

## 2

### Cópuas e Interdependência

Neste capítulo serão expostas as definições de interesse e os principais resultados a respeito da teoria de cópuas, interdependência e contágio. Mais a frente, o conceito de cópuas será usado para modelar estruturas de dependência de dados multivariados. A dependência nos extremos será analisada e, a partir daí, saberemos como ela revela o comprometimento da diversificação de um investimento em um período de crise. Desenvolvimentos semelhantes podem ser vistos em [14], artigo que serviu de inspiração para esta dissertação.

#### 2.1

##### Teoria Básica de Cópuas

A função de distribuição conjunta  $H(x_1, \dots, x_n)$  descreve completamente a dependência entre as variáveis aleatórias de valores reais  $X_1, \dots, X_n$

$$H(x_1, \dots, x_n) = P(X_1 \leq x_1, \dots, X_n \leq x_n). \quad (2-1)$$

Supondo que  $X_1, \dots, X_n$  têm distribuições marginais contínuas  $F_{X_1}(x_1), \dots, F_{X_n}(x_n)$  podemos, através da transformada integral de probabilidade, transformar o vetor aleatório  $(X_1, \dots, X_n)$ , componente a componente, de modo que ele passe a ter distribuições marginais  $U(0, 1)$ .

$$T_n : \mathfrak{R}^n \mapsto \mathfrak{R}^n, \quad (x_1, \dots, x_n) \mapsto (F_{X_1}(x_1), \dots, F_{X_n}(x_n)). \quad (2-2)$$

A função distribuição conjunta  $C(\cdot)$  destas novas marginais uniformes  $F_{X_1}(x_1), \dots, F_{X_n}(x_n)$  é chamada cópula do vetor aleatório  $(X_1, \dots, X_n)$ . De

forma equivalente,  $C(\cdot)$  também pode ser vista como a cópula associada com a distribuição conjunta  $H(\cdot)$ . Segue que

$$\begin{aligned} H(x_1, \dots, x_n) &= P(F_{X_1}(X_1) \leq F_{X_1}(x_1), \dots, F_{X_n}(X_n) \leq F_{X_n}(x_n)) \\ &= C(F_{X_1}(x_1), \dots, F_{X_n}(x_n)). \end{aligned}$$

**Observação 2.1.1.** É possível transformar qualquer variável aleatória contínua em uma outra variável aleatória que também tenha distribuição contínua (não necessariamente  $U(0, 1)$ ). A transformação  $T_n : (x_1, \dots, x_n) \mapsto (F_{X_1}(x_1), \dots, F_{X_n}(x_n))$  mostrada na equação (2-2) é uma ferramenta padrão na metodologia de simulação e largamente utilizada porque a distribuição  $U(0, 1)$  é a mais simples possível (livre de parâmetros).

**Definição 2.1.1.** Uma cópula é definida como uma função de distribuição conjunta

$$C(u_1, \dots, u_n) = P(U_1 \leq u_1, \dots, U_n \leq u_n), \quad 0 \leq u_i \leq 1$$

sendo  $U_i \sim U(0, 1)$ ,  $i = 1, \dots, n$ .

Uma definição alternativa é:

**Definição 2.1.2.** Uma cópula é qualquer função  $C : [0, 1]^n \mapsto [0, 1]$  que tem as seguintes propriedades:

- (i)  $C(x_1, \dots, x_n)$  é crescente em cada componente  $x_i$ ;
- (ii)  $C(1, \dots, 1, x_i, 1, \dots, 1) = x_i \in [0, 1]$  para todo  $i = 1, \dots, n$ ;
- (iii) Para todos  $(a_1, \dots, a_n), (b_1, \dots, b_n) \in [0, 1]^n$  com  $a_i \leq b_i$  tem-se que

$$\sum_{i_1=1}^2 \dots \sum_{i_n=1}^2 (-1)^{i_1+\dots+i_n} C(x_{1i_1}, \dots, x_{ni_n}) \geq 0,$$

com  $x_{j1} = a_j$  e  $x_{j2} = b_j$ ,  $j = 1, \dots, n$ .

Pode-se mostrar que essas duas definições de cópulas são equivalentes, e.g. Embrechts et al. [11].

