



**Weierstrass Institute for
Applied Analysis and Stochastics**



Die FWER und Konzepte multivariater Abhängigkeit

Jens Stange

1 Einleitung

2 Einschrittprozeduren

3 Abhängigkeitskonzepte

Multiples Testproblem: $(\mathcal{X}, \mathcal{F}, \mathcal{P}, \mathcal{H}_m)$

Parametrische Annahme:

$$\mathcal{P} = \{\mathbb{P}_\vartheta \mid \vartheta \in \Theta\}, \Theta \subseteq \mathbb{R}^p.$$

Multiples Testproblem: $(\mathcal{X}, \mathcal{F}, \mathcal{P}, \mathcal{H}_m)$

Parametrische Annahme:

alternativ:

$$\mathcal{P} = \{\mathbb{P}_{\vartheta, \eta} \mid \vartheta \in \Theta, \eta \in \Xi\}, \Theta \subseteq \mathbb{R}^p.$$

η nuisance Parameter, Abhängigkeitsparameter

Multiples Testproblem: $(\mathcal{X}, \mathcal{F}, \mathcal{P}, \mathcal{H}_m)$

Parametrische Annahme:

$$\mathcal{P} = \{\mathbb{P}_\vartheta \mid \vartheta \in \Theta\}, \Theta \subseteq \mathbb{R}^p.$$

Multiples Testproblem: $(\mathcal{X}, \mathcal{F}, \mathcal{P}, \mathcal{H}_m)$

Parametrische Annahme:

$$\mathcal{P} = \{\mathbb{P}_\vartheta \mid \vartheta \in \Theta\}, \Theta \subseteq \mathbb{R}^p.$$

Hypothesensystem $\mathcal{H}_m = \{\emptyset \neq H_i \subset \Theta \mid i = 1, \dots, m\}$

Multiples Testproblem: $(\mathcal{X}, \mathcal{F}, \mathcal{P}, \mathcal{H}_m)$

Parametrische Annahme:

$$\mathcal{P} = \{\mathbb{P}_\vartheta \mid \vartheta \in \Theta\}, \Theta \subseteq \mathbb{R}^p.$$

Hypothesensystem $\mathcal{H}_m = \{\emptyset \neq H_i \subset \Theta \mid i = 1, \dots, m\}$

Multipler Test für \mathcal{H}_m :

$$\varphi = (\varphi_i)_{i=1, \dots, m} : \mathcal{X} \rightarrow \{0, 1\}^m, \text{ messbar.}$$

Multiples Testproblem: $(\mathcal{X}, \mathcal{F}, \mathcal{P}, \mathcal{H}_m)$

Parametrische Annahme:

$$\mathcal{P} = \{\mathbb{P}_\vartheta \mid \vartheta \in \Theta\}, \Theta \subseteq \mathbb{R}^p.$$

Hypothesensystem $\mathcal{H}_m = \{\emptyset \neq H_i \subset \Theta \mid i = 1, \dots, m\}$

Multipler Test für \mathcal{H}_m :

$$\varphi = (\varphi_i)_{i=1, \dots, m} : \mathcal{X} \rightarrow \{0, 1\}^m, \text{ messbar.}$$

mit dem Ziel:

Kontrolle der Familywise Error Rate, das heißt für vorgegebenes $\alpha \in (0, 1)$

$$\forall \vartheta \in \Theta : \text{FWER}_\vartheta(\varphi) = \mathbb{P}_\vartheta \left(\bigcup_{i \in I_0(\vartheta)} \{\varphi_i = 1\} \right) \stackrel{!}{\leq} \alpha.$$

Trotz einiger Nachteile, die überwiegend dem Fluch der Dimension geschuldet sind, gibt es dennoch Gründe FWER-kontrollierende Testprozeduren zu konstruieren:

Trotz einiger Nachteile, die überwiegend dem Fluch der Dimension geschuldet sind, gibt es dennoch Gründe FWER-kontrollierende Testprozeduren zu konstruieren:

- Interpretierbarkeit

Trotz einiger Nachteile, die überwiegend dem Fluch der Dimension geschuldet sind, gibt es dennoch Gründe FWER-kontrollierende Testprozeduren zu konstruieren:

- Interpretierbarkeit
- bestätigender (confirmatory) Charakter

Trotz einiger Nachteile, die überwiegend dem Fluch der Dimension geschuldet sind, gibt es dennoch Gründe FWER-kontrollierende Testprozeduren zu konstruieren:

- Interpretierbarkeit
- bestätigender (confirmatory) Charakter
- Konservativität

Vektor von Teststatistiken

$$\mathbf{T} = (T_1, \dots, T_m) : \mathcal{X} \rightarrow S^m$$

messbare Abbildunge, üblicherweise: $S = \mathbb{R}$ oder $S = [0, \infty)$

Vektor von Teststatistiken

$$\mathbf{T} = (T_1, \dots, T_m) : \mathcal{X} \rightarrow S^m$$

messbare Abbildung, üblicherweise: $S = \mathbb{R}$ oder $S = [0, \infty)$

Testentscheidung mithilfe von Ablehnbereichen

$$\Gamma_i \subset S, i = 1, \dots, m$$

üblicherweise: $\Gamma = (c, \infty)$ oder $\Gamma = (-\infty, -c) \cup (c, \infty)$

$$\varphi_i = \mathbf{I}(T_i \in \Gamma_i), i = 1, \dots, m.$$

Vektor von Teststatistiken

$$\mathbf{T} = (T_1, \dots, T_m) : \mathcal{X} \rightarrow S^m$$

messbare Abbildung, üblicherweise: $S = \mathbb{R}$ oder $S = [0, \infty)$

Testentscheidung mithilfe von Ablehnbereichen

$$\Gamma_i \subset S, i = 1, \dots, m$$

üblicherweise: $\Gamma = (c, \infty)$ oder $\Gamma = (-\infty, -c) \cup (c, \infty)$

$$\varphi_i = \mathbf{I}(T_i \in \Gamma_i), i = 1, \dots, m.$$

Die Ablehnregionen $\Gamma_i \equiv \Gamma_i(\alpha_{\text{loc},i})$ seien so gewählt, dass

$$\vartheta \in H_i \Rightarrow \mathbb{P}_{\vartheta}(\varphi_i = 1) = \mathbb{P}_{\vartheta}(T_i \in \Gamma_i) \leq \alpha_{\text{loc},i} \in (0, \alpha].$$

