

# Statistik IV für Nebenfachstudierende

## 1. Grundlagen

Andreas Mayr

Institut für Statistik, LMU München

Sommersemester 2017

# Organisatorisches

## Vorlesungen

- **Montag** (ganzes Semester)  
12:15 – 13:45 , A120
- **Mittwoch** (bis Mitte Juni)  
14:15 – 15:45, A213

## Übung (Leitung: M. Schneider)

- **Donnerstag**  
12:15 – 13:45, A120

## Klausur

- **Mittwoch, 26.07.2017 (geplant)**  
14:00 – 16:00

# Übersicht

- ① Grundlagen
- ② Schätzen und Testen
- ③ Multivariate lineare Regression
- ④ Mehrkategoriale Regression
- ⑤ Diskriminanzanalyse, Klassifikation
- ⑥ Clusteranalyse

# 1. Grundlagen

# 1. Datenmatrix

$$\underline{\underline{X}} = \begin{pmatrix} x_{11} & \cdots & x_{1p} \\ \vdots & & \vdots \\ x_{n1} & \cdots & x_{np} \end{pmatrix}$$

$i$ -ter Beobachtungsvektor:

$$\underline{x}_i = \quad \underline{\underline{X}} =$$

$j$ -ter Vektor, zur  $j$ -ten Variablen:

$$\underline{x}_{.j} =$$

$$\underline{\underline{X}} =$$

Zusammen:

$$\underline{\underline{X}} =$$

$$=$$

## Zufallsvariablen

Meist: Man beobachtet zufällig, unabhängig die **Zufallsvariablen**

$X_1, \dots, X_p$ . Dadurch werden die Spalten der Matrix generiert.

## 2. Mehrdimensionale Zufallsvariablen

**Eindimensional:** Wie wird der Zufall charakterisiert?

- Zugrunde liegende Verteilung, unbekannt aber vorhanden.
- Dichte auf Träger
  - diskret
  - stetig
- Alternative: Verteilungsfunktion



## Mehrdimensional: ► Zufallsvektor

$$\underline{x} =$$

- Dichte auf Träger

- diskret:

$$f(\underline{x}) = f(x_1, \dots, x_p) =$$

- stetig: Gemeinsame Wahrscheinlichkeit

$$\mathbb{P}(X_1 \in [a_1, b_1], X_2 \in [a_2, b_2], \dots) =$$

- Alternative: Verteilungsfunktion:

$$F(x_1, \dots, x_p) = \mathbb{P}(X_1 \leq x_1, \dots, X_p \leq x_p) =$$

$$f(\underline{x}) =$$

## Erwartungswertvektor:

$$\underline{\mu} = E(\underline{X}) =$$

### Erwartungswert

$E(X)$  bzw.  $E(\underline{X})$  sind **feste** Größen (fixe Parameter), keine Zufallsvariablen mehr.

### 3. Varianz - Kovarianz - Struktur

$$\sigma_{ij} = \text{Cov}(X_i, X_j) =$$

$$\sigma_{ii} = \text{Cov}(X_i, X_i) =$$

$$\sigma_{ii} = \sigma_i^2$$

## Kovarianzmatrix

$$\underline{\underline{\Sigma}} =$$

## Schreibweise

$$\underline{\underline{\Sigma}} = \text{Cov}(\underline{X}) = \mathbb{E} \left( (\underline{X} - \underline{\mu})(\underline{X} - \underline{\mu})^T \right) =$$

## Inhaltlich interessanter: Korrelation

$$r_{ij} = \frac{\text{Cov}(X_i, X_j)}{\sqrt{\text{Var}(X_i)}\sqrt{\text{Var}(X_j)}}$$

## Korrelationsmatrix

$$R = (r_{ij}) =$$



## Kovarianz zwischen zwei Vektoren

$$\underline{X} = \begin{pmatrix} x_1 \\ \vdots \\ x_p \end{pmatrix}$$

$$\underline{Y} = \begin{pmatrix} y_1 \\ \vdots \\ y_q \end{pmatrix}$$

$$\underline{\underline{\Sigma}}_{X,Y} = \text{Cov}(X, Y) =$$

## Regeln:

Zufallsvektoren  $\underline{X}$  und  $\underline{Y}$ .