O resultado mais importante na teoria de cópulas, que mostra a existência e unicidade da função  $C(\cdot)$  é o teorema de Sklar [1].

**Teorema de Sklar.** *Seja  $H(\cdot)$  uma função de distribuição conjunta com marginais  $F_{X_1}, \dots, F_{X_n}$ . Então existe uma cópula  $n$ -dimensional  $C(\cdot)$  tal que*

$$H(x_1, \dots, x_n) = C(F_{X_1}(x_1), \dots, F_{X_n}(x_n)). \quad (2-3)$$

*Se as margens  $F_{X_1}, \dots, F_{X_n}$  são todas contínuas, então  $C(\cdot)$  é única. Em caso contrário,  $C(\cdot)$  é unicamente determinada no conjunto  $Im(F_{X_1}) \times \dots \times Im(F_{X_n})$ , onde  $Im(\cdot)$  representa a imagem de  $(\cdot)$ .*

*Reciprocamente, dado que  $C(\cdot)$  é uma cópula  $n$ -dimensional e  $F_{X_1}, \dots, F_{X_n}$  são funções de distribuição, então a função  $H(\cdot)$ , definida na equação (2-3), é uma função de distribuição conjunta  $n$ -dimensional.*

Através da equação (2-3) podemos concluir que a cópula  $C(\cdot)$  é uma função que relaciona a função distribuição conjunta e sua marginais.

O corolário a seguir mostra que podemos extrair, desde que a inversa exista, uma cópula de qualquer distribuição multivariada e usá-la independentemente das distribuições marginais originais.

**Corolário 2.1.1.** *Sejam  $H(\cdot)$ ,  $F_{X_1}, \dots, F_{X_n}$  como no Teorema de Sklar e sejam  $F_{X_1}^{-1}, \dots, F_{X_n}^{-1}$  inversas de  $F_{X_1}, \dots, F_{X_n}$  respectivamente. Então para qualquer  $u_i \in [0, 1]$  existe uma cópula  $n$ -dimensional  $C(\cdot)$  tal que*

$$C(u_1, \dots, u_n) = H(F_{X_1}^{-1}(u_1), \dots, F_{X_n}^{-1}(u_n)). \quad (2-4)$$

Em palavras, o corolário acima afirma ser possível estudar a dependência entre variáveis sem fixar suas distribuições marginais.

**Teorema 2.1.1.** *Seja  $(X_1, \dots, X_n)$  um vetor de variáveis aleatórias contínuas com cópula  $C(\cdot)$ . Se  $\alpha_1(\cdot), \dots, \alpha_n(\cdot)$  são funções estritamente crescentes em  $Im(X_1), \dots, Im(X_n)$ , respectivamente, então  $(\alpha_1(X_1), \dots, \alpha_n(X_n))$  também têm cópula  $C(\cdot)$ .*

**Prova.** Sejam  $F_{X_1}, \dots, F_{X_n}$  funções distribuição de  $X_1, \dots, X_n$  e sejam  $G_1, \dots, G_n$  as funções distribuição de  $\alpha_1(X_1), \dots, \alpha_n(X_n)$  respectivamente. Seja  $(X_1, \dots, X_n)$  um vetor aleatório com cópula  $C(\cdot)$  e seja  $C_\alpha(\cdot)$  a cópula de  $(\alpha_1(X_1), \dots, \alpha_n(X_n))$ . Uma vez que  $\alpha_k(\cdot)$  é estritamente crescente para cada  $k = 1, \dots, n$ ,

$$G_k(x) = P(\alpha_k(X_k) \leq x) = P(X_k \leq \alpha_k^{-1}(x)) = F_k(\alpha_k^{-1}(x)),$$

para todo  $x$  em  $\bar{\mathfrak{R}}$ , portanto

$$\begin{aligned} C_\alpha(G_1(x_1), \dots, G_n(x_n)) &= P(\alpha_1(X_1) \leq x_1, \dots, \alpha_n(X_n) \leq x_n) \\ &= P(X_1 \leq \alpha_1^{-1}(x_1), \dots, X_n \leq \alpha_n^{-1}(x_n)) \\ &= C(F_1(\alpha_1^{-1}(x_1)), \dots, F_n(\alpha_n^{-1}(x_n))) \\ &= C(G_1(x_1), \dots, G_n(x_n)). \end{aligned}$$

Como  $X_1, \dots, X_n$  são contínuas,  $Im(G_1) = \dots = Im(G_n) = [0, 1]$ , i.e.,  $C_\alpha(\cdot) = C(\cdot)$  em  $[0, 1]^n$ .

