

Sprechstunde
jederzeit nach
Vereinbarung und
nach der Vorlesung

Wallstr. 3, 6. Stock,
Raum 06-206



Mathematische und statistische Methoden I

Dr. Malte Persike



persike@uni-mainz.de



lordsofthebortz.de



twitter.com/methodenlehre



tinyurl.com/gplusmethodenlehre

WiSe 2011/2012

Fachbereich Sozialwissenschaften
Psychologisches Institut
Johannes Gutenberg Universität Mainz

Partialkorrelation

Semipartialkorrelation

Multiple Partialkorrelation


Partialkorrelation

Deutungsmöglichkeiten der einfachen Regression


1. Zufall

2. Direkte Kausalität: $x \rightarrow y$

3. Kausale Drittvariable(n)



4. Direkte und indirekte Kausalität



Partialkorrelation


Semipartialkorrelation

Multiple Partialkorrelation

Partialkorrelation

im Fall zweier korrelierter Variablen

- ⊕ Definition: Eine **Partialkorrelation** ist die Korrelation zweier Variablen, die vom Effekt anderer Variablen bereinigt wurden.
- ⊕ Einsatzzweck: Prüfung einer **Kausalvermutung G**
„Kommt $r_{y_1y_2}$ dadurch zustande, dass eine Drittvariable x ursächlich auf y_1 und y_2 einwirkt?“



Partialkorrelation

Semipartialkorrelation


Multiple Partialkorrelation

Partialkorrelation

Berechnung und Prüfung

1. Sage y_1 aus x voraus und berechne Residuen e_{y1}
2. Sage y_2 aus x voraus und berechne Residuen e_{y2}
3. Berechne die Korrelation $r_{e_{y1}e_{y2}}$ Schreibe: $r_{y_1y_2 \cdot x}$

„ohne“



Ist Partialkorrelation **nahe Null**, so beruht die Korrelation $r_{y_1y_2}$ tatsächlich vor allem auf der Einwirkung von x .

(Prüfung mit Korrelationstest)



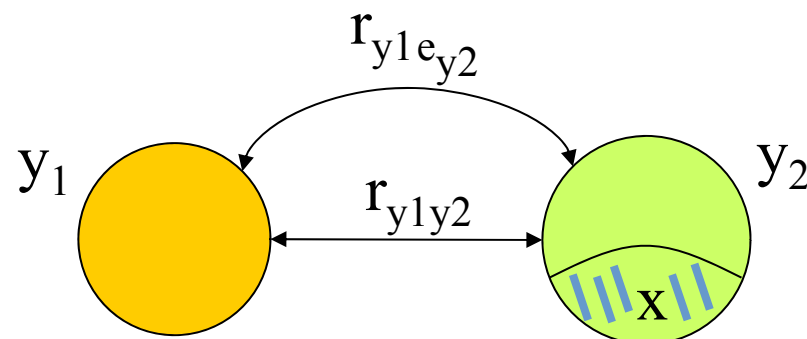
Partialkorrelation

Semipartialkorrelation

Multiple Partialkorrelation

Semipartialkorrelation im Fall zweier korrelierter Variablen

- ⊕ Definition: Eine **Semipartialkorrelation** ist die Korrelation zweier Variablen, von denen *eine* vom Effekt einer anderen Variablen bereinigt wurden.
- ⊕ Einsatzzweck: Prüfung der zusätzlichen Information eines Prädiktors bei der **Erklärung des Kriteriums**
- ⊕ Die Semipartialkorrelation ist eng verbunden mit der **Nützlichkeit**. Es gilt nämlich $U_{x_1} = r^2_{y(x_1 \cdot x_2)}$



Partialkorrelation

Semipartialkorrelation

Multiple Partialkorrelation

Semipartialkorrelation

Berechnung

1. Sage y_2 aus x voraus und berechne Residuen e_{y_2}
2. Berechne die Korrelation $r_{y_1 e_{y_2}}$
(analog für Auspartialisierung von x aus y_1)