Beispielsweise durch Bonferroni-Korrektur: $\alpha_{\text{loc},i} = \alpha/m, i = 1, \dots, m.$

Betrachte für fixes (reguläres) Design $X = (x_{ij})_{\substack{i=1,\dots,n \\ j=1,\dots,m}}$, $m < n$ das Regressionsmodell mit homoskedastischem, normalverteiltem Fehler $\varepsilon = (\varepsilon_i)_{i=1,\dots,n} \stackrel{i.i.d.}{\sim} \mathcal{N}(0, \sigma^2)$:

$$Y = X\beta + \varepsilon$$

mit unbekanntem Regressionsparametern $\beta = (\beta_1, \dots, \beta_m) \in \mathbb{R}^m$

Betrachte für fixes (reguläres) Design $X = (x_{ij})_{\substack{i=1,\dots,n \\ j=1,\dots,m}}$, $m < n$ das Regressionsmodell mit homoskedastischem, normalverteiltem Fehler $\varepsilon = (\varepsilon_i)_{i=1,\dots,n} \stackrel{i.i.d.}{\sim} \mathcal{N}(0, \sigma^2)$:

$$Y = X\beta + \varepsilon$$

mit unbekanntem Regressionsparametern $\beta = (\beta_1, \dots, \beta_m) \in \mathbb{R}^m$

Simultanes Testen auf signifikanten Einfluß der einzelnen Regressionsparameter:

$$\mathcal{H}_m = \{H_j = \{\beta_j = 0\} \mid j = 1, \dots, m\}$$

Betrachte für fixes (reguläres) Design $X = (x_{ij})_{\substack{i=1,\dots,n \\ j=1,\dots,m}}$, $m < n$ das Regressionsmodell mit homoskedastischem, normalverteiltem Fehler $\varepsilon = (\varepsilon_i)_{i=1,\dots,n} \stackrel{i.i.d.}{\sim} \mathcal{N}(0, \sigma^2)$:

$$Y = X\beta + \varepsilon$$

mit unbekanntem Regressionsparametern $\beta = (\beta_1, \dots, \beta_m) \in \mathbb{R}^m$

Simultanes Testen auf signifikanten Einfluß der einzelnen Regressionsparameter:

$$\mathcal{H}_m = \{H_j = \{\beta_j = 0\} \mid j = 1, \dots, m\}$$

Vektor von Teststatistiken: $\mathbf{T} = (T_1, \dots, T_m)$ gegeben durch:

$$T_j := \frac{\hat{\beta}_j}{\hat{S}}, \quad j = 1, \dots, m$$

Betrachte für fixes (reguläres) Design $X = (x_{ij})_{\substack{i=1,\dots,n \\ j=1,\dots,m}}$, $m < n$ das Regressionsmodell mit homoskedastischem, normalverteiltem Fehler $\varepsilon = (\varepsilon_i)_{i=1,\dots,n} \stackrel{i.i.d.}{\sim} \mathcal{N}(0, \sigma^2)$:

$$Y = X\beta + \varepsilon$$

mit unbekanntem Regressionsparametern $\beta = (\beta_1, \dots, \beta_m) \in \mathbb{R}^m$

Simultanes Testen auf signifikanten Einfluß der einzelnen Regressionsparameter:

$$\mathcal{H}_m = \{H_j = \{\beta_j = 0\} \mid j = 1, \dots, m\}$$

Vektor von Teststatistiken: $\mathbf{T} = (T_1, \dots, T_m)$ gegeben durch:

$$T_j := \frac{\hat{\beta}_j}{\hat{S}}, \quad j = 1, \dots, m$$

$$\hat{\beta} = (X^T X)^{-1} X^T Y \sim \mathcal{N}_m(\beta, \sigma^2 (X^T X)^{-1})$$

$$\hat{S}^2 = \frac{1}{n - m} \sum_{i=1}^n (Y_i - (X\hat{\beta})_i)^2,$$

Betrachte für fixes (reguläres) Design $X = (x_{ij})_{\substack{i=1,\dots,n \\ j=1,\dots,m}}$, $m < n$ das Regressionsmodell mit homoskedastischem, normalverteiltem Fehler $\varepsilon = (\varepsilon_i)_{i=1,\dots,n} \stackrel{i.i.d.}{\sim} \mathcal{N}(0, \sigma^2)$:

$$Y = X\beta + \varepsilon$$

mit unbekanntem Regressionsparametern $\beta = (\beta_1, \dots, \beta_m) \in \mathbb{R}^m$

Simultanes Testen auf signifikanten Einfluß der einzelnen Regressionsparameter:

$$\mathcal{H}_m = \{H_j = \{\beta_j = 0\} \mid j = 1, \dots, m\}$$

Vektor von Teststatistiken: $\mathbf{T} = (T_1, \dots, T_m)$ gegeben durch:

$$T_j := \frac{\hat{\beta}_j}{\hat{S}}, \quad j = 1, \dots, m$$

$$\hat{\beta} = (X^T X)^{-1} X^T Y \sim \mathcal{N}_m(\beta, \sigma^2 (X^T X)^{-1})$$

$$\hat{S}^2 = \frac{1}{n-m} \sum_{i=1}^n (Y_i - (X\hat{\beta})_i)^2, \quad \frac{(n-m)}{(X^T X)^{-1}_{jj} \sigma^2} \hat{S}^2 \sim \chi_{n-m}^2.$$

Betrachte für fixes (reguläres) Design $X = (x_{ij})_{\substack{i=1,\dots,n \\ j=1,\dots,m}}$, $m < n$ das Regressionsmodell mit homoskedastischem, normalverteiltem Fehler $\varepsilon = (\varepsilon_i)_{i=1,\dots,n} \stackrel{i.i.d.}{\sim} \mathcal{N}(0, \sigma^2)$:

$$Y = X\beta + \varepsilon$$

mit unbekanntem Regressionsparametern $\beta = (\beta_1, \dots, \beta_m) \in \mathbb{R}^m$