Sendo assim, as transformações não lineares estritamente crescentes alteram a distribuição conjunta  $H(\cdot)$  e suas marginais, mas a forma analítica da cópula  $C(\cdot)$  permanece a mesma. Esta é uma característica importante e desejável.

O teorema a seguir declara a existência de uma função  $\hat{C}(\cdot)$  que separa uma função de sobrevivência  $n$ -dimensional a partir de suas funções de sobrevivência marginais univariadas. Pode-se mostrar também que essa função é uma cópula, e essa cópula de sobrevivência pode ser expressa em termos de  $C(\cdot)$  e de suas marginais  $k$ -dimensionais.

**Teorema 2.1.2.** *Seja  $(X_1, \dots, X_n)$  um vetor de variáveis aleatórias contínuas com cópula  $C(\cdot)$ . Se  $\alpha_1(\cdot), \dots, \alpha_n(\cdot)$  são estritamente monótonas em  $Im(X_1), \dots, Im(X_n)$ , respectivamente, e seja  $(\alpha_1(X_1), \dots, \alpha_n(X_n))$  um vetor de variáveis aleatórias transformadas em cópula  $C_{\alpha_1(X_1), \dots, \alpha_n(X_n)}(\cdot)$ .*

*Além disso seja  $\alpha_k(\cdot)$  estritamente decrescente para algum  $k$ . Sem perda de generalidade, seja  $k=1$ . Então*

$$\begin{aligned} &C_{\alpha_1(X_1), \dots, \alpha_n(X_n)}(u_1, \dots, u_n) = \\ &= C_{\alpha_2(X_2), \dots, \alpha_n(X_n)}(u_2, \dots, u_n) - C_{X_1, \alpha_2(X_2), \dots, \alpha_n(X_n)}(1 - u_1, u_2, \dots, u_n). \end{aligned}$$

**Prova.** Sejam  $\alpha_1(X_1), \dots, \alpha_n(X_n)$  variáveis aleatórias com funções distribuição  $G_1, \dots, G_n$  respectivamente. Então,

$$\begin{aligned}
C_{\alpha_1(X_1), \dots, \alpha_n(X_n)}(G_1(x_1), \dots, G_n(x_n)) &= \\
&= P(\alpha_1(X_1) \leq x_1, \dots, \alpha_n(X_n) \leq x_n) \\
&= P(X_1 > \alpha_1^{-1}(x_1), \dots, X_n \leq \alpha_n^{-1}(x_n)) \\
&= C_{\alpha_2(X_2), \dots, \alpha_n(X_n)}(G_2(x_2), \dots, G_n(x_n)) \\
&\quad - C_{X_1, \alpha_2(X_2), \dots, \alpha_n(X_n)}(F_1(\alpha_1^{-1}(x_1)), G_2(x_2), \dots, G_n(x_n)) \\
&= C_{\alpha_2(X_2), \dots, \alpha_n(X_n)}(G_2(x_2), \dots, G_n(x_n)) \\
&\quad - C_{X_1, \alpha_2(X_2), \dots, \alpha_n(X_n)}(1 - G_1(x_1), G_2(x_2), \dots, G_n(x_n)).
\end{aligned}$$

De onde a conclusão segue diretamente.

**Teorema 2.1.3.** *Seja  $(X_1, \dots, X_n)$  um vetor de variáveis aleatórias contínuas com cópula  $C(\cdot)$ , então  $X_1, \dots, X_n$  são independentes se e somente se*

$$C(\mathbf{u}) = C(u_1, \dots, u_n) = \prod_{i=1}^n u_i = \Pi^n(\mathbf{u}).$$

## 2.2

### Cópuas Associadas a Valores Extremos

São inúmeras as situações em finança, engenharia, questões ambientais, re-seguros e outras áreas onde é necessário se caracterizar a estrutura de dependência existente nos quantis extremos de uma distribuição bivariada. Para se medir a dependência assintótica pode-se fazer uso da modelagem paramétrica dos máximos em cada componente da distribuição bivariada ou, alternativamente, podem ser utilizadas as cópuas pertencentes a essas distribuições. Em casos onde, ao invés de máximos em cada componente, prefere-se trabalhar com excessos além de limiares altos<sup>1</sup>, pode-se utilizar uma grande variedade de cópuas, com propriedades de assimetria e capazes de capturar vários tipos de dependência, inclusive dependência de cauda.

