

Statistik IV für Nebenfachstudierende

3.2. Grundkonzept der multivariaten linearen Regression

Prof. Dr. Andreas Mayr

Institut für Statistik, LMU München

Sommersemester 2017

Grundidee

- Bis jetzt hatten wir als Zielgröße Beobachtungen

$$\underline{y} = (y_1, \dots, y_n)^\top.$$

- Dazu p Einflussgrößen (multiple lineare Regression).
- Führt zu p verschiedenen Koeffizienten $\underline{\beta} = (\beta_0, \beta_1, \dots, \beta_p)^\top$.

- Jetzt multivariate Zielgröße der Dimension q :

$$\underline{y}_i = (y_{i1}, \dots, y_{iq})^\top$$

- Führt zu $p \cdot q$ verschiedenen Koeffizienten:
- Für jeden der q Zielgrößen ein Koeffizientenvektor,

$$\underline{\beta}_{(1)}, \dots, \underline{\beta}_{(q)}.$$

- ▶ Ziel: Gemeinsame Analyse, gemeinsame Hypothesentests.

Daten:

$(\underline{y}_i, \underline{x}_i)$, $i = 1, \dots, n$ mit

$$\underline{y}_i^\top = (y_{i1}, \dots, y_{iq})$$

$$\underline{x}_i^\top = (1, x_{i1}, \dots, x_{ip})$$

- q abhängige Variablen
- p konstante und fixe Kovariablen (ohne Intercept)

Klassisches lineares Modell

$$y_{ij} = \mathbf{x}_i^\top \underline{\beta}_{(j)} + \varepsilon_{ij}, \quad i = 1, \dots, n, \quad j = 1, \dots, q,$$

Matrixdarstellungen:

Vektorielle Form

$$\begin{pmatrix} y_{i1} \\ \vdots \\ y_{iq} \end{pmatrix} = \begin{pmatrix} \underline{x}_i^\top & & \\ & \underline{x}_i^\top & \\ & & \ddots \\ & & & \underline{x}_i^\top \end{pmatrix} \begin{pmatrix} \underline{\beta}_{(1)} \\ \vdots \\ \underline{\beta}_{(q)} \end{pmatrix} + \begin{pmatrix} \varepsilon_{i1} \\ \vdots \\ \varepsilon_{iq} \end{pmatrix}$$

bzw.

$$\underline{y}_i = \underline{\underline{X}}_i \underline{\beta} + \epsilon_i$$

und als Gesamtmodell

$$\underline{y} = \underline{\underline{X}} \underline{\beta} + \epsilon.$$

wobei

$$\underline{\beta}_{(j)}^\top = (\beta_{0j}, \beta_{1j}, \dots, \beta_{pj}), \quad \underline{\beta}^\top = (\underline{\beta}_{(1)}^\top, \dots, \underline{\beta}_{(q)}^\top).$$

Multivariate Formulierung I

$$\begin{pmatrix} \underline{y}_1^\top \\ \vdots \\ \underline{y}_n^\top \end{pmatrix} = \begin{pmatrix} \underline{x}_1^\top \\ \vdots \\ \underline{x}_n^\top \end{pmatrix} (\underline{\beta}_{(1)}, \dots, \underline{\beta}_{(q)}) + \begin{pmatrix} \underline{\epsilon}_1^\top \\ \vdots \\ \underline{\epsilon}_n^\top \end{pmatrix}$$

Multivariate Formulierung II

$$(\underline{y}_{(1)}, \dots, \underline{y}_{(q)}) = \begin{pmatrix} \underline{x}_1^\top \\ \vdots \\ \underline{x}_n^\top \end{pmatrix} (\underline{\beta}_{(1)}, \dots, \underline{\beta}_{(q)}) + (\boldsymbol{\epsilon}_{(1)}, \dots, \boldsymbol{\epsilon}_{(q)})$$

Als Gesamtmodell

$$\mathbf{Y} = \underline{\underline{\mathbf{X}}}_0 \mathbf{B} + \mathbb{E}$$

$$\text{mit } \underline{\underline{\mathbf{X}}}_0 = \begin{pmatrix} \underline{\mathbf{x}}_1^\top \\ \vdots \\ \underline{\mathbf{x}}_n^\top \end{pmatrix}, \underline{\underline{\boldsymbol{\beta}}}_{(j)} = \begin{pmatrix} \beta_{0j} \\ \vdots \\ \beta_{pj} \end{pmatrix}, \underline{\underline{\mathbf{y}}}_{(j)} = \begin{pmatrix} y_{1j} \\ \vdots \\ y_{nj} \end{pmatrix}, \underline{\underline{\boldsymbol{\epsilon}}}_{(j)} = \begin{pmatrix} \epsilon_{1j} \\ \vdots \\ \epsilon_{nj} \end{pmatrix}.$$

Beispiele ?

