbb{P}(X = n) = \exp(-\lambda) \frac{\lambda^n}{n!}$  und es ist  $\mathbb{E}[X] = \lambda$ .

**Definition 4.1.10.** Sei  $(\mathcal{F}_t)_{t \geq 0}$  eine Familie von  $\sigma$ -Algebren von Teilmengen aus  $\Omega$ . Ein stoch. Prozess  $X_{t \geq 0}$  heißt  $\mathcal{F}_t$ -**adaptiert**, falls für jedes  $t \geq 0$  auch die Funktion  $\omega \rightarrow X_t(\omega)$   $\mathcal{F}_t$ -messbar ist.

**Definition 4.1.11.** Ein càdlàg (continue à droite, limite à gauche, rechtsseitig stetig, mit Grenzwerten von links) und adaptierter Zahlprozess  $N_{t \geq 0} : \Omega \times \mathbb{R}^+ \rightarrow \mathbb{N}_0$  heißt **Poisson-Prozess [PP]**, falls

- 1)  $N_0 = 0$ ;
- 2)  $N_{t \geq 0}$  hat unabhängige Zuwächse;
- 3)  $N_{t \geq 0}$  hat Poisson-verteilte Zuwächse mit Parametern  $\lambda(t-s)$ ,  $0 \leq s \leq t < \infty$ .

Wir nennen  $\lambda > 0$  die Intensität des Poisson-Prozesses.



**Definition 4.1.12.** Sei  $N_{t \geq 0}$  ein Poisson-Prozess und  $X_1, \dots$  eine Folge von i.i.d ZVen, unabhängig von  $N_{t \geq 0}$  mit gemeinsamer Verteilung  $\mathbb{P}_{X_1} = \mathbb{P}_{X_n}$  für alle  $n \in \mathbb{N}$ . Dann heißt der zusammengesetzter Prozess  $Z_t = \sum_{k=0}^N X_k$ ,  $Z_0 = 0$ ,  $t \geq 0$  der **zusammengesetzter Poisson-Prozess [CPP]**. Wir schreiben  $\Delta Z_{s,t} = Z_t - Z_s = \sum_{k=N_{s+1}}^{N_t} X_k$ .

Wie Zählprozess ist ein CPP  $Z_{t \geq 0}$  auch ein Sprung-Prozess. Jedoch die Sprünge nicht mehr einheitlich, sondern zufällig und genau durch  $X_1, \dots, X_n, \dots$  gegeben. Für  $n \in \mathbb{N}$  sind Ereigniszeiten des PP  $N_{t \geq 0}$  gegeben durch  $T_n = \inf\{n \geq 0 \mid N_t > n\}$ ,  $T_0 = 0$ . Umgekehrt erhalten wir aus  $(T_n)_{n \in \mathbb{N}}$  auch wieder den Zählprozess  $N_{t \geq 0}$  mit  $N_t = \max\{n \geq 0 \mid T_n \leq t\}$ ,  $t \geq 0$ .

**Satz 4.1.13.** Sei  $N_{t \geq 0}$  ein PP mit Intensität  $\lambda > 0$  und Ereigniszeiten  $T_1, T_2, \dots$ . Dann sind  $\Delta T_n = T_n - T_{n-1}$ ,  $n \in \mathbb{N}$  unabhängig und exponential- $\lambda$ -verteilte ZVen.

**Beweis.** Seien  $t, t_1 > 0$ . Dann gilt  $\mathbb{P}(\Delta T_1 > t) = \mathbb{P}(N_t = 0) = \exp(-\lambda t)$  und weiter  $\mathbb{P}(\Delta T_2 > t \mid \Delta T_1 > t_1) = \mathbb{P}(N_{t_1+t} - N_{t_1} = 0 \mid N_{t_1} = 1) = \mathbb{P}(N_{t_1+t} - N_{t_1} = 0) = \mathbb{P}(N_{t_1, t_1+t} = 0) = \mathbb{P}(N_t = 0) = \exp(-\lambda t)$ , weshalb  $\Delta T_2$  unabhängig ist von  $\Delta T_1$  und gleichverteilt ist. Allgemein gilt für ein  $n \geq 1$  und  $t, t_1, \dots, t_n > 0$ , dass  $\mathbb{P}(\Delta T_{n+1} > t \mid \Delta T_1 > t_1 \dots \Delta T_n > t_n) = \mathbb{P}(N_{t_n+t} - N_{t_n} = 0 \mid N_{t_n} = n) = \mathbb{P}(N_t = 0) = \exp(-\lambda t)$ .  $\square$

