

## Beschreibung mehrdimensionaler Datensätze

Gegeben: Datenmatrix  $\mathbf{X}_{n \times p}$

Mittelwertsvektor

$$\bar{\mathbf{x}}_{p \times 1} = \mathbf{X}'_{p \times n} \mathbf{1}_{n \times 1} / n$$

Abweichungsmatrix

$$\mathbf{A}_{n \times p} = \mathbf{X}_{n \times p} - \mathbf{1}_{n \times 1} \bar{\mathbf{x}}'_{1 \times p}$$

SSCP-Matrix der Abweichungen

$$\mathbf{A}'_{p \times n} \mathbf{A}_{n \times p}$$

Kovarianzmatrix

$$\mathbf{S}_{p \times p} = \frac{1}{n-1} \mathbf{A}'_{p \times n} \mathbf{A}_{n \times p}$$

Korrelationsmatrix

$$\mathbf{R}_{p \times p} = \mathbf{S}_{p \times p} / \mathbf{s}_{p \times 1} \mathbf{s}'_{1 \times p}$$

## Lineare Regression

Modell

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad (\boldsymbol{\beta} = [\beta_0 \beta_1 \dots \beta_p]' \text{ und } \mathbf{x}_0 = \mathbf{1}_n)$$

Zielkriterium

$$RSS = \mathbf{e}'\mathbf{e} = \sum (y_i - \hat{y}_i)^2 \rightarrow \text{Min}$$

Schätzung der Regressionsparameter

$$\mathbf{b} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$$

$$[b_1 \dots b_p]' = \mathbf{S}_{XX}^{-1} \mathbf{s}_{Xy} \quad b_0 = \bar{y} - \bar{\mathbf{x}}'\mathbf{b}$$

Standardisierte Gewichte

$$\mathbf{b}^* = \mathbf{R}_{XX}^{-1} \mathbf{r}_{Xy} \quad b_i^* = b_i \frac{s_i}{s_y}$$

Hat-Matrix

$$\mathbf{H} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'$$

Gefittete Werte

$$\hat{\mathbf{y}} = \mathbf{X}\mathbf{b} = \mathbf{H}\mathbf{y}$$

Punktweises Konfidenzintervall an der Stelle  $\mathbf{x}$

$$\mathbf{x}'\mathbf{b} \pm t_{n-p-1; 1-\alpha/2} \cdot s \cdot \sqrt{\mathbf{x}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}}$$

Toleranz- bzw. Vorhersageintervall an der Stelle  $\mathbf{x}$

$$\mathbf{x}'\mathbf{b} \pm t_{n-p-1; 1-\alpha/2} \cdot s \cdot \sqrt{1 + \mathbf{x}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}}$$

Test für den Vergleich zweier hierarchischer Modelle

$$F = \frac{(R_{u+v}^2 - R_u^2) / v}{(1 - R_{u+v}^2) / (n - u - v - 1)} \quad df_1 = v \quad df_2 = n - u - v - 1$$

Mallow's  $C_p$ -Statistik

$$C_p = (n - p - 1) \left( \frac{MSE_p}{MSE_{full}} - 1 \right) + (p + 1)$$

Standardschätzfehler

$$s = \sqrt{\frac{RSS}{n-p-1}}$$

Standardfehler der Parameterschätzungen

$$SE(\mathbf{b}) = s \cdot \text{diag}(\sqrt{(\mathbf{X}'\mathbf{X})^{-1}})$$

Multipler Korrelationskoeffizient

$$R^2 = \mathbf{b}^*'\mathbf{r}_y = \mathbf{r}_y'\mathbf{R}^{-1}\mathbf{r}_y$$

Modelltest

$$F = \frac{\sum (\hat{y}_i - \bar{y})^2 / p}{\sum (y_i - \hat{y}_i)^2 / (n - p - 1)} = \frac{R^2 / p}{(1 - R^2) / (n - p - 1)}$$

Konfidenzbereich für die Regressionsgerade

$$f(\mathbf{x}) = \mathbf{x}'\mathbf{b} \pm \sqrt{p F_{p, n-p-1; 1-\alpha}} \cdot s \cdot \sqrt{\mathbf{x}'(\mathbf{X}'\mathbf{X})^{-1}\mathbf{x}}$$