- $\mathbb{E}(\underline{X} + \underline{Y}) =$
- $\mathbb{E}(\underline{A} \underline{X} + \underline{b}) =$
- $\text{Cov}(\underline{A} \underline{X} + \underline{b}) =$

## Spezialfälle:

- $\text{Cov}(\underline{X}, \underline{X}) = \text{Cov}(\underline{X})$
- $\text{Cov}(\underline{X}, \underline{Y}) = \text{Cov}(\underline{X}, \underline{Y})^\top$
- $\text{Cov}(\underline{a}^\top \underline{X}) =$

## Eigenschaften:

- $\underline{\underline{\Sigma}} = \text{Cov}(\underline{X}) =$ 
  - ① symmetrische Matrix
  - ② nicht negativ definit

Matrix  $\underline{\underline{\Sigma}}$  ist nicht negativ definit g.d.w.:

- $\underline{a}^\top \underline{\underline{\Sigma}} \underline{a} \geq 0 \quad \forall \underline{a}$

## 4. Normalverteilung

$p = 1$ :

$$\text{Dichte } f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

$$p > 1: \underline{x} = (x_1, \dots, x_p)^\top$$

$$\text{Dichte } f(\underline{x}) = \frac{1}{(2\pi)^{\frac{1}{2}} \underline{\underline{\Sigma}}^{\frac{1}{2}}} \exp\left(-\frac{1}{2}(\underline{x} - \underline{\mu})^\top \underline{\underline{\Sigma}}^{-1}(\underline{x} - \underline{\mu})\right)$$

## 5. Standardisierung eines Zufallsvektors

mit  $\mu = \mathbb{E}(\underline{x})$  und  $\underline{\underline{\Sigma}} = \text{Cov}(\underline{x})$ , beliebig verteilt.

- $p = 1$ :

$$z = \frac{x - \mu}{\sigma} \Rightarrow \mathbb{E}(z) = 0, \quad \text{Var}(z) = 1$$

- $p > 1$ :

" $\frac{x-\mu}{\underline{\underline{\Sigma}}}$ "  $\rightarrow$  Richtiger Gedanke, **falsche** Notation!

Notwendig ist Wurzel aus  $\underline{\underline{\Sigma}}$ :

- Voraussetzung  $\underline{\underline{\Sigma}}$  pos.definit, d.h

$$\underline{a}^\top \underline{\underline{\Sigma}} \underline{a} > 0 \quad \forall \underline{a} \neq \underline{0}$$

- Dann existiert eine symmetrische Matrix  $\underline{\underline{\Sigma}}^{\frac{1}{2}}$ , so dass

$$\underline{\underline{\Sigma}} = \underline{\underline{\Sigma}}^{\frac{1}{2}} \underline{\underline{\Sigma}}^{\frac{1}{2}}$$

- Und für  $\underline{\underline{\Sigma}}^{-1}$  gilt:

$$\underline{\underline{\Sigma}}^{-1} = \underline{\underline{\Sigma}}^{-\frac{1}{2}} \underline{\underline{\Sigma}}^{-\frac{1}{2}}$$



## Standardisieren von multiv. ZV

$$\underline{Z} = \underline{\Sigma}^{-\frac{1}{2}}(\underline{x} - \underline{\mu}),$$

weil

$$\mathbb{E}(\underline{Z}) = \underline{\Sigma}^{-\frac{1}{2}}(\mathbb{E}(\underline{x}) - \underline{\mu}) = \mathbf{0}$$

$$\begin{aligned}\text{Cov}(\underline{Z}) &= \underline{\Sigma}^{-\frac{1}{2}} \underline{\Sigma} \underline{\Sigma}^{-\frac{1}{2}} \\ &= \underline{\Sigma}^{-\frac{1}{2}} \underline{\Sigma}^{\frac{1}{2}} \underline{\Sigma}^{\frac{1}{2}} \underline{\Sigma}^{-\frac{1}{2}} = \underline{\mathbf{I}}\end{aligned}$$

**Graphisch:**

# Aussagen

Wenn  $X \sim N(\underline{\mu}, \underline{\Sigma})$ :

$$(1) \underline{Y} = \underline{A} \underline{x} + \underline{a}$$

- Es gilt:

$$\underline{Y} \sim N(\underline{A} \underline{\mu} + \underline{a}, \underline{A} \underline{\Sigma} \underline{A}^T)$$

- Daraus folgt:

## (2) Bedingte Verteilung

- Zwei Variablengruppen

$\underline{x} =$

$\underline{y} =$

Gesucht ist Verteilung von  $\underline{Y}|\underline{X}$

Wenn  $(\underline{Y}, \underline{X})$  gemeinsam normalverteilt, dh.

- Bedingte Dichte für  $\underline{Y}|\underline{X}$ , d.h

$$f_{Y|X}(\underline{y}|\underline{x}) = \frac{f(\underline{y}, \underline{x})}{f_x(\underline{x})}$$

folgt

$$\underline{Y}|\underline{X} \sim N(\underline{\mu}_{Y|X}, \underline{\Sigma}_{Y|X})$$

wieder normalverteilt mit

$$\underline{\mu}_{Y|X} = \underline{\mu}_y + \underline{\Sigma}_{yx} \underline{\Sigma}_x^{-1} (\underline{x} - \underline{\mu}_x)$$

$$\underline{\Sigma}_{Y|X} = \underline{\Sigma}_y - \underline{\Sigma}_{yx} \underline{\Sigma}_x^{-1} \underline{\Sigma}_{xy}$$

**Beispiel:**  $p = q = 1$