Alguns dos resultados clássicos da teoria de valores extremos bivariada serão traduzidos para a linguagem de cópuas. Em seguida veremos algumas propriedades e medidas de interesse. Para isto, seja  $\mathbf{X} = (X_1, X_2)$  um vetor aleatório em  $\mathfrak{R}^2$  com função distribuição conjunta  $H(\cdot, \cdot)$ , e tal que

<sup>1</sup>Chamamos de limiar alto um valor do suporte de  $X$  perto de  $x_{F_X}$ .

$H(.,.) \in MDA(W)$  <sup>2</sup>, onde  $W(.,.)$  é uma BEV <sup>3</sup>. Sejam  $F_i(.)$  as marginais de  $H(.,.)$ , com  $F_i \in MDA(H_i)$ , onde  $H_i(.)$  são as distribuições GEV,  $i = 1, 2$ . Seja  $C(.)$  a cópula pertencente a  $H(.,.)$ ;

$$H(x_1, x_2) = C(F_1(x_1), F_2(x_2)). \quad (2-5)$$

Pelas considerações já feitas podemos dizer que existe uma cópula  $C_*(.)$ , única, tal que

$$W(x_1, x_2) = C_*(H_1(x_1), H_2(x_2)). \quad (2-6)$$

Deheuvels [3] mostra que

$$C_*(u_1, u_2) = \lim_{n \rightarrow \infty} C^n(u_1^{\frac{1}{n}}, u_2^{\frac{1}{n}}). \quad (2-7)$$

Então  $C_*(.)$  satisfaz

$$C_*(u_1^t, u_2^t) = C_*^t(u_1, u_2), \quad (2-8)$$

para todo  $t > 0$ . A equação (2-8) é a definição de uma cópula de valores extremos.

<sup>2</sup>As distribuições  $H$  de valores extremos são obtidas como distribuições limite ( $n \rightarrow \infty$ ) do máximo de um conjunto de variáveis aleatórias independentes e identicamente distribuídas, e são unicamente determinadas a menos de transformações afins. O teorema de Fisher-Tippett implica que se  $F_X^n(c_n x + d_n)$  é não degenerada quando  $n \rightarrow \infty$ , para certas constantes  $c_n > 0$ ,  $d_n \in \mathfrak{R}$ , então

$$|F_X^n(x) - H(\frac{x - d_n}{c_n})| \rightarrow 0, n \rightarrow \infty$$

para alguma  $H$ . Se a equação acima se verifica, dizemos que  $F_X$  pertence ao domínio de atração do máximo da distribuição de valores extremos  $H$ . Notação:  $F_X \in MDA(H)$ .

<sup>3</sup>Distribuição de valores extremos bivariados (*Bivariate Extreme Value*).

Supondo que  $C(\cdot)$  seja a cópula BB4 (notação de Joe [5]):

$$C_{\theta,\delta}(u_1, u_2) = \left\{ u_1^{-\theta} + u_2^{-\theta} - 1 - [(u_1^{-\theta} - 1)^{-\delta} + (u_2^{-\theta} - 1)^{-\delta}]^{-\frac{1}{\delta}} \right\}^{-\frac{1}{\theta}},$$

onde  $\theta > 0$  e  $\delta > 0$ . Usando a equação (2-7) obtemos a cópula limite

$$C_*(u_1, u_2) = u_1 u_2 \exp \left\{ [(-\ln u_1)^{-\delta} + (-\ln u_2)^{-\delta}]^{-\frac{1}{\delta}} \right\},$$

que é a cópula Galambos, mostrada mais a frente na equação (2-14). Assim, dizemos que a cópula BB4 pertence ao domínio de atração da cópula Galambos.

Apresentamos agora uma versão bivariada do teorema de Fisher-Tippett.

