

Schätzung von Copulas

Gegeben sei ein Satz multi-dimensionaler Daten. Gesucht ist eine Copula und die Randverteilungen die diesem Datensatz am besten entsprechen.

1. Frage: Welche Familie von (bekannten) Copulas eignet sich am besten?

Antwort: Visueller Vergleich der graphischen Darstellungen von Daten bzw. bekannten Copulas, Berechnung der empirischen Koeffizienten der Tail-Abhängigkeit und Auswahl von dazu passenden Copula Familien.

2. Frage: Schätzung der Parameter einer vorselektierten Copula Familie.

Gegeben: Eine Stichprobe $\{X_1, X_2, \dots, X_n\}$ aus einer Gesamtverteilung F mit stetigen Randverteilungen F_1, F_2, \dots, F_d .

Gesucht: Ein Schätzer $\hat{\theta}$ des Parameter-Vektors θ der eindeutigen Copula C_θ , für die $F(x) = C(F_1(x_1), \dots, F_d(x_d))$ gilt.

Die Schätzer $\hat{\theta}$ für C_R^{Ga} , $C_{\nu,R}^t$, C_θ^{Cl} und C_θ^{Gu}

$$C_R^{Ga} = \phi_R^d(\phi^{-1}(u_1), \dots, \phi^{-1}(u_d)) \quad R_{ij} = \sin(\pi(\rho_\tau)_{ij}/2)$$

$$C_{\nu,R}^t = t_{\nu,R}^d(t_\nu^{-1}(u_1), \dots, t_\nu^{-1}(u_d)) \quad R_{ij} = \sin(\pi(\rho_\tau)_{ij}/2)$$

$$C_\theta^{Gu}(u) = \exp(-[(-\ln u_1)^\theta + \dots + (-\ln u_d)^\theta]^{1/\theta}) \quad \theta = 1/(1 - (\rho_\tau)_{ij}) \quad ,$$

$$C_\theta^{Cl}(u) = (u_1^{-\theta} + \dots + u_d^{-\theta} - d + 1)^{-1/\theta} \quad \theta = 2(\rho_\tau)_{ij}/(1 - (\rho_\tau)_{ij})$$

wobei

$$\begin{aligned} (\rho_\tau)_{ij} &= \rho_\tau(X_{k,i}, X_{k,j}) \\ &= P((X_{k,i} - X_{l,i})(X_{k,j} - X_{l,j}) > 0) - P((X_{k,i} - X_{l,i})(X_{k,j} - X_{l,j}) < 0) \\ &= E(\text{sign}((X_{k,i} - X_{l,i})(X_{k,j} - X_{l,j}))). \end{aligned}$$

Standard Schätzer für Kendalls Tau:

$$\hat{\rho}_{\tau ij} = \binom{n}{2}^{-1} \sum_{1 \leq k < l \leq n} \text{sign}((X_{k,i} - X_{l,i})(X_{k,j} - X_{l,j})).$$

Schätzung von Gauss'schen Copulas und t -Copulas

Es kann passieren, dass $\hat{R} = (\hat{R}_{ij})$ nicht positive definit ist, wobei

$$\hat{R}_{ij} = \sin(\pi \hat{\rho}_{\tau_{ij}}/2).$$

\hat{R} wird durch eine Korrelationsmatrix R^* ersetzt, wobei R^* "unweit" von \hat{R} liegt.

Algorithmus 6 (Eigenwert-Ansatz, siehe Rousseeuw und Molenberghs 1993)

- Berechne die Spektralzerlegung $\hat{R} = \Gamma \Lambda \Gamma^T$ von \hat{R} , wobei Λ eine Diagonalmatrix ist, die die Eigenwerte von \hat{R} enthält, und Γ eine orthogonale Matrix deren Spalten den Eigenvektoren von \hat{R} entsprechen.
- Ersetze die negativen Eigenwerte in λ durch eine kleine Zahl $\delta > 0$ um $\tilde{\Lambda}$ zu erhalten.
- Berechne $\tilde{R} = \Gamma \tilde{\Lambda} \Gamma^T$. \tilde{R} ist symmetrisch und positive definit aber nicht unbedingt eine Korrelationsmatrix, weil die Diagonalelemente \hat{R}_{ii} ungleich 1 sein könnten.
- Setze $\hat{R} = D \tilde{R} D$ wobei D eine diagonale Matrix mit $D_{k,k} = 1/\sqrt{\tilde{R}_{k,k}}$ ist.

t -Copulas: Schätzung des Parameters ν der Freiheitsgrade

1. Schätzung der univariaten Randverteilungsfunktionen F_1, F_2, \dots, F_d . Seien $\hat{F}_1, \dots, \hat{F}_d$ die dazugehörigen Schätzer.
2. Bildung einer Pseudo-Stichprobe der Copula:

$$\hat{U}_k = (\hat{U}_{k,1}, \hat{U}_{k,2}, \dots, \hat{U}_{k,d}) := (\hat{F}_1(X_{k,1}), \dots, \hat{F}_d(X_{k,d})),$$

für $k = 1, 2, \dots, n$ (siehe Genest und Rivest 1993).

\hat{F}_k kann folgendermaßen erzeugt werden:

- Parametrische Schätzung: \hat{F}_k ist eine parametrische Verteilungsfunktion wobei der Parameter zB. mit einem Maximum Likelihood (ML) Ansatz geschätzt wird.
- Nicht Parametrische Schätzung: \hat{F}_i ist die empirische Verteilungsfunktion $\hat{F}_i(x) = \frac{1}{n+1} \sum_{t=1}^n I_{X_{t,i} \leq x}$, $1 \leq i \leq d$.

ML-Schätzung von ν : $\nu = \arg \max_{\xi} \ln L(\xi; \hat{U}_1, \hat{U}_2, \dots, \hat{U}_n)$ wobei

$$L(\xi; \hat{U}_1, \hat{U}_2, \dots, \hat{U}_n) = \prod_{k=1}^n c_{\xi, R}^t(\hat{U}_k)$$

und $c_{\xi, R}^t$ die Dichte der t -Copula $C_{\xi, R}^t$ ist.

Daraus folgt

$$\ln L(\xi; \hat{U}_1, \hat{U}_2, \dots, \hat{U}_n) = \sum_{k=1}^n \ln g_{\xi, R}(t_{\xi}^{-1}(\hat{U}_{k,1}), \dots, t_{\xi}^{-1}(\hat{U}_{k,d})) - \sum_{k=1}^n \sum_{j=1}^d \ln g_{\xi}(t_{\xi}^{-1}(\hat{U}_{k,j})),$$

wobei $g_{\xi, R}$ die Gesamtdichte einer standard d -dimensionalen t -Verteilung mit Verteilungsfunktion $t_{\xi, R}^d$ ist,

und

g_{ξ} die Dichte einer univariaten standard t -Verteilung mit ξ Freiheitsgraden ist.