



TECHNISCHE UNIVERSITÄT
IN DER KULTURHAUPTSTADT EUROPAS
CHEMNITZ

Professur Psychologie digitaler Lernmedien

Institut für Medienforschung

Philosophische Fakultät



Statistik I

Regression



Matrix (1999). Warner Bros. Pictures.


Überblick

- Lineare bivariate Regression
- Methode der kleinsten Quadrate
- Nichtlineare Zusammenhänge
- Multiple Regression
- Indikatorcodierung
- Inferenzstatistische Voraussetzungen

Lineare bivariate Regression

(z. B. Rasch, Frieese, Hofmann & Naumann, 2021)

- **Lineare bivariate Regression:** Statistisches Verfahren zur Vorhersage einer Kriteriumsvariable durch eine Prädiktorvariable mittels linearer Funktion
- **Fiktives Beispiel:** Zusammenhang zwischen Behaltens- und Transferleistungen



Lineare bivariate Regression


- **Regressionsgrade** soll den Gesamttrend der Einzelwerte bestmöglich wiedergeben
- **Regressionsgleichung** zur Regressionsgraden:

$$\hat{y} = m \cdot x + b$$

\hat{y} = Vorhergesagte Kriteriumsvariable y
m = Steigung der Regressionsgraden
x = Prädiktorvariable x
b = Achsenabschnitt der Regressionsgraden

- **Berechnung der Regressionsgewichte m und b** mittels Methode der kleinsten Quadrate

Methode der kleinsten Quadrate




Quelle: <http://www.youtube.com/watch?v=jEEJNz0RK4Q>


Methode der kleinsten Quadrate

- **Summe der Abweichungsquadrate (SAQ)** soll ein Minimum ergeben
- **Ein Gewicht:** Parabel (\rightarrow Regressionsgerade durch Achsenursprung)
- **Zwei Gewichte:** Paraboloid (\rightarrow Regressionsgrade)

Für ein Gewicht



Für zwei Gewichte



Methode der kleinsten Quadrate

- **Summe der Abweichungsquadrate (SAQ)** soll ein Minimum ergeben
- **Formel:**

$$SAQ = \sum_{i=1}^n [y_i - \hat{y}_i]^2 = \sum_{i=1}^n [y_i - (m \cdot x_i + b)]^2 = \min$$

- **Erste Ableitung** bilden und auf Null setzen ergibt für m und b:

$$m_{yx} = \frac{\text{COV}(x, y)}{\sigma_x^2}$$

$$b_{yx} = \bar{y} - m_{yx} \cdot \bar{x}$$

y = Beobachtete Werte der Variablen y
ŷ = Vorhergesagte Kriteriumsvariable y
m = Steigung der Regressionsgraden
x = Prädiktorvariable x
b = Achsenabschnitt der Regressionsgraden
i = Person i

Lineare bivariate Regression

- **Beispiel:** Berechnung von b und m zu dem rechts dargestellten Datensatz:


$$m_{yx} = \frac{\text{cov}(x, y)}{\sigma_x^2} \approx \frac{8.5}{3.21^2} \approx 0.82$$

$$b_{yx} = \bar{y} - m_{yx} \cdot \bar{x} \approx 6.5 - 0.82 \cdot 6.1 = 1.47$$

VPN	IQ	Mathe
Sheldon	9.5	9.0
Leonard	6.5	7.5
Howard	4.5	6.0
Rajesh	8.5	8.0
Penny	1.5	2.0
M	6.1	6.5
SD	3.21	2.74

Lineare bivariate Regression

- **Beispiel:** Regressionsgrade mit $b = 1.47$ und $m = 0.82$:



Lineare bivariate Regression


Wie hoch ist die Intelligenz laut Regressionsgleichung für das Beispiel auf der vorherigen Folie bei einer Person mit einem Mathewert von 4?