**Satz 4.1.14.** Sei  $(\Delta T_n)_{n \in \mathbb{N}_0}$  eine Folge unabhängigen exp- $\lambda$ -verteilte ZV und  $N_{t \geq 0} = \max\{n \geq 0 \mid T_n \leq t\}$ . Dann ist  $(N_t)_{t \geq 0}$  ein PP mit Intensität  $\lambda > 0$ .

**Beweis.** Sei  $t \geq 0$  und  $n \in \mathbb{N}_0$ . Es gilt  $\mathbb{P}(N_t = 0) = \mathbb{P}(T_1 > t) = \exp(-\lambda t)$  und  $\mathbb{P}(N_t = n) = \mathbb{P}(T_n \leq t, T_{n+1} > t)$  und  $T_{n+} = T_n + \Delta T_{n+1}$ . Die gemeinsame Dichte von  $(T_n, \Delta T_{n+1})$  ist wegen Unabhängigkeit gegeben durch  $h(y, u) = \frac{\lambda^n}{r(n)} \exp(-\lambda y) y^{n-1} \lambda \exp(-\lambda u)$  mit  $u, y > 0$ . Sei  $A_t = \{(y, u) \in \mathbb{R}_+^2 \mid 0 < y < t, t - y < u < \infty\}$ . Dann gilt  $\mathbb{P}(N_t = n) = \int_{A_t} h(y, u) dy du = \exp(-\lambda t) \frac{(\lambda t)^n}{n!}$ , weshalb  $N_t \sim \text{Pois}(\lambda, t)$ .  $\square$

**Definition 4.1.15.** Seien  $D_1, D_2, \dots$  nichtnegative iid ZVen,  $T_n = \sum_i D_i$ ,  $D_0 = 0$  und  $N_{t \geq 0} = \max\{n \geq 0 \mid T_n \geq t\}$ . Dann heißen die drei unabhängige stoch. Prozesse  $(T_n)_{n \geq 1}$ ,  $(D_n)_{n \geq 1}$ ,  $(N_t)_{t \geq 0}$  **Erneuerungsprozesse**.

## 4.2 Risikoprozess

### 4.2.1 Komponenten des Risikoprozesses

**Definition 4.2.1** (Cramer-Lundberg). Sei  $X_1, X_2, \dots$  eine Folge iid ZVen mit  $X_i \in \mathcal{L}^1(\Omega)$ . Sei  $(N_t)_{t \geq 0}$  PP mit Intensität  $\lambda > 0$ . Dann definieren wir einen zusammengesetzter Prozess durch  $Z_t = \sum_{i=0}^{N_t} X_i$ ,  $t \geq 0$ ,  $X_0 = 0$ . Seien  $c > 0$ ,  $r_0 \geq 0$  Konstanten. Dann definieren wir den **Risikoprozess** durch  $Y_t = r_0 + ct - Z_t$ ,  $t \geq 0$ .

Interpretation im Kontext einer Versicherung

- $X_1, X_2, \dots$  individuelle Schadensbeiträge;
- $N_t$  Anzahl der Schäden, die im Zeitintervall  $[0, t]$  eintreten;
- $Z_t$  stochastische Komponente, d.h. Summanden entsprechen den einzelnen Schadensbeiträge;
- $c$  Prämienintensität/Prämiensatz;
- $r_0$  Anfangskapital.

