






# Kopula









# Využitie copuly

- Copula umožňuje „rozčleniť“ viacrozmerné rozdelenie na jednorozmerné rozdelenia a „štruktúru závislostí“ medzi nimi:

Ak  $F_1(x) := \Pr[X \leq x]$  a  $F_2(y) := \Pr[Y \leq y]$  sú jednorozmerné distribučné funkcie, potom výraz v tvare  $C(F_1(x), F_2(y))$ , kde  $C$  je nejaká copula, vyjadruje viacrozmernú distribučnú funkciu  $H(x, y) := \Pr[X \leq x, Y \leq y]$ .

# Definícia

- Copula  $C$  je viacrozmerná distribučná funkcia za predpokladu, že jej jednorozmerné zložky  $u, v$  (*margins*) majú rovnomerné rozdelenie na  $[0,1]$ :

$$C(u, v) = \Pr[U < u, V < v]$$

- Dvojrozmerná copula je funkcia  $C : [0,1] \times [0,1] \rightarrow [0,1]$  s nasledujúcimi vlastnosťami:

1. Pre každé  $u, v$  z  $[0,1]$  platí:

$$C(u,0) = C(0,v) = 0$$

$$C(u,1) = u \text{ a } C(1,v) = v$$

2. Pre každé  $u_1, u_2, v_1, v_2$  z  $[0,1]$  také, že  $u_1 \leq u_2$  a  $v_1 \leq v_2$

$$C(u_2, v_2) - C(u_2, v_1) - C(u_1, v_2) + C(u_1, v_1) \geq 0$$

- Interpretácia:  $C(u,v)$  je pravdepodobnosť, že hodnoty náhodných premenných  $U, V$  (nemusia byť rovnomerne rozdelené) padnú pod ich  $(100u)\%$ -ný, resp.  $(100v)\%$ -ný kvantil.

# Pozor na pojmy!

- Copula nie je kupola ani kopolácia!





# Sklarova veta

- Nech  $H$  je distribučná funkcia viacrozmerného rozdelenia s jednorozmernými rozdeleniami, ktoré majú distribučné funkcie  $F$  a  $G$ . Potom existuje copula  $C$  taká, že pre každé  $x, y \in \mathbf{R}$  platí:

$$H(x, y) = C(F(x), G(y))$$

- Ak sú  $F$  a  $G$  spojité, potom je copula  $C$  určená jednoznačne.
- Naopak, ak  $C$  je copula a  $F$  a  $G$  sú distribučné funkcie, potom funkcia  $H$  je viacrozmerná distribučná funkcia, ktorej jednorozmerné rozdelenia majú distribučné funkcie  $F$  a  $G$ .

# Tail dependence

- Analógia problému tučných chvostov (*fat tails*) vo viacrozmernom prípade
- Miera súčasného výskytu vysokých strát vo viacerých aktívach

$$\lambda(w) := \Pr[X \leq w | Y \leq w] = \frac{\Pr[X \leq w \wedge Y \leq w]}{\Pr[Y \leq w]}$$

- S využitím copuly môžeme písať:  $\lambda(w) := \frac{C(w, w)}{w}$
- Lower tail index:  $\lambda_L := \lim_{w \rightarrow 0^+} \lambda(w)$

# Hustota bivariačného rozdelenia

- Ak distribučné funkcie  $F$  a  $G$  sú diferencovateľné a kopula  $C$  je dvakrát diferencovateľná, potom

$$h(x, y) \equiv \frac{\partial^2 H(x, y)}{\partial x \partial y}$$

$$h(x, y) \equiv \frac{\partial F(x)}{\partial x} \cdot \frac{\partial G(y)}{\partial y} \cdot \frac{\partial^2 C(F(x), G(y))}{(\partial F(x) \partial G(y))}$$

$$h(x, y) \equiv f(x) \cdot g(y) \cdot c(F(x), G(y))$$


# Príklady kopúl

- **Gaussova kopula**

$$C_N(x,y;\rho) = \Phi_2[\Phi^{-1}(x); \Phi^{-1}(y); \rho],$$

- Ak sú marginálne rozdelenia normálne, Gaussova kopula dáva viacrozmerne normálne rozdelenie

