

DGFF-Kolleg: Regressionsanalyse

17. Mai 2024

Bastian Fuchs

bastian.fuchs@rub.de




Foto: © Universität Bielefeld

Übersicht


- Einfache lineare Regression
- Regressionsgleichung
- Methode der kleinsten Quadrate
- Determinationskoeffizient R^2
- Standardisiertes Regressionsgewicht β
- Ausblick: Multiple Regression

Vorbereitung

- Kapitel 13 (S. 209-214) in Hanna & Dempster (2017)
- 4.3. Einfache lineare Regression (S. 105-118) in Rasch et al. (2021)
- Video zur Inferenzstatistik (DGFF-Kolleg am 23.06.2023, Prof. Dr. Dominik Rumlich)
→ *Inferenzstatistik: Zusammenhänge (Regression)* (ab 23:24 Min. / Folie 33)

Einfache lineare Regression


- **Korrelation** (Zusammenhang) → **Regression** (Vorhersage)



Bildquelle 1

- **Korrelation:** Es besteht ein starker positiver **Zusammenhang** zwischen der Anzahl der Übungen und den Testergebnissen der SuS.
- **Regression:** Schüler A hat 5 Übungen gemacht und wird im Test 70 Punkte bekommen (**Vorhersage**).

Einfache lineare Regression




Bildquelle 1

- **Ziel:** “auf der Grundlage von Korrelationen die bestmögliche **Vorhersage** für eine Variable zu bestimmen“ (Sedlmeier & Renkewitz, 2018, S. 246)
- Eine Variable (*Kriterium*) wird durch eine andere Variable (*Prädiktor*) **vorhergesagt**
- **Abhängigkeit** einer Variable von der anderen bzw. **Einfluss** einer Variable auf die andere Variable
- Warum *einfache* Regression? → nur **1** Prädiktor
- Warum *lineare* Regression? → **linearer** Zusammenhang zw. Prädiktor und Kriterium (Rasch et al., 2021, S. 105)

Regressionsgleichung

- **Ziel:** eine Variable (*Kriterium*) durch eine andere Variable (*Prädiktor*) vorhersagen
- Diese Vorhersage basiert auf einer **Regressionsgleichung**




Bildquelle 1

„Das Ziel dieses Verfahrens ist es, den stochastischen Zusammenhang zwischen zwei Variablen durch eine **lineare Funktion** wiederzugeben. Anschaulich bedeutet dies, dass die Punktwolke durch eine **einzigste, möglichst repräsentative Gerade** ersetzt wird. Dies gelingt natürlich umso besser, je enger die Punktwolke ist, also je höher die beiden Merkmale tatsächlich miteinander korrelieren.“

Rasch et al., 2021, S. 106

- Testergebnis $\text{Schüler A} = b * \text{Anzahl der Übungen}_{\text{Schüler A}} + a$

Methode der kleinsten Quadrate



n = 30

Fit your own line

y =

Display line of best fit

r = 0.756

y = 0.713x + 2.105

Add Points

Remove Points

Move Points

Move Your Fit Line

Show Residuals

Set Window

Bildquelle 2

- Wie entsteht die Regressionsgleichung?
- Residuen müssen **möglichst klein** sein
- **Methode der kleinsten Quadrate:**
Minimierung der Summe der (quadrierten) Residuen

$$\sum_{i=1}^n (y_i - \hat{y}_i)^2 = \min$$

tatsächlicher Messwert vorhergesagter Wert

Bildquelle 1

Determinationskoeffizient R^2

Determinationskoeffizient $\rightarrow R^2 = r^2_{(x,y)} = \frac{S^2_{\hat{y}}}{S^2_y}$

\leftarrow Regressionsvarianz „erklärte Varianz“
 \leftarrow Gesamtvarianz

quadierte Korrelation der Variablen x und y

Bildquelle 1

- Ein Gütemaß für die Vorhersage: Wie viel Varianz (Streuung) erklärt der Prädiktor?
- Prozentuale Varianzerklärung einer Variable durch die andere
- Wird in empirischen Studien berichtet

$R^2 = 0.55 \rightarrow$ 55% der Varianz in den Testergebnissen geht auf die Anzahl der Übungen zurück

Nicht-erklärte Varianz

$R^2 = 0.85 \rightarrow$ 85% der Varianz in den Testergebnissen geht auf die Anzahl der Übungen zurück




Gesamtvarianz

Erklärte Varianz durch den Prädiktor

Standardisiertes Regressionsgewicht β

- Zur Erinnerung:



Problem: abhängig von der Skala

Bildquelle 1

- Lösung: Standardisierung


$$\text{standardisierter Regressionskoeffizient (\beta-Gewicht)} \rightarrow \beta_{yx} = b \cdot \frac{s_x}{s_y} = \frac{\text{cov}(xy)}{s_x^2} \cdot \frac{s_x}{s_y} = \frac{\text{cov}(xy)}{s_x \cdot s_y}$$

Regressionskoeffizient Kovarianz Standardabweichung von y Standardabweichung von x

Bildquelle 1

Ausblick: Multiple Regression

- Bisher: *einfache* lineare Regression → nur **1** Prädiktor
- Erweiterung: *multiple* lineare Regression → **mehrere** Prädiktoren
- Testergebnis_{Schüler A} = $b_1 * \text{Anzahl der Übungen}_{\text{Schüler A}} + b_2 * \text{Motivation}_{\text{Schüler A}} + b_3 * \text{Vorwissen}_{\text{Schüler A}} + a$



Literaturangaben

- Hanna, D., & Dempster, M. (2017). *Statistik für Psychologen*. WILEY.
- Planing, P. *Regression*. <https://statistikgrundlagen.de/ebook/chapter/regression/>
- Rasch, B., Friese, M., Hofmann, W., & Naumann, E. (2021). *Quantitative Methoden 1. Einführung in die Statistik für Psychologie, Sozial- & Erziehungswissenschaften* (5. Auflage). Springer.
- Sedlmeier, P., & Renkewitz, F. (2018). *Forschungsmethoden und Statistik für Psychologen und Sozialwissenschaftler*. Pearson.

Bildquellen:

1. Planing, P. *Regression*. <https://statistikgrundlagen.de/ebook/chapter/regression/>
2. <http://www.shodor.org/interactivate/activities/Regression/>