- A: 3
- B: 3.09 (gerundet)
- C: 4
- D: 4.75
- E: Wert kann nicht berechnet werden


Nichtlineare Zusammenhänge (z. B. Rasch, Frieese, Hofmann & Naumann, 2021)

- **Beispiele** für lineare und nonlineare Zusammenhänge

Linearer Zusammenhang



Nonlinearer Zusammenhang



Multiple univariate Regression

- **Definition:** Statistisches Verfahren zur Vorhersage einer Kriteriumsvariable durch mehrere Prädiktorvar. mittels Linearkombination
- **Regressionsgleichung zur Regressions(hyper-)ebene:**


$$\hat{y} = 1 \cdot b_0 + x_1 \cdot b_1 + \dots + x_m \cdot b_m$$

- **Bestimmung der Regressionsgewichte** (Beta-Gewichte) wieder mittels Methode der kleinsten Quadrate
- **Unterschied zur linearen bivariaten Regression:** Berechnung mit Matrizen statt mit Zahlen

\hat{y}	Vorhergesagte Kriteriumsvariable y
b_0	Achsenabschnitt der Regressionsgeraden
x_1	Erste Prädiktorvariable
b_1	Steigung zur ersten Prädiktorvariablen
x_m	m-te Prädiktorvariable
b_m	Steigung zur m-ten Prädiktorvariablen

Interaktionseffekte in der multiplen Regression

- **Interaktionseffekt** (bzw. Moderatoreffekt bzw. Wechselwirkungseffekt)
- **Fiktives Beispiel:** Studienerfolg nur dann hoch, wenn IQ (x_1) und Motivation (x_2) hoch sind
- $\hat{y} = 1 \cdot b_0 + x_1 \cdot b_1 + x_1 \cdot x_2 \cdot b_3 + x_2 \cdot b_2$



Inkrement und Dekrement in der multiplen Regression

- **Beitrag zur Varianzaufklärung:** Für jede einzelne Prädiktorvariable lässt sich ein solcher Beitrag bestimmen
- **Unterscheidung** zwischen Inkrement und Dekrement
 - **Inkrement (R_I^2):** Zuwachs an aufgeklärter Varianz durch Hinzunahme weiterer Prädiktorvariablen
 - **Dekrement (R_D^2):** Abnahme an aufgeklärter Varianz durch Verzicht auf bestimmte Prädiktorvariablen

Inkrement und Dekrement in der multiplen Regression

- **Orthogonaler Fall** (sämtliche Prädiktorvariablen sind unkorreliert): Addition der Einzelkorrelationen zur Berechnung von R^2 ; R_I^2 (bzw. R_D^2) = $r_{x_j,y}^2$
- **Kollinearer Fall** (Prädiktoren sind korreliert)
 - R^2 kleiner als Summe der Einzelkorrelationen durch Informationsüberschneidungen (häufiger Fall)
 - R^2 größer als Summe der Einzelkorrelationen: Suppressoreffekte durch Informationspräzisierung (seltener Fall)

$$R^2 = \sum_{j=1}^m r_{x_j,y}^2$$

$$R^2 < \sum_{j=1}^m r_{x_j,y}^2$$


$$R^2 > \sum_{j=1}^m r_{x_j,y}^2$$

Suppressorvariablen in der multiplen Regression

- **Suppressorvariablen** erhöhen die aufgeklärte Varianz durch Unterdrückung irrelevanter Varianzen anderer Variablen
- **Bedingungen für eine Suppressorvariable**
 - Keine oder geringe Korrelation mit der Kriteriumsvariable
 - Deutliche Korrelation mit mindestens einer Prädiktorvariable
 - Inkrement bzw. Dekrement der Variable ist (deutlich) größer als einfacher Determinationskoeffizient (R^2) der Suppressorvariable
- **Beispiel:** Berufserfolg (AV) wird durch Abschlussnote im Studium (UV_1) und Prüfungsangst (UV_2) vorhergesagt
- Prüfungsangst könnte als mögliche Suppressorvariable irrelevante Varianz in der Abschlussnote unterdrücken

Indikatorcodierung

- **Regressionsanalyse** mittels Indikatorcodierung auch bei fehlendem Intervallskalenniveau der Prädiktorvariable(n) möglich
- **Indikatorcodierung:** Umrechnung von nominal- oder ordinalskalierten Prädiktorvariablen in künstliche, intervallskalierte Prädiktorvariablen
- **Beispiel:** Umrechnung der Variable Geschlecht in eine Indikatorvariable (z. B. $\sigma = 0$ und $\text{♀} = 1$)
- **Äquidistanz:** Diese Indikatorvariable enthält nur ein Intervall, welches zu sich selbst äquidistant ist und somit Intervallskalenniveau besitzt
- **Wichtig:** Durch Indikatorcodierung und das Allgemeine Lineare Modell gilt mathematisch: Varianzanalyse = Regressionsanalyse