Akaike's Informationskriterium

$$AIC = n \ln \left( \frac{RSS_p}{n} \right) + 2(p + 1)$$

### Einflussreiche Datenpunkte

$$e^{(-i)} = y_i - \hat{y}_i^{(-i)} \quad (\text{Deleted Residuals})$$

$$DFFITS_i = \frac{\hat{y}_i - \hat{y}_i^{(-i)}}{(s^{(-i)})^2 h_{ii}}$$

$$D_i = \frac{(\hat{y} - \hat{y}^{(-i)})'(\hat{y} - \hat{y}^{(-i)})}{p \cdot s^2} \quad (\text{Cook's Abstand})$$

$$DFBETAS_{ki} = \frac{\hat{\beta}_k - \hat{\beta}_k^{(-i)}}{s^{(-i)} \sqrt{c_{kk}}}$$

### Multivariate multiple Regression

#### Zielkriterium

$$\|\mathbf{Y} - \mathbf{X}\mathbf{B}\|^2 \rightarrow \text{Min}$$

#### Modelltest

$$\Lambda = \frac{|\mathbf{S}|}{|\mathbf{S}_{XX}| |\mathbf{S}_{YY}|}$$

#### Schätzung der Regressionsparameter

$$\mathbf{B} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}$$

#### Bartlett's Approximation

$$V = -[(n-1) - (p+q)/2] \ln \Lambda \quad \text{mit} \quad df = q(p-1)$$

### MANOVA

#### Hotelling's $T^2$ für zwei unabhängige Stichproben

$$T^2 = \frac{n_1 n_2}{n_1 + n_2} (\bar{\mathbf{y}}_1 - \bar{\mathbf{y}}_2)' \mathbf{S}^{-1} (\bar{\mathbf{y}}_1 - \bar{\mathbf{y}}_2) = \frac{n_1 n_2 (n_1 + n_2 - 2)}{n_1 + n_2} (\bar{\mathbf{y}}_1 - \bar{\mathbf{y}}_2)' \mathbf{W}^{-1} (\bar{\mathbf{y}}_1 - \bar{\mathbf{y}}_2)$$

$$F = \frac{(n_1 + n_2 - 2) - (q-1)}{q(n_1 + n_2 - 2)} T^2 = \frac{n_1 + n_2 - q - 1}{q} \frac{T^2}{n_1 + n_2 - 2} \quad df_1 = q \quad df_2 = n_1 + n_2 - q - 1$$

#### Mahalanobis-Distanz

$$D^2(\mathbf{x}_1, \mathbf{x}_2) = (\mathbf{x}_1 - \mathbf{x}_2)' \mathbf{S}^{-1} (\mathbf{x}_1 - \mathbf{x}_2)$$

#### Wilks' Lambda

$$\Lambda = \frac{|\mathbf{W}|}{|\mathbf{T}|} = \frac{|\mathbf{W}|}{|\mathbf{B} + \mathbf{W}|} = \frac{1}{|\mathbf{B}\mathbf{W}^{-1} + \mathbf{I}|} = \prod \frac{1}{1 + \lambda_i} \quad (\lambda_i \text{ Eigenwerte von } \mathbf{B}\mathbf{W}^{-1})$$

#### Bartlett's Chiquadrat

$$\chi^2 = -[(n-1) - (q+m)/2] \ln \Lambda \quad df = q(m-1)$$

#### Roy's Kriterium des größten Eigenwerts

$$\frac{\lambda_{\max}}{1 + \lambda_{\max}}$$

#### Hotelling-Lawley Spur

Summe der Eigenwerte (Spur) von  $\mathbf{B}\mathbf{W}^{-1}$

#### Pillai-Bartlett Spur

Summe der Eigenwerte (Spur) von  $\mathbf{B}\mathbf{T}^{-1}$

#### Test eines linearen Kontrasts

$$\hat{\Psi} = \sum c_j \bar{\mathbf{y}}_j \quad T^2 = \frac{1}{\sum c_j^2 / n_j} \hat{\Psi}' \mathbf{S}^{-1} \hat{\Psi} \quad F = \frac{n-m-q+1}{(n-m)q} T^2 \quad df_1 = q \quad df_2 = n-m-q+1$$