- Nulová chvostová závislosť (pokiaľ  $\rho < 1$ )



Marginálne rozdelenia:  $N(0,1)$ ,  $\rho = 0.5$

- Platí

$$C_N(u_1, u_2, \rho) = \int_{-\infty}^{\Phi^{-1}(u_1)} \int_{-\infty}^{\Phi^{-1}(u_2)} \frac{1}{2\pi\sqrt{1-\rho^2}} \exp\left\{\frac{-(r^2 - 2\rho rs + s^2)}{2(1-\rho^2)}\right\} dr ds$$

# Príklady kopúl


- **Studentova t-kopula**

$$C_t(x,y;\rho,v) = t_2[t^{-1}(x;v); t^{-1}(y;v); \rho],$$

- Ak sú marginálne rozdelenia Studentove, Studentova t-kopula dáva viacrozmerne Studentovo rozdelenie

- Nenulová chvostová závislosť

- rastie s klesajúcim počtom stupňov voľnosti



Marginálne rozdelenia:  $N(0,1)$ ,  $\rho = 0.5$ ,  $v = 3$

# Príklady kopúl

- **Archimedova trieda kopúl (*class of Archimedean copulas*)**
  - Všeobecný tvar:  $C(x,y) = \varphi^{-1}[\varphi(x) + \varphi(y)]$ , kde  $\varphi : [0,1] \rightarrow [0,\infty)$  je spojitá, klesajúca, konvexná funkcia spĺňajúca  $\varphi(0) = \infty$  a  $\varphi(1) = 0$  [tzv. generátor]
  - Parametrické kopuly:

1. Gumbelova kopula:

$$\varphi_{\alpha}(t) = (-\ln t)^{\alpha}, \quad \text{kde } \alpha \in [1, \infty)$$

2. Claytonova kopula:

$$\varphi_{\alpha}(t) = \frac{1}{\alpha} (t^{-\alpha} - 1), \quad \text{kde } \alpha \in [-1, \infty) \setminus \{0\}$$


3. Frankova kopula:

$$\varphi_{\alpha}(t) = -\ln \frac{e^{-\alpha t} - 1}{e^{-\alpha} - 1}, \quad \text{kde } \alpha \in (-\infty, \infty) \setminus \{0\}$$

# Príklady kopúl

- **Gumbelova kopula**
- Dolná chvostová závislosť je nulová
- Horná chvostová závislosť rastie s rastúcim  $\alpha$

$$\lambda_u = 2 - 2^{\frac{1}{\alpha}}$$




Marginálne rozdelenia:  $N(0,1)$ ,  $\alpha = 1.5$

# Príklady kopúl

- **Claytonova kopula**
- Horná chvostová závislosť je nulová
- Dolná chvostová závislosť rastie s rastúcim  $\alpha$

$$\lambda_L = 2^{-\frac{1}{\alpha}}$$



Marginálne rozdelenia:  $N(0,1)$ ,  $\alpha = 1$



# Odhad parametrov

- Metóda maximálnej vierohodnosti

$$l(\theta_C, \theta_X, \theta_Y) = \sum_{n=1}^N \ln c(F(x_n; \theta_X), G(y_n; \theta_Y); \theta_C) + \sum_{n=1}^N \ln f(x_n; \theta_X) + \sum_{n=1}^N \ln g(y_n; \theta_Y)$$

- Odhad všetkých parametrov naraz (kopula aj marginálne rozdelenia) môže byť výpočtovo náročný → dvojkrokové metódy
  1. *Interference for margins* (plne parametrická metóda)
  2. *Canonical Maximum Likelihood* (semiparametrická metóda)
- Empirická kopula
- Pomocou mier súhlasnosti

# Odhad parametrov

- **Interference for margins**

- Najprv sa nezávisle odhadnú parametre marginálnych rozdelení  $\theta_X, \theta_Y$
- S využitím týchto odhadov sa následne odhadnú parametre kopuly  $\theta_C$
- Odhad je nevychýlený