### 4.2.2 Ruinwahrscheinlichkeit

**Definition 4.2.2.** Die **Ruinwahrscheinlichkeit im unendlichen Zeithorizont** des Risikoprozesses  $(Y_t)_{t \geq 0}$  ist gegeben durch  $\psi(r_0) = \mathbb{P}(\inf_{t \geq 0} Y_t < 0)$ . Sein Komplement nennen wir die **Überlebenswahrscheinlichkeit im unendlichen Zeithorizont**, diese ist gegeben durch  $R(r_0) = 1 - \psi(r_0)$ .

**Bemerkung 4.2.3.** Die Ruinwahrscheinlichkeit ist die W-keit, dass der Risikoprozess jemals unter Null fallen wird. Dieses Ereignis nennen wir den **Ruin**.

**Definition 4.2.4.** Die **Ruinwahrscheinlichkeit im endlichen Zeithorizont**  $[0, t^+]$ ,  $t^+ > 0$  ist gegeben durch  $\psi(r_0, t^+) = \mathbb{P}(\inf_{0 \leq t \leq t^+} Y_t < 0)$ . Sein Komplement nennen wir die **Überlebenswahrscheinlichkeit im endlichen Zeithorizont**,  $[0, t^+]$ ,  $t^+ > 0$ , diese ist gegeben durch  $R(r_0, t^+) = 1 - \psi(r_0, t^+)$ .

**Bemerkung 4.2.5.** Die so definierte Ruinwahrscheinlichkeit ist die W-keit, dass der Risikoprozess  $(Y_t)_{t \geq 0}$  vor Zeitpunkt  $t^+$  unter Null fallen wird. Der **Ruinzeitpunkt**  $T$  lässt sich dann wie folgt definieren:

$$T = \begin{cases} \inf\{t \geq 0 \mid Y_t \leq 0\} & \text{falls existiert,} \\ -\infty & \text{sonst.} \end{cases}$$

Dann gilt für  $(Y_t)_{t \geq 0}$ , dass  $\psi(r_0, t^+) = \mathbb{P}(T < t^+)$ ,  $t^+ \in (0, \infty)$  und  $\psi(r_0) = \lim_{t^+ \rightarrow \infty} \psi(r_0, t^+)$ .

**Definition 4.2.6.** Der **angehäufte Verlustprozess**  $(L_t)_{t \geq 0}$  ist definiert durch  $L_t = Z_t - ct = r_0 - Y_t$ ,  $t \geq 0$ . Wir nennen das Supremum von  $(L_t)_{t \geq 0}$  im endlichen Zeithorizont  $[0, t^+]$  den **maximal angehäuftten Verlust** zum endlichen Zeithorizont  $t^+$ . Dieser ist gegeben durch  $S_{t^+} = \sup_{0 \leq t \leq t^+} \{L_t\}$ ,  $t^+ \in (0, \infty)$  (im unendlichen Zeitraum  $S_t = \sup_{t \geq 0} \{L_t\}$ ).

**Satz 4.2.7.** Die Überlebenswahrscheinlichkeit im endl. bzw. unendl. Zeithorizont ist gleich der Verteilungsfunktion von  $S_{t^+}$  bzw.  $S_t$ .

**Beweis.** Es ist zu zeigen, dass

- 1)  $R(r_0, t^+) = \mathbb{P}(S_{t^+} \leq r_0)$ , wobei  $r_0 \geq 0$ ,  $t^+ \in \infty$ , mit speziellem Wert  $R(0, t^+) = \mathbb{P}(S_{t^+} = 0)$ ;
- 2)  $R(r_0) = \mathbb{P}(S_t \leq r_0)$ ,  $r_0 \geq 0$ , mit speziellem Wert  $R(0) = \mathbb{P}(S_t = 0)$ ,  $t > 0$ .