Simultanes Testen auf signifikanten Einfluß der einzelnen Regressionsparameter:

$$\mathcal{H}_m = \{H_j = \{\beta_j = 0\} \mid j = 1, \dots, m\}$$

Vektor von Teststatistiken: $\mathbf{T} = (T_1, \dots, T_m)$ gegeben durch:

$$T_j := \frac{\hat{\beta}_j}{\hat{S}}, \quad j = 1, \dots, m$$

$$\hat{\beta} = (X^T X)^{-1} X^T Y \sim \mathcal{N}_m(\beta, \sigma^2 (X^T X)^{-1}) \Rightarrow \hat{\beta}_j \stackrel{H_j}{\sim} \mathcal{N}(0, \sigma^2 (X^T X)^{-1}_{jj})$$

$$\hat{S}^2 = \frac{1}{n-m} \sum_{i=1}^n (Y_i - (X\hat{\beta})_i)^2, \quad \frac{(n-m)}{(X^T X)^{-1}_{jj} \sigma^2} \hat{S}^2 \sim \chi_{n-m}^2.$$

Betrachte für fixes (reguläres) Design $X = (x_{ij})_{\substack{i=1,\dots,n \\ j=1,\dots,m}}$, $m < n$ das Regressionsmodell mit homoskedastischem, normalverteiltem Fehler $\varepsilon = (\varepsilon_i)_{i=1,\dots,n} \stackrel{i.i.d.}{\sim} \mathcal{N}(0, \sigma^2)$:

$$Y = X\beta + \varepsilon$$

mit unbekanntem Regressionsparametern $\beta = (\beta_1, \dots, \beta_m) \in \mathbb{R}^m$

Simultanes Testen auf signifikanten Einfluß der einzelnen Regressionsparameter:

$$\mathcal{H}_m = \{H_j = \{\beta_j = 0\} \mid j = 1, \dots, m\}$$

Vektor von Teststatistiken: $\mathbf{T} = (T_1, \dots, T_m)$ gegeben durch:

$$T_j := \frac{\hat{\beta}_j}{\hat{S}} \stackrel{H_j}{\sim} t_{n-m}, \quad j = 1, \dots, m$$

$$\hat{\beta} = (X^T X)^{-1} X^T Y \sim \mathcal{N}_m(\beta, \sigma^2 (X^T X)^{-1}) \Rightarrow \hat{\beta}_j \stackrel{H_j}{\sim} \mathcal{N}(0, \sigma^2 (X^T X)^{-1}_{jj})$$

$$\hat{S}^2 = \frac{1}{n-m} \sum_{i=1}^n (Y_i - (X\hat{\beta})_i)^2, \quad \frac{(n-m)}{(X^T X)^{-1}_{jj} \sigma^2} \hat{S}^2 \sim \chi_{n-m}^2.$$

Sei $H_{\text{glob}} = \bigcap_{j=1}^m H_j = \{\beta = 0\}$ die Globalhypothese, dann gilt

$$\hat{\beta} \stackrel{H_{\text{glob}}}{\sim} \mathcal{N}_m(0, \sigma^2 (X^T X)^{-1})$$

Für die Standardabweichung verwende nun

$$\frac{(n-1)}{\sigma^2} \hat{S}'^2 = \frac{1}{\sigma^2} \sum_{i=1}^n (Y_i - \bar{Y})^2 \sim \chi_{n-1}^2$$

Dann gilt für $\mathbf{T} = (T_1, \dots, T_m)$, $T_j := \frac{\hat{\beta}_j}{\hat{S}'}$

$$\mathbf{T} \stackrel{H_{\text{glob}}}{\sim} t_m(n-1, (X^T X)^{-1})$$

Sei $H_{\text{glob}} = \bigcap_{j=1}^m H_j = \{\beta = 0\}$ die Globalhypothese, dann gilt

$$\hat{\beta} \stackrel{H_{\text{glob}}}{\sim} \mathcal{N}_m(0, \sigma^2 (X^\top X)^{-1})$$

Für die Standardabweichung verwende nun

$$\frac{(n-1)}{\sigma^2} \hat{S}'^2 = \frac{1}{\sigma^2} \sum_{i=1}^n (Y_i - \bar{Y})^2 \sim \chi_{n-1}^2$$

Dann gilt für $\mathbf{T} = (T_1, \dots, T_m)$, $T_j := \frac{\hat{\beta}_j}{\hat{S}'}$

$$\mathbf{T} \stackrel{H_{\text{glob}}}{\sim} t_m(n-1, (X^\top X)^{-1})$$

Kontrolle der FWER?

$$\forall \beta \in \mathbb{R}^m : \mathbb{P}_\beta \left(\bigcup_{i \in I_0(\beta)} \{T_i \in \Gamma_i\} \right) \leq \alpha.$$

Forderung

Die Abhängigkeitsstruktur der Teststatistiken ist gegenüber dem Wahrheitsgehalt der Hypothesen invariant.

Forderung

Die Abhängigkeitsstruktur der Teststatistiken ist gegenüber dem Wahrheitsgehalt der Hypothesen invariant.

Formal fordern wir die Existenz eines Elementes $\vartheta^* \in H_{\text{glob}}$, so dass

$$\forall \vartheta \in \Theta : \mathbb{P}_{\vartheta} \left(\bigcup_{i \in I_0(\vartheta)} \{T_i \in \Gamma\} \right) = \mathbb{P}_{\vartheta^*} \left(\bigcup_{i \in I_0(\vartheta)} \{T_i \in \Gamma\} \right).$$

Forderung

Die Abhängigkeitsstruktur der Teststatistiken ist gegenüber dem Wahrheitsgehalt der Hypothesen invariant.