**Teorema 2.2.1.**(Fisher-Tippett para cópulas). *Suponha que  $H(\cdot, \cdot) \in MDA(W)$  e que  $W(x_1, x_2) = C_*(H_1(x_1), H_2(x_2))$ . Então*

- (i) As marginais  $H_i$  são GEV e  $F_i \in MDA(H_i)$ ,  $i = 1, 2$ .
- (ii)  $C_*(u_1^t, u_2^t) = C_*^t(u_1, u_2)$  para todo  $t > 0$ .

O teorema diz que se existir uma distribuição limite não degenerada para os máximos bivariados, então as suas marginais devem ser do tipo de uma distribuição de valores extremos, e que a cópula pertencente à distribuição limite deve ser max-estável.<sup>4</sup>

Sabe-se que a cópula  $C(\cdot)$  de  $H(\cdot, \cdot)$  é invariante sob transformações estritamente crescentes de  $(X_1, X_2)$ . Isto é, seja  $Y_1 = T_1(X_1)$  e  $Y_2 = T_2(X_2)$ , onde  $T_1, T_2$  são funções estritamente crescentes de  $\mathfrak{R} \mapsto \mathfrak{R}$ . Então  $(Y_1, Y_2)$  tem também cópula  $C(\cdot)$ , como mostrado no Teorema 2.1.1.

Por outro lado, se  $C_*(\cdot)$  é a cópula limite de  $(M_1, M_2)$ , ou seja,  $C_*(\cdot)$  é a cópula pertencente a  $W(\cdot)$ , pode-se mostrar que a cópula limite de  $(M'_1, M'_2)$  é também  $C_*(\cdot)$ , onde  $(M'_1, M'_2)$  são os máximos associados às seqüências das variáveis aleatórias  $(Y_1, Y_2)$ . Para a prova deste resultado consulte Joe [5]. De fato, a cópula limite  $C_*$  é independente da escolha das marginais de  $H(\cdot, \cdot)$ . Ela é determinada apenas pela cópula  $C(\cdot)$  de  $H(\cdot, \cdot)$ .

<sup>4</sup>Sejam  $X_1, X_2, \dots$  variáveis aleatórias independentes e identicamente distribuídas com função distribuição  $F$ , e sejam  $d_n \in \mathfrak{R}$  e  $c_n > 0$  constantes apropriadas. Dizemos que  $F$  é max-estável se satisfaz a igualdade em distribuição

$$\max(X_1, \dots, X_n) \stackrel{d}{=} c_n X + d_n.$$

A definição mostra que toda distribuição max-estável é distribuição limite para o máximo de variáveis aleatórias independentes e identicamente distribuídas.

Este é um resultado de interessantes implicações. A interdependência entre quantis extremos de variáveis depende somente da cópula que as conecta, não importando em nada a forma de suas distribuições marginais.

Assim, dizer que  $H(.,.) \in MDA(W)$  é equivalente a dizer que  $(C, F_1, F_2) \in MDA(C_*, H_1, H_2)$ . Resultando em:

**Teorema 2.2.2.**  $(C, F_1, F_2) \in MDA(C_*, H_1, H_2)$  se e somente se

- (i)  $F_i \in MDA(H_i), i = 1, 2$ .
- (ii)  $C \in MDA(C_*)$ .

Não é fácil a caracterização dos domínios de atração bivariados. Através das cópulas, no entanto, este exercício se torna bastante interessante. Uma distribuição normal bivariada com coeficiente de correlação  $< 1$ , por exemplo, apresenta margens pertencentes ao MDA da Gumbel,  $H_0$ , e o limite de sua cópula (cópula Gaussiana) é a cópula produto,  $\Pi(.,.)$ . Temos então:

$$\begin{aligned} W(x_1, x_2) &= \Pi(H_0(x_1), H_0(x_2)) \\ &= \exp(-e^{-x_1}) \exp(-e^{-x_2}) \\ &= \exp(-e^{x_1} - e^{x_2}). \end{aligned}$$

Podemos agora estabelecer o conceito de domínio de atração para cópulas.

**Definição 2.2.1.** Seja  $C_*(.)$  uma cópula de valores extremos. Dizemos que a cópula  $C(.,.)$  pertence ao domínio de atração de  $C_*(.,.)$ , e escrevemos,  $C \in CDA(C_*)$ , se e somente se  $C(F_1, F_2) \in MDA(C_*(H_1, H_2))$ , sempre que  $F_i$  contínua,  $F_i \in MDA(H_i), i = 1, 2$ .