Dazu seien  $r_0 > 0$  und  $t^+ \in (0, \infty)$ . Es gilt  $R(r_0, t^+) = 1 - \psi(r_0, t^+) = \mathbb{P}(\forall t \in$

$[0, t^+]$   $Y_t \geq 0$ ) =  $\mathbb{P}(\forall t \in [0, t^+] \ Z_t - ct < r_0) = \mathbb{P}(S_{t^+} \leq r_0)$ . Weiter gilt,  $Z_t - ct \upharpoonright_{t=0} = 0$ , also  $S_{t^+} \geq 0$ . Damit folgt  $R(0, t^+) = \mathbb{P}(S_{t^+} \leq 0) = \mathbb{P}(S_{t^+} = 0)$ . D.h.,  $S_{t^+}$  besitzt  $R(0, t^+) > 1$  eine positive W-keit an der Stelle 0, also gilt 1). Analog zeigt man 2).  $\square$

**Definition 4.2.8.** Wir betrachten den Risikoprozess  $(Y_t)_{t \geq 0}$  und seine Ruinwahrscheinlichkeit  $\psi(r_0) = \mathbb{P}(T < \infty)$ . Die **Value-at-Ruin** zum Niveau  $\alpha \in (0, 1)$  ist definiert durch  $VaRu(\alpha) = \inf\{x \geq 0 \mid \psi(x) \leq \alpha\}$ . Beim endl. Zeithorizont:  $VaRu(\alpha, t^+) = \inf\{x \geq 0 \mid \psi(x, t^+) \leq \alpha\}$ .

**Bemerkung 4.2.9.**  $VaRu$  ist nicht subadditiv, also nicht kohärent.

**Lemma 4.2.10.** O.B.d.A können wir stets  $c = 1$  in  $(Y_t)_{t \geq 0}$  annehmen.

**Beweis.** Sei  $\tilde{Y}_t = Y_{\frac{t}{c}} = r_0 + t + Z_{\frac{t}{c}}$ ,  $t \geq 0$ . Dann gelten  $\mathbb{P}(\inf_{t \geq 0} \tilde{Y}_t < 0) = \mathbb{P}(\inf_{t \geq 0} Y_t < 0) = \psi(r_0)$  und  $\mathbb{P}(\inf_{0 \leq t \leq t^+} \tilde{Y}_t < 0) = \mathbb{P}(\inf_{0 \leq t \leq \frac{t^+}{c}} Y_t < 0) = \psi(r_0, \frac{t^+}{c})$ .  $\square$

**Bemerkung 4.2.11.** Wenn  $(Y_t)_{t \geq 0}$  ein CPP ist mit Parameter  $\lambda$ , dann ist  $(\tilde{Y}_t)_{t \geq 0}$  wieder ein CPP aber mit Parameter  $\frac{\lambda}{c}$ . Analog tauscht sich stets der Zeithorizont  $\frac{t^+}{c}$  statt  $t^+$  aus.

**Satz 4.2.12 (Beweis).** Betrachte  $(Y_t)_{t \geq 0}$ , wobei jetzt  $(N_t)_{t \geq 0}$  ein Erneuerungsprozess ist, d.h.  $N_t = \max\{n \geq 0 \mid T_n \geq t\}$  und  $c = 1$ . Seien  $\rho = \frac{\mathbb{E}[X_1]}{\mathbb{E}[\Delta T_1]}$  und  $\beta = \frac{c-\rho}{\rho}$ , wobei  $\mathbb{E}[X_1] < \infty$ . Dann tritt Ruin fast sicher, falls  $\beta < 0$ .

**Beweis.** Definiere  $V_i = \Delta T_i - X_i$ ,  $i = 1, 2, 3, \dots$  und  $C_n = r_0 + T_n - \sum_{i=1}^n X_i = r_0 + \sum_{i=1}^n V_i$ ,  $i = 1, 2, 3, \dots$ . Das sogenannte **Skelet** (d.h. der Zeit-diskrete) des Prozesses  $(Y_t)_{t \geq 0}$  ist dann gegeben durch  $C_n = Y_{T_n}$ ,  $n \in \mathbb{N}$ . Nun sei  $\beta < 0$ .  
 $\implies \mathbb{E}[V_1] < 0 \implies \sum V_i \rightarrow -\infty$  f.s.  $\implies C_n \rightarrow -\infty$  f.s.  
 $\implies Y_{T_n} \rightarrow -\infty$  f.s.  $\implies \inf_{n \geq 1} Y_{T_n} < 0 \implies$  Ruin tritt ein.  $\square$