Formal fordern wir die Existenz eines Elementes $\vartheta^* \in H_{\text{glob}}$, so dass

$$\forall \vartheta \in \Theta : \mathbb{P}_{\vartheta} \left(\bigcup_{i \in I_0(\vartheta)} \{T_i \in \Gamma\} \right) = \mathbb{P}_{\vartheta^*} \left(\bigcup_{i \in I_0(\vartheta)} \{T_i \in \Gamma\} \right).$$

Damit können unter der Globalhypothese Ablehnregionen $(\Gamma_i(\alpha))_{i=1}^m$ bestimmt werden, so dass Kontrolle der FWER garantiert ist:

$$\forall \vartheta \in \Theta : \text{FWER}_{\vartheta}(\varphi) \leq 1 - \mathbb{P}_{\vartheta^*}(T_1 \notin \Gamma_1(\alpha), \dots, T_m \notin \Gamma_m(\alpha)) \stackrel{!}{=} \alpha.$$

Forderung

Die Abhängigkeitsstruktur der Teststatistiken ist gegenüber dem Wahrheitsgehalt der Hypothesen invariant.

Formal fordern wir die Existenz eines Elementes $\vartheta^* \in H_{\text{glob}}$, so dass

$$\forall \vartheta \in \Theta : \mathbb{P}_{\vartheta} \left(\bigcup_{i \in I_0(\vartheta)} \{T_i \in \Gamma\} \right) = \mathbb{P}_{\vartheta^*} \left(\bigcup_{i \in I_0(\vartheta)} \{T_i \in \Gamma\} \right).$$

Damit können unter der Globalhypothese Ablehnregionen $(\Gamma_i(\alpha))_{i=1}^m$ bestimmt werden, so dass Kontrolle der FWER garantiert ist:

$$\forall \vartheta \in \Theta : \text{FWER}_{\vartheta}(\varphi) \leq 1 - \mathbb{P}_{\vartheta^*}(T_1 \notin \Gamma_1(\alpha), \dots, T_m \notin \Gamma_m(\alpha)) \stackrel{!}{\leq} \alpha.$$

Seien X und Y zwei Zufallsvariablen

$$\text{cov}(X, Y) := \mathbb{E}[XY] - \mathbb{E}X\mathbb{E}Y$$

Pearson's Produktmomentenkorrelation und misst genau den Grad der linearen stochastischen Abhängigkeit zweier Zufallsvariablen.

Seien X und Y zwei Zufallsvariablen

$$\text{cov}(X, Y) := \mathbb{E}[XY] - \mathbb{E}X\mathbb{E}Y$$

Pearson's Produktmomentenkorrelation und misst genau den Grad der linearen stochastischen Abhängigkeit zweier Zufallsvariablen.

Beispiel

Multivariate Normalverteilungen verfügen über lineare Abhängkeitsstruktur.

Seien, X und ε unabhängige standardnormalverteilte Zufallsvariablen und definiere

$$Y := aX + \varepsilon$$

für ein $a \in \mathbb{R}$.

Dann gilt:

$$Y \sim \mathcal{N}(0, 1 + a^2) \text{ und } \text{cov}(X, Y) = a$$

mittels Linearkombinationen von Vektoren:

Kovarianzmatrix: $\Sigma \in \mathbb{R}^{m \times m}$ symmetrisch, positiv definit Mittelwert $\mu \in \mathbb{R}^m$

$$\mathbf{X} = (X_1, \dots, X_m) \sim \mathcal{N}_m(\mu, \Sigma)$$

$$\Leftrightarrow \forall v \in \mathbb{R}^m \langle X, v \rangle \sim \mathcal{N}(\langle \mu, v \rangle, \langle \Sigma v, v \rangle).$$

mittels Linearkombinationen von Vektoren:

Kovarianzmatrix: $\Sigma \in \mathbb{R}^{m \times m}$ symmetrisch, positiv definit Mittelwert $\mu \in \mathbb{R}^m$

$$\mathbf{X} = (X_1, \dots, X_m) \sim \mathcal{N}_m(\mu, \Sigma)$$

$$\Leftrightarrow \forall v \in \mathbb{R}^m \langle X, v \rangle \sim \mathcal{N}(\langle \mu, v \rangle, \langle \Sigma v, v \rangle).$$

$$\Rightarrow \text{cov}(X_i, X_j) = (\Sigma)_{ij}$$

Lässt sich immer auf Unabhängigkeit zurückführen:

$$\mathbf{X} \stackrel{d}{=} \mu + \Sigma^{\frac{1}{2}} \mathbf{Z}, \quad \mathbf{Z} = (Z_1, \dots, Z_m) \sim \mathcal{N}_m(0, I_m).$$

mittels Linearkombinationen von Vektoren:

Kovarianzmatrix: $\Sigma \in \mathbb{R}^{m \times m}$ symmetrisch, positiv definit Mittelwert $\mu \in \mathbb{R}^m$

$$\mathbf{X} = (X_1, \dots, X_m) \sim \mathcal{N}_m(\mu, \Sigma)$$

$$\Leftrightarrow \forall v \in \mathbb{R}^m \langle X, v \rangle \sim \mathcal{N}(\langle \mu, v \rangle, \langle \Sigma v, v \rangle).$$

$$\Rightarrow \text{cov}(X_i, X_j) = (\Sigma)_{ij}$$

Lässt sich immer auf Unabhängigkeit zurückführen:

$$\mathbf{X} \stackrel{d}{=} \mu + \Sigma^{\frac{1}{2}} \mathbf{Z}, \quad \mathbf{Z} = (Z_1, \dots, Z_m) \sim \mathcal{N}_m(0, I_m).$$

Begrenztes Konzept, denn z.B. für $X \sim \mathcal{N}(0, 1)$ gilt

$$\text{cov}(X, X^2) = \mathbb{E}[X^3] = 0.$$

■ Kendall's τ

Für zwei Zufallsvariablen X, Y seien X' und Y' jeweils unabhängige Kopien

$$\tau(X, Y) = \mathbb{P}(\{X > X'\} \cap \{Y > Y'\}) - \mathbb{P}(\{X < X'\} \cap \{Y > Y'\})$$

Differenz der Wahrscheinlichkeit des Auftretens **konkordanter** bzw. **diskordante** Paare.

■ Kendall's τ

Für zwei Zufallsvariablen X, Y seien X' und Y' jeweils unabhängige Kopien

$$\tau(X, Y) = \mathbb{P}(\{X > X'\} \cap \{Y > Y'\}) - \mathbb{P}(\{X < X'\} \cap \{Y > Y'\})$$

Differenz der Wahrscheinlichkeit des Auftretens **konkordanter** bzw. **diskordante** Paare.