Schreibe: $r_{y_1(y_2 \cdot x)}$

↑
„ohne“



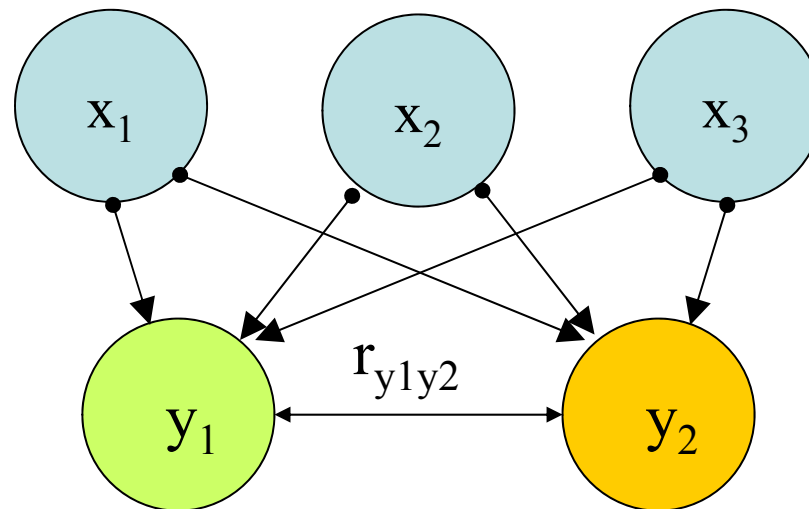
Partialkorrelation

Semipartialkorrelation

Multiple Partialkorrelation

(Semi-)Partialkorrelation höherer Ordnung Prinzip

- ⊕ Soll der Zusammenhang zwischen zwei Variablen um **mehrere andere Variablen** bereinigt werden, spricht man von (Semi-)Partialkorrelationen höherer Ordnung
- ⊕ Die Berechnung verläuft analog zu den (Semi-)Partialkorrelationen bei nur einer auszupartialisierenden Variable, nur mithilfe der Multiplen Regression



Partialkorrelation

Semipartialkorrelation

Multiple Partialkorrelation

(Semi-)Partialkorrelation höherer Ordnung Berechnung über multiple Regression

1. Sage y_1 aus den $x_1 \dots x_k$ voraus und berechne Residuen e_{y1}
2. Sage y_2 aus den $x_1 \dots x_k$ und berechne Residuen e_{y2}
3. Berechne die Korrelation $r_{e_{y1}e_{y2}}$ $\rightarrow r_{y_1 y_2 \cdot x_1 \dots x_k}$
(Partialkorrelation)

oder

Berechne die Korrelation $r_{y_1 e_{y2}}$ $\rightarrow r_{y_1(y_2 \cdot x_1 \dots x_k)}$
(Semipartialkorrelation)



Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse

Ein-/Mehrfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ **Ziel:** Analyse des Einflusses **unabhängiger Variablen** (UVn) auf eine **abhängige Variable** (AV)
- ⊕ Während bei der Regression der Fokus auf den **Zusammenhängen** zwischen UVn und AV liegt, soll die ANOVA gemessene **Unterschiede** in der AV erklären.
- ⊕ **Beispiele:** Wie gut wirken unterschiedliche Therapieformen bei spezifischen Phobien bei verschiedenen Geschlechtern? Wie verändert sich die Schulleistung von Kindern über mehrere Nachhilfesitzungen hinweg?
- ⊕ Generell versucht die ANOVA immer, Unterschiede **zwischen Gruppen** in der Höhe der AV aufzuzeigen.



Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse

Ein-/Mehrfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ Die AV muss dabei **stetig** sein (intervallskaliert) die UVn sind i.d.R **nominal-** oder **ordinalskaliert**
- ⊕ Die UVn werden im Rahmen der ANOVA auch als **Treatments** oder **Faktoren** bezeichnet, die Ausprägungen eines Treatments als **Treatmentstufen** oder **Faktorstufen**
- ⊕ Nach der Anzahl der Treatments unterscheidet man die einfaktorielle, zweifaktorielle oder allgemein mehrfaktorielle ANOVA



Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse

Ein-/Mehrfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ **Beispiel:** Experiment mit einem 3stufigen Treatment A
- ⊕ Man habe an 3 Personengruppen (definiert durch die Treatmentstufen A_1 bis A_3) die Werte einer AV erhoben.