**Lemma 4.2.13 (Diskretisierungslemma).** Betrachte den Verlustprozess  $L_t = Z_t - ct = r_0 - Y_t$ ,  $t \geq 0$ , mit  $c = 1$ , d.h.  $L_t = Z_t - t$ ,  $t \geq 0$ . Dann gilt für alle  $n \in \mathbb{N}_+$ ,  $n > 0$ , und  $t \in [nh, (n+1)h]$ , dass  $L_{nh} - h \leq L_t \leq L_{(n+1)h} + h$ .

**Beweis.** Seien  $r, s \geq 0$ .  $L_{r+s} - L_r$  minimal in  $[r, r+s]$ , wenn alle  $X_i = 0$ ,  $i = 1, 2, 3, \dots$ , in dem Intervall und das Minimum ist dann  $-s$ . Also ist  $L_{r+s} \geq L_r - s$ . Jetzt gilt für  $t = nh + s$  und  $s \in [0, h]$ ,  $L_t \geq L_{nh} - s \geq L_{nh} - h$ . Analog zeigt man die Beschränktheit von oben.  $\square$

**Satz 4.2.14.** Seien  $\rho$  und  $\beta$  wie oben. Sei  $(L_t)_{t \geq 0} = (Z_t - t)_{t \geq 0}$  mit unabhängigen stationären Zuwächsen. Dann gelten folgende Aussagen:

- 1)  $\forall \beta \in \mathbb{R} \quad \frac{L_t}{t} \rightarrow \rho - 1 \quad f.s.$ ;
- 2) Falls  $\beta < 0$ , so ist  $L_t \rightarrow \infty \quad f.s.$ ;
- 3) Falls  $\beta > 0$ , so ist  $L_t \rightarrow -\infty \quad f.s.$ ;
- 4) Falls  $\beta > 0$ , so ist  $\liminf_{t \rightarrow \infty} L_t = -\infty$  und  $\limsup_{t \rightarrow \infty} L_t = \infty \quad f.s.$ ;

**Beweis.**

- 1) Sei  $h > 0$ . Dann ist  $(L_{nh})_{n \geq 0}$  eine Irrfahrt, d.h. ein stoch. Prozess in diskreter Zeit, wobei die Zuwächse jeder Zeiteinheit iid sind. Folglich  $\frac{L_{nh}}{n} \rightarrow (\rho - 1)h$  f.s., wenn  $n \rightarrow \infty$ , wobei  $L_h, L_{2h} - L_h, \dots$  iid sind. Somit gilt  $\liminf_{t \rightarrow \infty} \frac{L_t}{t} = \lim_{n \rightarrow \infty} \inf_{t \geq nh} \frac{L_t}{t} = \lim_{n \rightarrow \infty} \inf_{k \geq n} \inf_{kh \leq t \leq (k+1)h} \frac{L_t}{t} = \lim_{n \rightarrow \infty} \inf_{nh \leq t \leq (n+1)h} \frac{L_t}{t} \geq \liminf_{n \rightarrow \infty} \frac{L_{nh} - h}{(n+1)h} = \frac{1}{h} \liminf_{n \rightarrow \infty} \frac{L_{nh}}{n} = \rho - 1$  fast sicher. Analog zeigt man, dass  $\limsup_{t \rightarrow \infty} \frac{L_t}{t} \leq \rho - 1$ ;

2)&3) Klar, wegen 1);

4) Folgt als Resultat der Irrfahrt (siehe z.B. Durrett, Th.4.1.2).  $\square$

**Korollar 4.2.15.** Seien  $\rho$  und  $\beta$  wie oben und  $c = 1$ . Sei der Verlustprozess  $L_t = Z_t - t$  mit unabhängigen stationären Zuwächsen. Sei  $r_0 \geq 0$ . Dann gilt:

$$\psi(r_0) = \begin{cases} 1 & \text{falls } \beta \leq 0; \\ -1 & \text{sonst.} \end{cases}$$