■ Spearman's ρ

Seien $X \sim F_X$ und $Y \sim F_Y$ mit jeweiligen Verteilungsfunktionen:

$$\rho(X, Y) = \text{cov}(F_X(X), F_Y(Y)).$$

■ Kendall's τ

Für zwei Zufallsvariablen X, Y seien X' und Y' jeweils unabhängige Kopien

$$\tau(X, Y) = \mathbb{P}(\{X > X'\} \cap \{Y > Y'\}) - \mathbb{P}(\{X < X'\} \cap \{Y > Y'\})$$

Differenz der Wahrscheinlichkeit des Auftretens **konkordanter** bzw. **diskordante** Paare.

■ Spearman's ρ

Seien $X \sim F_X$ und $Y \sim F_Y$ mit jeweiligen Verteilungsfunktionen:

$$\rho(X, Y) = \text{cov}(F_X(X), F_Y(Y)).$$

■ tail dependence

upper tail dependence: $\lambda_U : \lim_{x \rightarrow \infty} \mathbb{P}(Y > x | X > x)$.

lower tail dependence: $\lambda_L : \lim_{x \rightarrow -\infty} \mathbb{P}(Y \leq x | X \leq x)$.

■ Kendall's τ

Für zwei Zufallsvariablen X, Y seien X' und Y' jeweils unabhängige Kopien

$$\tau(X, Y) = \mathbb{P}(\{X > X'\} \cap \{Y > Y'\}) - \mathbb{P}(\{X < X'\} \cap \{Y > Y'\})$$

Differenz der Wahrscheinlichkeit des Auftretens **konkordanter** bzw. **diskordante** Paare.

■ Spearman's ρ

Seien $X \sim F_X$ und $Y \sim F_Y$ mit jeweiligen Verteilungsfunktionen:

$$\rho(X, Y) = \text{cov}(F_X(X), F_Y(Y)).$$

■ tail dependence

upper tail dependence: $\lambda_U : \lim_{x \rightarrow \infty} \mathbb{P}(Y > x | X > x)$.

lower tail dependence: $\lambda_L : \lim_{x \rightarrow -\infty} \mathbb{P}(Y \leq x | X \leq x)$.

■ Copulas

mehrdimensionale Verteilungsfunktionen mit uniformen Randverteilungen.

Einfachstes Abhängigkeitskonzept?

Einfachstes Abhängigkeitskonzept

Unabhängigkeit:

Bestimmung der Ablehnbereiche $\Gamma_i \equiv \Gamma_i(\alpha_{\text{loc}})$, $i = 1, \dots, m$ mit Šidák-Korrektur:

$$\alpha_{\text{loc}} = 1 - (1 - \alpha)^{1/m}.$$

also

$$\vartheta \in H_i : \mathbb{P}_{\vartheta}(\varphi = 1) = \mathbb{P}_{\vartheta}(T_i \notin \Gamma_i) = 1 - (1 - \alpha)^{1/m}$$

Einfachstes Abhängigkeitskonzept

Unabhängigkeit:

Bestimmung der Ablehnbereiche $\Gamma_i \equiv \Gamma_i(\alpha_{\text{loc}})$, $i = 1, \dots, m$ mit Šidák-Korrektur:

$$\alpha_{\text{loc}} = 1 - (1 - \alpha)^{1/m}.$$

also

$$\vartheta \in H_i : \mathbb{P}_{\vartheta}(\varphi = 1) = \mathbb{P}_{\vartheta}(T_i \notin \Gamma_i) = 1 - (1 - \alpha)^{1/m}$$

$$\forall \vartheta \in \Theta : \text{FWER}_{\vartheta}(\varphi) \leq 1 - \mathbb{P}_{\vartheta^*} \left(\bigcap_{i=1}^m \{T_i \notin \Gamma_i\} \right) = 1 - \prod_{i=1}^m \mathbb{P}_{\vartheta^*}(T_i \notin \Gamma_i) = \alpha.$$

Einfachstes Abhängigkeitskonzept

Unabhängigkeit:

Bestimmung der Ablehnbereiche $\Gamma_i \equiv \Gamma_i(\alpha_{\text{loc}})$, $i = 1, \dots, m$ mit Šidák-Korrektur:

$$\alpha_{\text{loc}} = 1 - (1 - \alpha)^{1/m}.$$

also

$$\vartheta \in H_i : \mathbb{P}_{\vartheta}(\varphi = 1) = \mathbb{P}_{\vartheta}(T_i \notin \Gamma_i) = 1 - (1 - \alpha)^{1/m}$$

$$\forall \vartheta \in \Theta : \text{FWER}_{\vartheta}(\varphi) \leq 1 - \mathbb{P}_{\vartheta^*} \left(\bigcap_{i=1}^m \{T_i \notin \Gamma_i\} \right) = 1 - \prod_{i=1}^m \mathbb{P}_{\vartheta^*}(T_i \notin \Gamma_i) = \alpha.$$

Qualitative Abhängigkeitskonzepte zielen auf $\mathbb{P}_{\vartheta^*} \left(\bigcap_{i=1}^m \{T_i \notin \Gamma_i\} \right)$.

Es können die folgenden Konzepte unterschieden werden:

1. positive quadrant dependent –PQD (Positiv Quadrantenabhängig)
2. stochastically increasing– SI, or positive regression dependent–PRD (stochastisch wachsend)
3. right-tail increasing –RTI, left-tail decreasing –LTD
4. association –A
5. total positivity of order 2 – TP_2

Es können die folgenden Konzepte unterschieden werden:

1. positive quadrant dependent –PQD (Positiv Quadrantenabhängig)
2. stochastically increasing– SI, or positive regression dependent–PRD (stochastisch wachsend)
3. right-tail increasing –RTI, left-tail decreasing –LTD
4. association –A
5. total positivity of order 2 – TP_2

Im folgenden werden jeweils ein Paar $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ reellwertiger Zufallsvariablen auf einem geeigneten Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, \mathbb{P})$ betrachtet.