Inferenzstatistische Voraussetzungen (z. B. Rasch, Frieze, Hofmann & Naumann, 2021)

- **Intervallskalenniveau** der Kriteriumsvariable
- **Normalverteilung** der Kriteriumsvariable in der Population
- **Unabhängigkeit der einzelnen Messwerte** verschiedener Personen
- **Homoskedastizität**: Homogenität der Streuungen der zu einem x-Wert gehörenden y-Werte über den gesamten Wertebereich von x (vgl. inferenzstatistische Voraussetzungen der MANOVA ohne MW)

Beispiele für Korrelationen und Regressionen in Fachzeitschriften

The data were analyzed by means of a 2×2 ANOVA with the learner's gender and the speaker's gender as between-factors. For the analysis of problem-solving performance, two additional control variables were included, namely the "Abiturnote" (i.e., final high school grade point average) and intrinsic motivation, resulting in a 2×2 ANCOVA. Both covariates showed a significant correlation with problem-solving performance (Abiturnote: $r = -.36$, $P = .001$, whereby better school grades were associated with better learning outcomes; intrinsic motivation: $r = .26$, $P = .02$, whereby higher intrinsic motivation was associated with better learning outcomes), but were independent from each other ($r = -.01$, $P = .94$). The results of the experiment are shown in Table 1.

Quelle: Linek, Gerjets und Scheiter (2010)

Table 6. Correlations between indices of game performance, pre-test and learning outcome

	2	3	4	5	6
(1) Level Reached	.99***	.49**	.41*	.43*	.18
(2) Unique Maths Tasks		.55**	.38*	.44*	.20
(3) All Maths Tasks			-.23	.37*	.25
(4) Accuracy				.06	-.14
(5) Pre-test					-.01
(6) Gain					

Note. * = $p < 0.05$, ** = $p < 0.01$, *** = $p < 0.001$ (two-tailed test of significance).

Quelle: Habgood und Ainsworth (2011)

Table 2



Summary of regression analysis for variables predicting posttest scores.

Predictor variable	B	SE	β
Unique simulation experiments	0.05	0.02	0.23
Relations aspect model quality	-0.12	0.04	-0.29

Quelle: Mulder, Lazonder und de Jong (2014)

Zusammenfassung

- **Lineare bivariate Regression:** Statistisches Verfahren zur Vorhersage einer Kriteriumsvariable durch eine Prädiktorvariable mittels linearer Funktion
- **Methode der kleinsten Quadrate** zur Berechnung der Regressionsgewichte
- **Nichtlineare Zusammenhänge** ebenfalls vorhersagbar
- **Multiple Regression** zur Vorhersage einer Kriteriumsvariable durch mehrere Prädiktorvariablen mittels Linearkombination
- **Indikatorcodierung** als Umrechnung in künstliche, intervallskalierte Prädiktorvariablen
- **Inferenzstatistische Voraussetzungen:** Intervallskalenniveau & Normalverteilung der Kriteriumsvariable, Unabhängigkeit der einzelnen Messwerte & Homoskedastizität



- Rasch, B., Frieze, M., Hofmann, W., & Naumann, E. (2021). *Quantitative Methoden 1: Einführung in die Statistik für Psychologie, Sozial- & Erziehungswissenschaften* (5. Aufl.). Heidelberg: Springer.
 - Merkmalszusammenhänge (S. 105–119)

Weiterführende Literatur I

- Bortz, J., & Schuster, C. (2010). *Statistik für Human- und Sozialwissenschaftler* (7. Aufl.). Berlin: Springer.
 - Einfache lineare Regression (S. 183–202)
- Eid, M., Gollwitzer, M., & Schmitt, M. (2017). *Statistik und Forschungsmethoden* (5. Aufl.). Weinheim: Beltz.
 - Abhängigkeiten zwischen zwei Variablen: Einfache lineare Regression (S. 589–613)
- Leonhart, R. (2022). *Lehrbuch Statistik. Einstieg und Vertiefung* (5. Auflage). Bern: Huber.
 - Korrelation und Regression (S. 261–378)

Weiterführende Literatur II

- Sedlmeier, P., & Renkewitz, F. (2018). *Forschungsmethoden und Statistik: Ein Lehrbuch für Psychologen und Sozialwissenschaftler* (3. Aufl.). München: Pearson.
 - Lineare Regression (S. 245–288)