**Beweis.** Der maximal angehäuften Verlust ist durch  $S_t = \sup_{t \geq 0} L_t$  gegeben. Falls  $\beta < 0$ , ist  $S_t = \infty$  fast sicher. Also  $\psi(r_0) = \mathbb{P}(S_t > r_0) = 1$ . Falls  $\beta = 0$ , so ist  $S_t \geq \limsup_{t \rightarrow \infty} L_t = \infty$  fast sicher, also wieder  $\psi(r_0) = 1$ . Falls  $\beta > 0$ , genügt es zu zeigen, dass aus  $\psi(r_0) < \psi(0)$  folgt, dass  $\psi(0) = \mathbb{P}(S_t > 0) < 1$  gilt. Angenommen es gilt  $\psi(r_0) < \psi(0)$ , aber es folgt  $\psi(0) = \mathbb{P}(S_t > 0) = 1$ . Dann gilt, dass  $(L_t)_{t \geq 0}$  die Nulllinie von unten nach oben fast sicher durchkreuzt. Sei jetzt  $T_1$  die erste Zeit, in der die Nulllinie von unten gekreuzt wird. Aus dem Satz folgt dann, dass  $(L_t)_{t \geq 0}$  die Nulllinie von oben nach unten fast sicher kreuzt. Dann folgt aus  $\mathbb{P}(S_t > 0) = 1$ , dass  $(L_t)_{t \geq 0}$  die Nulllinie von unten nach oben fast sicher durchkreuzt. Dieses Schema wiederholt man und stellt fest, dass  $(L_t)_{t \geq 0}$  die Nulllinie unendlich oft kreuzen wird. Widerspruch zu  $L_t \rightarrow -\infty$  f.s.  $\square$

**Satz 4.2.16.** Sei  $L_t = Z_t - t$ ,  $t \geq 0$ , wobei der PP Intensität  $\lambda > 0$  hat und  $\mu_2 = \mathbb{E}[X_1^2] < \infty$ , sowie  $c = 1$ . Dann folgt  $U_t = t^{-1/2}(L_t - t(\rho - 1))$  gegen  $\mathcal{N}(0, \lambda\mu_2)$  in Verteilung.

**Beweis.** Sei  $h > 0$ . Da  $(L_t)$  cadlag, stationäre und unabhängige Zuwächse hat, folgt, dass  $(L_{nh})_{n \geq 0}$  eine Irrfahrt ist mit  $\mathbb{V}(L_h) = \lambda\mu_2 h$ . Also  $U_{nh} \rightarrow \mathcal{N}(0, \lambda\mu_2)$  in Verteilung, demnach ist die Aussage bewiesen für  $t \in [nh, (n+1)h]$ . Sei nun  $n \in \mathbb{N}$  und  $t_n \in [nh, (n+1)h]$ . Es folgt  $R_n = ((n+1)h)^{-1/2}(L_{nh} - h - (n+1)h(\rho - 1)) \leq t_n^{-1/2}(L_{t_n} - t_n(\rho - 1)) = U_{t_n}$  und  $U_{t_n} \leq (nh)^{-1/2}(L_{(n+1)h} + h + nh(\rho - 1)) = S_n$ . Also gilt  $R_n \rightarrow \mathcal{N}(0, \lambda\mu_2)$  und  $S_n \rightarrow \mathcal{N}(0, \lambda\mu_2)$ . Dann gilt für alle  $x \in \mathbb{R}$ :  $\mathbb{P}(S_n \leq x) \leq \mathbb{P}(U_{t_n} \leq x) \leq \mathbb{P}(R_n \leq x)$ , weshalb insgesamt  $U_{t_n} \rightarrow \mathcal{N}(0, \lambda\mu_2)$  in Verteilung.  $\square$

### 4.2.3 Berechnung der Ruinwahrscheinlichkeit mit Hilfe der Integro-Differentialgleichung

**Ziel:** Herleitung einer Integro-Differentialgleichung zur Ruinwahrscheinlichkeit im unendlichen Zeithorizont  $\psi(r_0)$  als Funktion der Variable  $r_0 \geq 0$ . Aus der