Ein Paar $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ heißt **positive quadrant dependent**, falls für alle $x, y \in \mathbb{R}$ gilt

$$\mathbb{P}(\{X \leq x\} \cap \{Y \leq y\}) \geq \mathbb{P}(X \leq x)\mathbb{P}(Y \leq y).$$

bzw. für alle $x, y \in \mathbb{R}$ gilt

$$\mathbb{P}(\{X > x\} \cap \{Y > y\}) \geq \mathbb{P}(X > x)\mathbb{P}(Y > y).$$

Ein Paar $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ heißt **positive quadrant dependent**, falls für alle $x, y \in \mathbb{R}$ gilt

$$\mathbb{P}(\{X \leq x\} \cap \{Y \leq y\}) \geq \mathbb{P}(X \leq x)\mathbb{P}(Y \leq y).$$

bzw. für alle $x, y \in \mathbb{R}$ gilt

$$\mathbb{P}(\{X > x\} \cap \{Y > y\}) \geq \mathbb{P}(X > x)\mathbb{P}(Y > y).$$

Y heißt **stochastisch wachsend** in X falls für alle $y \in \mathbb{R}$ die Funktion $t_y : \mathbb{R} \rightarrow [0, 1]$ gegeben durch

$$t_y(x) := \mathbb{P}(Y > y \mid X = x), \quad x \in \mathbb{R}$$

monoton wachsend ist.

Y heißt **right-tail increasing** in X , falls für alle $y \in \mathbb{R}$ die Funktion $rt_y : \mathbb{R} \rightarrow [0, 1]$ gegeben durch

$$rt_y(x) := \mathbb{P}(Y > y | X > x), \quad x \in \mathbb{R}$$

monoton wachsend ist.

Y heißt **right-tail increasing** in X , falls für alle $y \in \mathbb{R}$ die Funktion $rt_y : \mathbb{R} \rightarrow [0, 1]$ gegeben durch

$$rt_y(x) := \mathbb{P}(Y > y | X > x), \quad x \in \mathbb{R}$$

monoton wachsend ist.

In ähnlicher Form: Y heißt **left-tail decreasing** in X , falls für alle $y \in \mathbb{R}$ die Funktion $lt_y : \mathbb{R} \rightarrow [0, 1]$ gegeben durch

$$lt_y(x) := \mathbb{P}(Y \leq y | X \leq x), \quad x \in \mathbb{R}$$

monoton fallend ist.

Ein Paar Zufallsvariablen $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ werden als **Associated** bezeichnet falls für alle (komponentenweise) wachsenden Funktionen $f, g : \mathbb{R}^2 \rightarrow \mathbb{R}$ gilt

$$\begin{aligned}\mathbb{E}[f(X, Y)g(X, Y)] &\geq \mathbb{E}[f(X, Y)]\mathbb{E}[g(X, Y)] \\ \iff \text{cov}(f(X, Y), g(X, Y)) &\geq 0.\end{aligned}$$

Ein Paar Zufallsvariablen $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ werden als **Associated** bezeichnet falls für alle (komponentenweise) wachsenden Funktionen $f, g : \mathbb{R}^2 \rightarrow \mathbb{R}$ gilt

$$\begin{aligned}\mathbb{E}[f(X, Y)g(X, Y)] &\geq \mathbb{E}[f(X, Y)]\mathbb{E}[g(X, Y)] \\ \iff \text{cov}(f(X, Y), g(X, Y)) &\geq 0.\end{aligned}$$

Auch als FKG-inequality (nach Fortuin-Kasteleyn-Ginibre, 1971) oder Korrelationsungleichung in der Quantenphysik bekannt.

Ein Paar Zufallsvariablen $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ werden als **Associated** bezeichnet falls für alle (komponentenweise) wachsenden Funktionen $f, g : \mathbb{R}^2 \rightarrow \mathbb{R}$ gilt

$$\begin{aligned}\mathbb{E}[f(X, Y)g(X, Y)] &\geq \mathbb{E}[f(X, Y)]\mathbb{E}[g(X, Y)] \\ \iff \text{cov}(f(X, Y), g(X, Y)) &\geq 0.\end{aligned}$$

Auch als FKG-inequality (nach Fortuin-Kasteleyn-Ginibre, 1971) oder Korrelationsungleichung in der Quantenphysik bekannt.

Ein Paar $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ heißt **total positiv der Ordnung 2** (TP₂), falls die entsprechende Lebesgue-dichte $f : \mathbb{R}^2 \rightarrow [0, \infty)$ TP₂ ist, also es gilt

$$\forall a_1 < b_1, a_2 < b_2 : f(a_1, a_2)f(b_1, b_2) \geq f(a_1, b_2)f(b_1, a_2).$$

Bezeichne für $\mathbf{x} = (x_1, x_2)$ und $\mathbf{y} = (y_1, y_2)$

$$\mathbf{x} \vee \mathbf{y} := (\max(x_1, y_1), \max(x_2, y_2))$$

$$\mathbf{x} \wedge \mathbf{y} := (\min(x_1, y_1), \min(x_2, y_2))$$

das komponentenweise Maximum bzw. Minimum.

Betrachte zu einer $f : \mathbb{R}^2 \rightarrow [0, \infty)$ die Matrizen

$$A_f(\mathbf{x}, \mathbf{y}) := \begin{pmatrix} f(\mathbf{x} \vee \mathbf{y}) & f(\mathbf{x}) \\ f(\mathbf{y}) & f(\mathbf{x} \wedge \mathbf{y}) \end{pmatrix} \in \mathbb{R}^{2 \times 2}, \mathbf{x}, \mathbf{y} \in \mathbb{R}^2$$

Dann kann man auch umformulieren:

Eine positive Funktion $f : \mathbb{R}^2 \rightarrow [0, \infty)$ ist TP_2 , falls für alle $\mathbf{x}, \mathbf{y} \in \mathbb{R}^2$:

$$\det(A_f(\mathbf{x}, \mathbf{y})) = f(\mathbf{x} \wedge \mathbf{y})f(\mathbf{x} \vee \mathbf{y}) - f(\mathbf{x})f(\mathbf{y}) \geq 0$$

Theorem

Die Konzepte PQD, SI, RTI, LTD, A und TP_2 sind invariant gegenüber streng monoton wachsenden Transformationen der Komponenten.