Assim, max-estabilidade não só garante que  $W \in MDA(W)$  como também garante que  $C_* \in CDA(C_*)$ , para toda cópula de valores extremos  $C_*$ .

Analogamente ao estudo dos diferentes domínios de atração, também precisamos de teoremas e condições que permitam caracterizar se uma determinada cópula está, ou não, no domínio de atração de uma outra cópula. O teorema a seguir é uma ferramenta que pode ser utilizada nesse sentido.

**Teorema 2.2.3.** *Seja  $C(\cdot)$  uma cópula e  $C_*(\cdot)$  uma cópula de valores extremos. Então,  $C \in CDA(C_*)$  se e somente se*

$$\lim_{t \rightarrow 0} \frac{1 - C(1 - tu_1, 1 - tu_2)}{t} = -\ln C_*(e^{-u_1}, e^{-u_2}). \quad (2-9)$$

Uma outra propriedade interessante é sobre o resultado de uma combinação convexa de cópulas de valores extremos. Sejam  $C_i(\cdot)$ ,  $i = 1, 2$ , cópulas. Seja  $\alpha \in (0, 1)$ , e suponha que  $C_i \in CDA(C_{*,i})$ ,  $i = 1, 2$ . Defina

$$C_3(u_1, u_2) = \alpha C_1(u_1, u_2) + (1 - \alpha)C_2(u_1, u_2).$$

Pode-se mostrar, usando a equação (2-9), que a cópula limite de  $C_3(\cdot)$ , denotada por  $C_{*,3}(\cdot)$  é dada por

$$C_{*,3}(u_1, u_2) = (C_{*,1}(u_1, u_2))^\alpha (C_{*,2}(u_1, u_2))^{1-\alpha}. \quad (2-10)$$

Aplicando a equação (2-10) às cópulas de valores extremos: as cópulas produto  $\Pi(\cdot)$ , e a da dependência positiva perfeita  $M(\cdot)$ , obtêm-se

$$C_{*,3}(u_1, u_2) = (u_1 u_2)^\alpha \min(u_1^{1-\alpha}, u_2^{1-\alpha}),$$

que é a cópula de valor extremo de Marshall-Olkin.

Uma cópula  $C(\cdot)$  é simétrica se satisfaz

$$C(u_1, u_2) = C(u_2, u_1), \quad \text{para todo } (u_1, u_2) \in [0, 1]^2,$$

e as variáveis envolvidas são permutáveis. Isto significa que as linhas de quantil de  $C(\cdot)$  são simétricas em relação à diagonal principal de  $[0, 1]^2$ . Em uma cópula permutável, a seção vertical de sua densidade ao longo da diagonal secundária,  $c(u, 1 - u)$ , é simétrica.

Cópulas permitem o uso de vários conceitos de dependência e de concordância, veja Joe [5] e Nelsen [15]. Aqui, tratando de extremos, o

conceito mais importante será o de dependência de cauda. O coeficiente de dependência de cauda mede a dependência assintótica existente no quadrante superior direito, ou no quadrante inferior esquerdo, de uma distribuição bivariada.

O coeficiente de dependência de cauda superior,  $\lambda_U$ , entre  $X_1$  e  $X_2$ , é definido como

$$\lim_{\alpha \rightarrow 0^+} \lambda_U(\alpha) = \lim_{\alpha \rightarrow 0^+} P\{X_1 > F_1^{-1}(1 - \alpha) \mid X_2 > F_2^{-1}(1 - \alpha)\}, \quad (2-11)$$

se este limite existe. Dizemos que duas variáveis,  $X_1$  e  $X_2$ , são assintoticamente dependentes na cauda superior se  $\lambda_U \in (0, 1]$ , e assintoticamente independentes se  $\lambda_U = 0$ . O mesmo conceito é aplicado para se definir o coeficiente de dependência de cauda inferior,  $\lambda_L$ .