Definition folgt die infinitesimale Darstellung der Poisson-wahrscheinlichkeit:

$$\mathbb{P}(N_h = k) = \begin{cases} 1 - \lambda h + o(h) & \text{falls } k = 0; \\ \lambda h + o(h) & \text{falls } k = 1, h \rightarrow 0; \\ o(h) & \text{falls } k \geq 2, h \rightarrow 0. \end{cases}$$

Betrachte die folgende Fälle:

- $X_1 \leq r_0$  kein Ruin in  $[0, h]$ ;
- $r_0 \leq X_1 \leq r_0 + ch$  so existiert ein  $\delta \in (0, h]$ , s.d. Ruin sicher in  $[0, s]$  und unmöglich in  $[s, h]$ ;
- $X_1 > r_0 + ch$  Ruin sicher in  $[0, h]$ .

Für  $X_1 = x \in (r_0, r_0 + ch]$  gilt  $r_0 + c\delta = x \Leftrightarrow \delta = \delta(x) = \frac{x-r_0}{c}$ . Dann lässt sich folgende asymptotische Integro-Differentialgleichung finden:  $\psi(r_0) = (1 - \lambda h)\psi(r_0 + ch) + \lambda h(\int_0^{r_0} \psi(r_0 + ch - x)dF(x) + \int_{r_0}^{r_0+ch} \psi(r_0 + ch - x)dF(x) + \int_{r_0+ch}^{\infty} dF(x)) + o(h)$ , für  $h \rightarrow 0$ . Das ist äquivalent zur folgenden Gleichung:  $\psi(r_0) - \psi(r_0 + ch) = -\lambda h(\psi(r_0 + ch) - \int_0^{r_0} \psi(r_0 + ch - x)dF(x) - \int_{r_0}^{r_0+ch} \psi(r_0 + ch - x)dF(x) - (1 - F(r_0 + ch))) + o(h)$ , für  $h \rightarrow 0$ .

Sei  $\psi$  differenzierbar. Dann folgt durch Grenzübergang:

$$\psi'(r_0) = \frac{\lambda}{c}(\psi(r_0) - \int_0^{r_0} \psi(r_0 - x)dF(x) - (1 - F(r_0))).$$

Diese Gleichung heißt die **Integro-Differentialgleichung für die Ruinwahrscheinlichkeit**  $\psi$ .

**Beispiel 4.2.17.** Für die Überlebenswahrscheinlichkeit  $1 - \psi(r_0) = R(r_0)$  gilt  $R'(r_0) = \frac{\lambda}{c}R(r_0) - \frac{\lambda}{c} \int_0^{r_0} R(r_0 - x)dF(x)$ .

Betrachte die lineare Kombination von exp-Verteilungen mit der Dichte  $f(x) = \exp(-3x) + \frac{10}{3} \exp(-5x)$ ,  $x > 0$ .

Dann gilt  $\mu = \mathbb{E}[X_1] = \frac{11}{45}$ . Weiter ist  $\beta = \frac{4}{11}$  und  $\frac{\lambda}{c} = \frac{3}{1}$ .

Also haben wir  $R'(r_0) = 3R(r_0) - 3 \int_0^{r_0} R(r_0 - x)f(x)dx$ .

Definiere  $g_n(u) = \int_0^u \exp(ny)R(y)dy$ . Damit gilt:

$R'(u) = 3R(u) - 3 \exp(-3u)g_3(u) - 10 \exp(-5u)g_5(u)$  und

$R''(u) = \dots = -2R'(u) + 2R(u) - 6 \exp(-3u)g_3(u)$  und

$R'''(u) = \dots = -5R''(u) - 4R'(u)$ .

Also ist  $R'''(u) + 5R''(u) - 4R'(u) = 0$ . Nach der Lösung von DGL ergibt sich

$R(u) = 1 - \frac{32}{45} \exp(-u) - \frac{1}{45} \exp(-4u)$ .



# Literatur

[A]