Das heißt z.B. falls (X, Y) PQD ist, so ist auch $(t_1(X), t_2(Y))$ PQD, falls $t_1, t_2 : \mathbb{R} \rightarrow \mathbb{R}$ streng monoton wachsend sind.

Theorem

Die Konzepte PQD, SI, RTI, LTD, A und TP_2 sind invariant gegenüber streng monoton wachsenden Transformationen der Komponenten.

Das heißt z.B. falls (X, Y) PQD ist, so ist auch $(t_1(X), t_2(Y))$ PQD, falls $t_1, t_2 : \mathbb{R} \rightarrow \mathbb{R}$ streng monoton wachsend sind.

Theorem (Hierarchie der Abhängigkeitskonzepte)

- $TP_2 \implies SI \implies RTI \text{ und } LTD.$
- $RTI \text{ oder } LTD \implies A \implies PQD$

Sei $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ ein Paar Zufallsvariablen mit einer TP_2 -Lebesgue-dichte $f : \mathbb{R}^2 \rightarrow \mathbb{R}$.

Es ist zu zeigen:

$$x < x' \Rightarrow \mathbb{P}(Y > y | X = x) \leq \mathbb{P}(Y > y | X = x').$$

Sei $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ ein Paar Zufallsvariablen mit einer TP₂-Lebesgue-dichte $f : \mathbb{R}^2 \rightarrow \mathbb{R}$.

Es ist zu zeigen:

$$x < x' \Rightarrow \mathbb{P}(Y > y | X = x) \leq \mathbb{P}(Y > y | X = x').$$

Definiere $f^X(x) = \int_{-\infty}^{\infty} f(x, y) dy$ (Randdichte) und $f^{Y|x}(y) := f(x, y)/f^X(x)$ (bedingte Dichte)

Sei $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ ein Paar Zufallsvariablen mit einer TP₂-Lebesgue-dichte $f : \mathbb{R}^2 \rightarrow \mathbb{R}$.

Es ist zu zeigen:

$$x < x' \Rightarrow \mathbb{P}(Y > y | X = x) \leq \mathbb{P}(Y > y | X = x').$$

Definiere $f^X(x) = \int_{-\infty}^{\infty} f(x, y) dy$ (Randdichte) und $f^{Y|x}(y) := f(x, y)/f^X(x)$ (bedingte Dichte)

$$\begin{aligned} & \mathbb{P}(Y > y | X = x') - \mathbb{P}(Y > y | X = x) \\ &= \int_y^{\infty} f^{Y|x'}(z) - f^{Y|x}(z) dz \end{aligned}$$

Sei $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ ein Paar Zufallsvariablen mit einer TP₂-Lebesgue-dichte $f : \mathbb{R}^2 \rightarrow \mathbb{R}$.

Es ist zu zeigen:

$$x < x' \Rightarrow \mathbb{P}(Y > y | X = x) \leq \mathbb{P}(Y > y | X = x').$$

Definiere $f^X(x) = \int_{-\infty}^{\infty} f(x, y) dy$ (Randdichte) und $f^{Y|x}(y) := f(x, y)/f^X(x)$ (bedingte Dichte)

$$\begin{aligned} & \mathbb{P}(Y > y | X = x') - \mathbb{P}(Y > y | X = x) \\ &= \int_y^{\infty} f^{Y|x'}(z) - f^{Y|x}(z) dz \\ &= f^X(x)f^X(x') \int_y^{\infty} f^X(x)f(x', z) - f^X(x')f(x, z) dz \end{aligned}$$

Sei $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ ein Paar Zufallsvariablen mit einer TP₂-Lebesgue-dichte $f : \mathbb{R}^2 \rightarrow \mathbb{R}$.

Es ist zu zeigen:

$$x < x' \Rightarrow \mathbb{P}(Y > y | X = x) \leq \mathbb{P}(Y > y | X = x').$$

Definiere $f^X(x) = \int_{-\infty}^{\infty} f(x, y) dy$ (Randdichte) und $f^{Y|x}(y) := f(x, y)/f^X(x)$ (bedingte Dichte)

$$\begin{aligned} & \mathbb{P}(Y > y | X = x') - \mathbb{P}(Y > y | X = x) \\ &= \int_y^{\infty} f^{Y|x'}(z) - f^{Y|x}(z) dz \\ &= f^X(x)f^X(x') \int_y^{\infty} f^X(x)f(x', z) - f^X(x')f(x, z) dz \\ &= f^X(x)f^X(x') \int_y^{\infty} \int_{-\infty}^{\infty} f(x, w)f(x', z) - f(x', w)f(x, z) dw dz \end{aligned}$$

Sei $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ ein Paar Zufallsvariablen mit einer TP₂-Lebesgue-dichte $f : \mathbb{R}^2 \rightarrow \mathbb{R}$.

Es ist zu zeigen:

$$x < x' \Rightarrow \mathbb{P}(Y > y | X = x) \leq \mathbb{P}(Y > y | X = x').$$

Definiere $f^X(x) = \int_{-\infty}^{\infty} f(x, y) dy$ (Randdichte) und $f^{Y|x}(y) := f(x, y)/f^X(x)$ (bedingte Dichte)

$$\begin{aligned} & \mathbb{P}(Y > y | X = x') - \mathbb{P}(Y > y | X = x) \\ &= \int_y^{\infty} f^{Y|x'}(z) - f^{Y|x}(z) dz \\ &= f^X(x)f^X(x') \int_y^{\infty} f^X(x)f(x', z) - f^X(x')f(x, z) dz \\ &= f^X(x)f^X(x') \int_y^{\infty} \int_{-\infty}^y f(x, w)f(x', z) - f(x', w)f(x, z) dw dz \end{aligned}$$

Sei $(X, Y) : \Omega \rightarrow \mathbb{R}^2$ ein Paar Zufallsvariablen mit einer TP₂-Lebesgue-dichte $f : \mathbb{R}^2 \rightarrow \mathbb{R}$.