Ambos os coeficientes,  $\lambda_U$  e  $\lambda_L$ , podem ser expressos através da cópula  $C(\cdot)$  pertencente a  $(X_1, X_2)$ :

$$\lambda_U = \lim_{u \uparrow 1} \frac{\bar{C}(u, u)}{1 - u}, \quad (2-12)$$

onde  $\bar{C}(u, v) = Pr\{U > u, V > v\}$ , e

$$\lambda_L = \lim_{u \downarrow 0} \frac{C(u, u)}{u}, \quad (2-13)$$

se esses limites existem.

Podemos classificar as cópulas em três tipos, de acordo com a forma da seção vertical  $c(u, u)$  de sua densidade ao longo da diagonal principal. A cópula tipo “J” possui somente  $\lambda_U > 0$ . A cópula do tipo “L” possui somente  $\lambda_L > 0$ , e a cópula tipo “U” possui ambos  $\lambda_L > 0$  e  $\lambda_U > 0$ .

As cópulas tipo “J” apresentam um tipo de assimetria de particular interesse quando se estuda valores extremos. A maioria das cópulas de valores extremos são do tipo “J”.

Cópulas que têm  $\lambda_U > 0$  podem ser construídas aplicando-se o conceito de cópulas associadas. Para qualquer cópula n-dimensional, existem  $2^n - 1$

cópulas associadas. Quando  $n = 2$  e  $(U, V)$  possui cópula  $C(\cdot)$ , as cópulas associadas são:

1. A cópula pertencente à distribuição de  $(1 - U, 1 - V)$  e dada por  $C'(u, v) = u + v - 1 + C(1 - u, 1 - v)$ .
2. A cópula pertencente à distribuição de  $(U, 1 - V)$  e dada por  $C''(u, v) = u - C(u, 1 - v)$ .
3. A cópula pertencente à distribuição de  $(1 - U, V)$  e dada por  $C'''(u, v) = v - C(1 - u, v)$ .

Se a cópula  $C(\cdot)$  é do tipo “L”, então  $C'(\cdot)$  é do tipo “J” (Joe [5]). Aplicaremos esta construção à cópula de Kimeldorf e Sampson, para obtermos uma cópula de valores extremos com  $\lambda_U > 0$  (veja a cópula  $C_{AKS}^\delta$ ).

Na prática, o problema da identificação da cópula mais adequada para um conjunto de dados é complexo. No caso da modelagem de eventos extremos, podemos superar esta dificuldade restringindo nossa atenção às cópulas de valores extremos. Serão mostradas a seguir as cinco famílias paramétricas de cópulas de valores extremos que serão usadas, nesta dissertação, na modelagem dos dados. Nas expressões abaixo usar-se-á a seguinte notação:  $\tilde{u} = -\ln u$ , e  $\tilde{v} = -\ln v$ .

(i) *Cópula Galambos:  $C_{Gal}^\delta$*

$$C_{Gal}(u, v, \delta) = u_1 u_2 \exp \left\{ (\tilde{u}^{-\delta} + \tilde{v}^{-\delta})^{-\frac{1}{\delta}} \right\}, \quad (2-14)$$

onde  $0 \leq \delta < \infty$ . Esta é uma cópula permutável tipo “J”, com coeficiente de dependência de cauda superior igual a  $2 - 2^{\frac{1}{\delta}}$ , para  $\delta > 1$ . Quando  $\delta \rightarrow 0$ ,  $C_{Gal}^\delta$  se aproxima da cópula produto.

(ii) *Cópula associada a cópula de Kimeldorf e Sampson:  $C_{AKS}^\delta$*

$$C_{AKS}(u, v, \delta) = u + v - 1 + \left[ (1 - u)^{-\frac{1}{\delta}} + (1 - v)^{-\frac{1}{\delta}} - 1 \right]^{-\delta}, \quad (2-15)$$

onde  $\delta \geq 0$ . Esta é uma cópula tipo “J” permutável, obtida como a cópula  $C'$  associada à cópula de Kimeldorf e Sampson (ou Pareto), dada por  $C(u, v) = (u^{-\delta} + v^{-\delta} - 1)^{-\frac{1}{\delta}}$ . Ela possui  $\lambda_U = 2^{-\frac{1}{\delta}}$ , que vai para zero quando  $\delta \rightarrow 0$ . Pode-se mostrar (Frees e Valdez [7]) que a  $C_{AKS}(u, v, \delta)$  é a cópula pertencente à distribuição de Pareto bivariada, isto é, à distribuição formada por marginais Pareto procedentes de uma mesma classe indexada por um parâmetro que induz independência.