Verteilungsannahme

- $\text{Cov}(\underline{y}_i) = \underline{\underline{\Sigma}}$
- Normalverteilung in Struktur
- Unkorreliertheit der Beobachtungen
- Zusammen:

Annahmen Störterm

$$(1) \mathbb{E}(\boldsymbol{\epsilon}_i) = \mathbf{0}$$

$$(2) \text{cov}(\boldsymbol{\epsilon}_i) = \underline{\underline{\Sigma}} \quad , \quad i = 1, \dots, n$$

$$\text{cov}(\boldsymbol{\epsilon}_i, \boldsymbol{\epsilon}_j) = \mathbf{0} \quad , \quad i \neq j$$

$$\Rightarrow \text{cov}(\boldsymbol{\epsilon}_{(s)}, \boldsymbol{\epsilon}_{(t)}) = \sigma_{st} \mathbf{I}, \quad s \neq t$$

$$(3) \text{ Normalverteilung: } \boldsymbol{\epsilon}_i \sim N(\mathbf{0}, \underline{\underline{\Sigma}})$$

Kleinste-Quadrate-Schätzung

$$\sum_{j=1}^q (\underline{y}_{(j)} - \underline{X}_{=0} \underline{\beta}_{(j)})^\top (\underline{y}_{(j)} - \underline{X}_{=0} \underline{\beta}_{(j)}) \rightarrow \min$$

Lösung (voller Rang von \underline{X}):

$$\hat{\underline{\beta}}_{(j)} = (\underline{X}_{=0}^\top \underline{X}_{=0})^{-1} \underline{X}_{=0}^\top \underline{y}_{(j)} \quad \text{bzw.} \quad \hat{\mathbf{B}} = (\underline{X}_{=0}^\top \underline{X}_{=0})^{-1} \underline{X}_{=0}^\top \mathbf{Y}$$

Als Vektor

$$\hat{\underline{\beta}} = \text{BlockDiag}\{(\underline{X}_{=0}^\top \underline{X}_{=0})^{-1} \underline{X}_{=0}^\top\} \underline{y}_0 \quad \text{oder} \quad \hat{\underline{\beta}} = (\underline{X}^\top \underline{X})^{-1} \underline{X}^\top \underline{y}.$$

mit

$$\underline{y}_0^\top = (\underline{y}_{(1)}^\top, \dots, \underline{y}_{(q)}^\top), \quad \underline{y}^\top = (\underline{y}_1^\top, \dots, \underline{y}_n^\top).$$

Kleinste-Quadrate-Schätzung

Anmerkung:

- In KQ-Schätzung fließt $\underline{\underline{\Sigma}}$ nicht ein.
- $\hat{\underline{\beta}}_{(q)}$ hängt nicht von $\underline{\underline{\Sigma}}$ ab.
- KQ-Schätzung identisch mit separater Optimierung!

Warum dann das Ganze?

- ▶ Simultane multivariate Tests (z.B., MANOVA)

Schätzung der Kovarianz

$$\hat{\underline{\Sigma}} = \frac{1}{n-p-1} \sum_{i=1}^n (\underline{y}_i - \underline{X}_i \hat{\underline{\beta}})(\underline{y}_i - \underline{X}_i \hat{\underline{\beta}})^\top$$

$$\hat{\underline{\Sigma}} = \frac{1}{n-p-1} \mathbb{E}^\top \mathbb{E}$$

wobei

$$\mathbb{E} = \mathbf{Y} - \underline{X}_0 \hat{\mathbf{B}} \text{ Residuenmatrix.}$$

Gauß-Markov-Theorem

$$(1) \mathbb{E}(\hat{\mathbf{B}}) = \mathbf{B}, \quad \mathbb{E}(\hat{\underline{\underline{\Sigma}}}) = \underline{\underline{\Sigma}}$$

$$(2) \text{cov}(\hat{\beta}_{(i)}, \hat{\beta}_{(j)}) = \sigma_{ij}(\underline{\underline{\mathbf{X}}}_0^T \underline{\underline{\mathbf{X}}}_0)^{-1}$$

(3) $\hat{\mathbf{B}}$ ist BLUE

Weiter gilt mit Normalverteilungsannahme

(4) $\hat{\mathbf{B}}$ ist normalverteilt

$$(5) \mathbf{Q}_e = \hat{\mathbb{E}}^T \hat{\mathbb{E}} \sim W_p(\underline{\underline{\Sigma}}, n - p - 1)$$

(6) $\hat{\mathbf{B}}$ und $\hat{\underline{\underline{\Sigma}}}$ sind unabhängig.