Es ist zu zeigen:

$$x < x' \Rightarrow \mathbb{P}(Y > y | X = x) \leq \mathbb{P}(Y > y | X = x').$$

Definiere $f^X(x) = \int_{-\infty}^{\infty} f(x, y) dy$ (Randdichte) und $f^{Y|x}(y) := f(x, y)/f^X(x)$ (bedingte Dichte)

$$\begin{aligned} & \mathbb{P}(Y > y | X = x') - \mathbb{P}(Y > y | X = x) \\ &= \int_y^{\infty} f^{Y|x'}(z) - f^{Y|x}(z) dz \\ &= f^X(x)f^X(x') \int_y^{\infty} f^X(x)f(x', z) - f^X(x')f(x, z) dz \\ &= f^X(x)f^X(x') \int_y^{\infty} \int_{-\infty}^y f(x, w)f(x', z) - f(x', w)f(x, z) dw dz \geq 0. \end{aligned}$$

Nun betrachten wir einige Erweiterungen für höher dimensionale Zufallsvektoren

$$\mathbf{T} = (T_1, \dots, T_m) : \Omega \rightarrow \mathbb{R}^m, m > 2,$$

definiert auf geeignetem Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, \mathbb{P})$

Nun betrachten wir einige Erweiterungen für höher dimensionale Zufallsvektoren

$$\mathbf{T} = (T_1, \dots, T_m) : \Omega \rightarrow \mathbb{R}^m, \quad m > 2,$$

definiert auf geeignetem Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, \mathbb{P})$

\mathbf{T} heißt

- positive lower orthant dependent (PLOD), falls für alle $t_1, \dots, t_m \in \mathbb{R}$

$$\mathbb{P} \left(\bigcap_{i=1}^m \{T_i \leq t_i\} \right) \geq \prod_{i=1}^m \mathbb{P}(T_i \leq t_i).$$

- positive upper orthant dependent (PUOD), falls für alle $t_1, \dots, t_m \in \mathbb{R}$

$$\mathbb{P} \left(\bigcap_{i=1}^m \{T_i > t_i\} \right) \geq \prod_{i=1}^m \mathbb{P}(T_i > t_i).$$

Falls PLOD und PUOD zutreffen so heißt \mathbf{T} positive orthant dependent (POD)

\mathbf{T} heißt

- (Multivariate) associated, falls

$$\mathbb{E}[g(\mathbf{T})h(\mathbf{T})] \geq \mathbb{E}[g(\mathbf{T})]\mathbb{E}[h(\mathbf{T})]$$

für alle (komponentenweise) wachsenden Funktionen $g, h : \mathbb{R}^m \rightarrow \mathbb{R}$.

- Multivariate totally positive of order 2 (MTP_2), falls die entsprechende Lebesgue-dichte $f : \mathbb{R}^m \rightarrow [0, \infty)$

$$\forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^m : f(\mathbf{x} \wedge \mathbf{y})f(\mathbf{x} \vee \mathbf{y}) \geq f(\mathbf{x})f(\mathbf{y}).$$

erfüllt.

Bezeichne die Ereignisse:

$$O_i := \{\varphi_i = 0\} = \{T_i \notin \Gamma_i\}, \quad i = 1, \dots, m,$$

die zur Annahme der Nullhypothese führen.

Falls ein Vektor von Teststatistiken \mathbf{T} MTP_2 ist, so gilt für alle $2 \leq k \leq m$

$$\mathbb{P}_{\vartheta^*}(O_i | O_{i-1}, \dots, O_1) \geq \mathbb{P}_{\vartheta^*}(O_i | O_{i-1}, \dots, O_{i-k+1}), \quad i \geq k$$

Bezeichne die Ereignisse:

$$O_i := \{\varphi_i = 0\} = \{T_i \notin \Gamma_i\}, \quad i = 1, \dots, m,$$

die zur Annahme der Nullhypothese führen.

Falls ein Vektor von Teststatistiken \mathbf{T} MTP_2 ist, so gilt für alle $2 \leq k \leq m$

$$\mathbb{P}_{\vartheta^*}(O_i | O_{i-1}, \dots, O_1) \geq \mathbb{P}_{\vartheta^*}(O_i | O_{i-1}, \dots, O_{i-k+1}), \quad i \geq k$$

Und damit für fixes k :

$$\mathbb{P}_{\vartheta^*} \left(\bigcap_{i=1}^m O_i \right) \geq \mathbb{P}_{\vartheta^*}(O_1, \dots, O_k) \prod_{i=k}^m \mathbb{P}_{\vartheta^*}(O_i | O_{i-1}, \dots, O_{i-k+1}) =: \beta_k$$

Für globales Signifikanzniveau $\alpha \in (0, 1)$ seien die Ablehnregionen $\Gamma_i \equiv \Gamma_i(\alpha)$ so gewählt, dass für Ereignisse $O_i \equiv O_i(\alpha)$ gilt:

$$\beta_k = 1 - \alpha$$

Mithilfe der Annahme für Einschrittprozeduren also:

$$\forall \vartheta \in \Theta : \text{FWER}_{\vartheta}(\varphi) \leq 1 - \beta_k = \alpha$$

Für globales Signifikanzniveau $\alpha \in (0, 1)$ seien die Ablehnregionen $\Gamma_i \equiv \Gamma_i(\alpha)$ so gewählt, dass für Ereignisse $O_i \equiv O_i(\alpha)$ gilt:

$$\beta_k = 1 - \alpha$$

Mithilfe der Annahme für Einschrittprozeduren also:

$$\forall \vartheta \in \Theta : \text{FWER}_{\vartheta}(\varphi) \leq 1 - \beta_k = \alpha$$

Lokale Signifikanzniveaus: $\alpha_{\text{loc},i} = \mathbb{P}_{\vartheta^*}(T_i \in \Gamma_i)$

Eine effektive Anzahl an Tests im Šidák-Korrekturformat ergibt sich implizit als Lösung der Gleichung:

$$1 - (1 - \alpha)^{m_{\text{eff}}} \stackrel{!}{=} 1 - \prod_{i=1}^m (1 - \alpha_{\text{loc},i}).$$

Vielen Dank für die Aufmerksamkeit.

Literaturhinweis:

Harry Joe: "Multivariate models and dependence concepts", Chapman Hall 1997