#### Box' M

$$M = (n-q) \ln |\mathbf{S}| - \sum (n_j - 1) \ln |\mathbf{S}_j|$$

## Diskriminanzanalyse

Zielkriterium

$$\lambda = \frac{\mathbf{v}'\mathbf{B}\mathbf{v}}{\mathbf{v}'\mathbf{W}\mathbf{v}} \rightarrow \text{Max}$$

Lösungsansatz

$$(\mathbf{W}^{-1}\mathbf{B})\mathbf{V} = \mathbf{V} \text{diag}(\boldsymbol{\lambda}) \quad \text{bzw.} \quad (\mathbf{W}^{-1/2}\mathbf{B}\mathbf{W}^{-1/2})\mathbf{Q} = \mathbf{Q} \text{diag}(\boldsymbol{\lambda}) \quad \text{mit} \quad \mathbf{V} = \mathbf{W}^{-1/2}\mathbf{Q}$$

Test der Diskriminanzfunktionen

$$\Lambda = \prod_{i=j}^r \frac{1}{1+\lambda_i} \quad (j = 1, \dots, r) \quad \text{Bartlett:} \quad \chi^2 = [n-1 - (q+m)/2] \ln \Lambda \quad df = q(m-1)$$

Diskriminanzscores

$$\mathbf{F} = \mathbf{X}\mathbf{V}$$

Gruppenzentrum

$$\bar{\mathbf{f}}^{(g)} = (\bar{\mathbf{x}}^{(g)'} \mathbf{V})'$$

## PCA und FA

Grundgleichung der Faktorenanalyse

$$\mathbf{X} = \mathbf{F}\mathbf{A}' + \boldsymbol{\varepsilon} \quad X_{ik} = \alpha_{k1}F_{i1} + \alpha_{k2}F_{i2} + \dots + \alpha_{kr}F_{ir} + \varepsilon_{ik}$$

Diagonalisierung von  $\mathbf{S}$  (Kovarianz- bzw. Korrelationsmatrix)

$$\mathbf{S} = \mathbf{V}\boldsymbol{\Lambda}\mathbf{V}' \quad (\mathbf{V}: \text{normierte Eigenvektoren; } \boldsymbol{\Lambda}: \text{Diagonalmatrix der Eigenwerte})$$

Kovarianzmatrix der Faktoren

$$\boldsymbol{\Lambda} = \mathbf{V}'\mathbf{S}\mathbf{V} = \mathbf{A}'\mathbf{A}$$

Fundamentaltheorem

$$\mathbf{R} = \mathbf{A}\mathbf{A}' + \boldsymbol{\Psi} \quad \mathbf{R}_h = \mathbf{A}\mathbf{A}' \quad (\mathbf{R}_h: \text{reduzierte Korrelationsmatrix})$$

Varianz der Variable  $k$

$$\sigma_k^2 = h_k^2 + u_k^2 = h_k^2 + b_k^2 + \varepsilon_k^2 = 1 \quad (h_k^2: \text{Kommunalität; } u_k^2: \text{„Uniqueness“})$$

Faktorladungen

$$\mathbf{A} = \mathbf{V}\boldsymbol{\Lambda}^{1/2} \quad (\mathbf{V}: \text{normierte Eigenvektoren; } \boldsymbol{\Lambda}: \text{Diagonalmatrix der Eigenwerte})$$

Orthogonale Rotation

$$\mathbf{B} = \mathbf{A}\mathbf{T} \quad (\mathbf{T}: \text{orthonormale Transformationsmatrix})$$

Transformationsmatrix für eine Rotation (zweidimensionaler Fall)

$$\mathbf{T} = \begin{bmatrix} \cos(\varphi) & -\sin(\varphi) \\ \sin(\varphi) & \cos(\varphi) \end{bmatrix} \quad (\varphi: \text{Drehwinkel gegen den Uhrzeigersinn})$$

Transformationsmatrix für eine Spiegelung an der ersten Achse (zweidimensionaler Fall)

$$\mathbf{T} = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}$$