(iii) *Cópula do modelo logístico assimétrico:  $C_{ALM}^{\delta, p_1, p_2}$*

$$C_{ALM}(u, v, \delta, p_1, p_2) = \exp \left[ - \left( p_1^\delta \tilde{u}^\delta + p_2^\delta \tilde{v}^\delta \right)^{\frac{1}{\delta}} - (1 - p_1) \tilde{u} - (1 - p_2) \tilde{v} \right], \quad (2-16)$$

para  $(p_1, p_2) \in [0, 1]^2$  e  $\delta \leq 1$ . Esta cópula é uma mistura das cópulas produto e Gumbel, e pode ser obtida usando a técnica de assimetrização. É uma cópula não permutável. Contudo, não possui um único parâmetro associado com a não-permutabilidade, e problemas de identificabilidade de modelo podem ocorrer.

Utilizando-se a técnica de assimetrização é possível obter-se a mesma expressão para a função de dependência  $A(\cdot)$  do modelo logístico assimétrico dada por

$$A_4(v) = \left[ \theta^\delta (1 - v)^\delta + \phi^\delta v^\delta \right]^{\frac{1}{\delta}} + (\theta - \phi)v + 1 - \theta, \quad 0 \leq \theta, \phi \leq 1, \quad \delta \geq 1.$$

No caso da cópula da cópula  $C_{ALM}^{\delta, p_1, p_2}$ , os parâmetros  $(p_1, p_2)$  estão restritos ao  $[0, 1]^2$ . A partir da expressão obtida para  $A(\cdot)$  e de  $\lambda = 2[1 - A(1/2)]$  obtemos a expressão para o coeficiente de dependência de cauda superior da cópula  $C_{ALM}^{\delta, p_1, p_2}$ . É dado por:

$$\lambda_U = p_1 + p_2 - (p_1^\delta + p_2^\delta)^{\frac{1}{\delta}}, \quad (2-17)$$

para  $(p_1, p_2) \in [0, 1]^2$  e  $\delta \geq 1$ . Se  $p_1$  ou  $p_2$  for igual a zero, então  $\lambda_U = 0$ , e temos independência. Quando  $p_1 = p_2 = 1$ , fazendo  $\delta \rightarrow \infty$ ,  $\lambda_U$  se aproxima de 1, o caso da dependência perfeita.

(iv) *Cópula Joe-Clayton:  $C_{JC}^{\delta, \theta}$*

$$C(u, v, \delta, \theta) = 1 - \left[ 1 - \left( [1 - (1 - u)^\theta]^{-\delta} + [1 - (1 - v)^\theta]^{-\delta} - 1 \right)^{-\frac{1}{\delta}} \right]^{\frac{1}{\theta}}, \quad (2-18)$$

onde  $\theta \geq 1$ ,  $\delta \geq 0$ . Esta é uma cópula tipo “U”, permutável, que possui ambos os coeficientes de dependência de cauda (não necessariamente iguais), sendo  $\lambda_U = 2 - 2^{\frac{1}{\theta}}$  independente de  $\delta$ , e  $\lambda_L = 2^{-\frac{1}{\theta}}$ , independente de  $\theta$ . Quando  $\lambda_U = 0$  ( $\theta = 1$ ) ela reduz à cópula Clayton. Quando  $\delta \leq 1$ , a concordância aumenta com  $\theta$ . Quando  $\theta \rightarrow \infty$  ou  $\delta \rightarrow \infty$ , a  $C_{JC}^{\delta, \theta}$  se aproxima da dependência perfeita positiva dada pela cópula  $M$ , e  $\lambda_U \rightarrow 1$ .

(v) *Cópula Joe:  $C_J^\delta$*

$$C(u, v, \delta) = 1 - \left[ (1 - u)^\delta + (1 - v)^\delta - (1 - u)^\delta (1 - v)^\delta \right]^{\frac{1}{\delta}}, \quad (2-19)$$

onde  $\delta \geq 1$ .

Maiores definições e explicações a respeito das cópulas, como modelar dependências com elas e seus principais processos de estimação podem ser encontrados em Mendes [12] e Anjos, Ferreira, Kolev e Mendes [13].