- **Canonical Maximum Likelihood**

- Distribučné funkcie marginálnych rozdelení sa odhadnú empiricky
- Pomocou nich sa odhadnú parametre copuly

$$\hat{\theta}_C = \arg \max_{\theta_C} \sum_{n=1}^N \ln c(\hat{F}(x_n), \hat{G}(y_n), \theta_C)$$

# Odhad parametrov

- **Empirická kopula**

- Výpočet

$$C\left(\frac{i}{N}, \frac{j}{N}\right) = \frac{\#\{(x, y) \mid x \leq x_i \wedge y \leq y_j\}}{N}, \quad i, j = 1, \dots, N$$

- Empirická kopula je empirická distribučná funkcia transformovaných dát, kde každému údaju priradíme jeho poradie
- Empirická kopula rovnomerne konverguje k skutočnej kopule (Deheuvels, 1978, 1981)

# Concordance measures

- Miery závislosti / súhlasnosti / zhodnosti
- **Concordance** = pravdepodobnosť, že náhodné vektory  $X$  a  $Y$  nadobúdajú zároveň veľké alebo zároveň malé hodnoty je vysoká, ale pravdepodobnosť veľkých hodnôt  $X$  spolu s malými hodnotami  $Y$  je nízka.
- Concordance measures
  - Kendallovo tau
  - Spearmanov koeficient
  - Korelačný (Pearsonov) koeficient
  - Tail dependence

# Concordance measures

- **Kendalovo tau**

- Definícia

$$\tau = \frac{\# \text{ concordant pairs} - \# \text{ discordant pairs}}{\# \text{ total number of pairs}} \in [-1, 1]$$

- Alternatívny zápis definície

$$\tau = P((X_1 - X_2)(Y_1 - Y_2) > 0) - P((X_1 - X_2)(Y_1 - Y_2) < 0)$$

- Výpočet pomocou kopule

$$\tau = 4 E[C(U, V)] - 1$$

(U, V sú rovnomerne rozdelené na [0,1])

- Príklad: Výpočet pre nezávislé náhodné premenné

$$\tau_{C^\perp} = 4 \iint_{[0,1]^2} uv \, du \, dv - 1 = 4 \left( \int_0^1 x \, dx \right)^2 - 1 = 0$$

# Concordance measures

- **Spearmanovo  $\rho$ :**

- Definícia: Ak máme tri vektory  $(X_1, Y_1)$ ,  $(X_2, Y_2)$ ,  $(X_3, Y_3)$ , tak Spearmanovo  $\rho$  sa vypočíta ako Kendallovo tau pre  $(X_1, Y_1)$  a  $(X_2, Y_3)$

[prvá dvojica má distribučnú funkciu H, druhá je nezávislá]

$$\rho = P((X_1 - X_2)(Y_1 - Y_3) > 0) - P((X_1 - X_2)(Y_1 - Y_3) < 0)$$

- Alternatívna definícia: *rank correlation*

$$\rho = \frac{\text{cov}(F_1(X), F_2(Y))}{\sqrt{\text{var}(F_1(X)) \text{var}(F_2(Y))}}$$

- Definícia pomocou kopule

$$\rho = 12 \iint_{[0,1]^2} C(u, v) \, du \, dv - 3$$

# Concordance measures

- **Korelačný (Pearsonov) koeficient**

- Definícia

$$\rho = \frac{\text{cov}(X, Y)}{\sqrt{\text{var}(X) \text{var}(Y)}}$$

- Korelačný koeficient nie je považovaný za mieru konkordancie!

- Vyjadruje len lineárnu závislosť
- Môže vyjsť nulový, aj keď náhodné premenné sú úplne závislé
  - Príklad: Pre dve lognormálne rozdelenia s štandardnými odchýlkami  $\sigma_1 = 0.4$  a  $\sigma_2 = 0.6$  nemôže pri žiadnej štruktúre závislostí (danej ľubovoľnou kopulou) byť mimo intervalu  $[-0.45, 0.57]$
- Nie je definovaný, ak neexistuje druhý moment
- Nezávisí iba na marginálnych rozdeleniach, ale aj na kopule

# Literatúra

- Cherubini, U., Luciano, E., Vecchiao, W. (2004): Copula Methods in Finance, John Wiley & Sons, Ltd