Vp-Nr.	A_1	A_2	A_3
1	9	6	10
2	14	8	11
3	12	13	7
...
$n-1$	17	19	14
n	15	11	12



Einführung

Lineares
Modell

Voraus-
setzungen



Varianzanalyse

Ein-/Mehrfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ **Beispiel:** Nun nehme man das Geschlecht als „Treatment“ B mit zwei Stufen hinzu
- ⊕ Man hat nun 6 Personengruppen (oder „Zellen“)

	Vp-Nr.	A ₁	A ₂	A ₃
B₁	1	9	6	10

	n_1	12	13	7
B₂	1	17	19	14

	n_2	15	11	12

Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse

Ein-/Mehrfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ Die abhängige Variable sei X genannt.
- ⊕ Mit der korrekten Indizierung lässt sich die Tabelle dann schreiben als

	Vp-Nr.	A ₁	A ₂	A ₃
B₁	1	$x_{1,1,1} = 9$	$x_{1,2,1} = 6$	$x_{1,3,1} = 10$

	n_1	$x_{n_1,1,1} = 12$	$x_{n_1,2,1} = 13$	$x_{n_1,3,1} = 7$
B₂	1	$x_{1,1,2} = 17$	$x_{1,2,2} = 19$	$x_{1,3,2} = 14$

	n_2	$x_{n_2,1,2} = 15$	$x_{n_2,2,2} = 11$	$x_{n_2,3,2} = 12$



Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse


Ein-/Mehrfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ Die ANOVA geht davon aus, dass am Zustandekommen jedes Messwertes $x_{i,j,k}$ ($i = 1 \dots n$, $j = 1 \dots p$, $k = 1 \dots q$ mit $p=3$, $q=2$) mehrere Komponenten beteiligt sind:
1. **Populationswert**, von allen Personen geteilt
Dieser ist für alle Personen konstant
 2. **Effekt der Treatmentstufe j** des Treatments A
Dieser ist für jede Person in Gruppe A_j konstant
 3. **Effekt der Treatmentstufe k** des Treatments B
Dieser ist für jede Person in Gruppe B_k konstant
 4. **Interaktionseffekt** jeder spezifischen Kombination von A_j und B_k
Dieser ist für jede Person in Zelle $A_j B_k$ konstant
 5. **Zufallsfehler**, der Unterschiede zwischen Personen ausmacht, die nicht auf A oder B zurückgehen
Dieser ist individuell für jede Person



- ⊕ Wie die Regression geht die ANOVA von einem einfachen **linearen Modell** aus.
- ⊕ Sie nimmt an, dass der Messwert einer Person auf einer beliebigen AV additiv aus **systematischen Komponenten** und einer **Fehlerkomponente** besteht

$n=60$



$$x = \mu$$

Von allen geteilter
Populationswert

| = Streuung von μ



$$x = \mu + e$$

plus Fehler

☐ = Fehlerstreuung

$n_1=n_2=n_3=20$




$$x = \mu + a + e$$

plus
Effekt A

☐ = Treatment-
streuung A

- ⊕ Wie die Regression geht die ANOVA von einem einfachen **linearen Modell** aus.
- ⊕ Sie nimmt an, dass der Messwert einer Person auf einer beliebigen AV additiv aus **systematischen Komponenten** und einer **Fehlerkomponente** besteht



Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse

Ein-/Mehrfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ Der einfaktoriellen Varianzanalyse liegt also formal ein sehr einfaches lineares Modell zugrunde

$$x_{ijk} = \mu + a_j + b_k + a_j b_k + e_{ij}$$

x_{ijk} = Messwert der Person i unter Treatmentstufen j und k

μ = Populationswert aller $\sum n_{jk} = N$ Personen

a_j = Effekt der Treatmentstufe j

b_k = Effekt der Treatmentstufe k

$a_j b_k$ = Interaktionseffekt der Treatmentstufen j und k

e_{ijk} = Fehler der Person i unter Treatmentstufen j und k

- ⊕ **Merke:** Der Messwert einer beliebigen aller N Person setzt sich zusammen aus einem **Populationswert**, den **Treatmenteffekten** & einem individuellen **Messfehler**.



Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse

Einfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ Der beobachtete Messwert jeder Person ist also in drei Komponenten **zerlegt**
- ⊕ Damit lässt sich die Tabelle schreiben als

	Vp-Nr.	A_1	...	A_p
B_1	1	$a_1 + b_1 + a_1 b_1 + e_{1,1,1}$...	$a_p + b_1 + a_p b_1 + e_{1,p,1}$

	n_1	$a_1 + b_1 + a_1 b_1 + e_{n_1,1,1}$...	$a_p + b_1 + a_p b_1 + e_{n_1,p,1}$
B_q	1	$a_1 + b_q + a_1 b_q + e_{1,1,q}$...	$a_p + b_q + a_p b_q + e_{1,p,q}$

	n_2	$a_1 + b_q + a_1 b_q + e_{n_2,1,q}$...	$a_p + b_q + a_p b_q + e_{n_2,p,q}$



Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse

Einfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ Die zentrale **Forschungsfrage**, die von der ANOVA beantwortet werden soll, lautet nun:

Gilt

$$a_j = a_{j'}$$

für alle

oder

$$a_j \neq a_{j'}$$

für mindestens eine

der paarweisen Kombinationen von j und j' .

- ⊕ **In Worten:** Gibt es mindestens eine Treatmentstufe von A , die auf den Messwert der Versuchspersonen anders wirkt als die übrigen Treatmentstufen von A ?



Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse

Einfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ Die zentrale **Forschungsfrage**, die von der ANOVA beantwortet werden soll, lautet nun:

Gilt

$$b_k = b_{k'}$$

für alle

oder

$$b_k \neq b_{k'}$$

für mindestens eine

der paarweisen Kombinationen von k und k' .

- ⊕ **In Worten:** Gibt es mindestens eine Treatmentstufe von B , die auf den Messwert der Versuchspersonen anders wirkt als die übrigen Treatmentstufen von B ?



Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse

Einfaktorielle ANOVA (ANalysis Of VAriance)

- ⊕ Die zentrale **Forschungsfrage**, die von der ANOVA beantwortet werden soll, lautet nun:

Gilt

$$a_j \cdot b_k = a_{j'} \cdot b_{k'}$$

für alle

oder

$$a_j \cdot b_k \neq a_{j'} \cdot b_{k'}$$

für mindestens

eine der paarweisen Kombinationen von jk & $j'k'$.

- ⊕ **In Worten:** Gibt es mindestens eine Interaktion von A und B , die auf den Messwert der Versuchspersonen anders wirkt als die übrigen Kombinationen von A und B ?



Einführung

Lineares
Modell

Voraus-
setzungen

Varianzanalyse

Ein-/Mehrfaktorielle ANOVA - Annahmen

⊕ Die Beobachtungen müssen **unabhängig** sein, d.h. sie müssen von verschiedenen Merkmalsträgern stammen

⊕ Die **Fehler** in jeder Treatmentstufe sollten **normalverteilt** sein mit einem erwarteten Mittelwert von 0.

$$\bar{e}_{jk} = 0$$

⊕ Die Fehlervarianzen in jeder der p Treatmentstufen sollen erwartet (nicht numerisch) gleich sein (**Homoskedastizität**).

$$s_{e_{1,1}}^2 = s_{e_{1,2}}^2 = \dots = s_{e_{p,q}}^2$$

⊕ Treatmenteffekt und Fehler müssen **additiv** sein, d.h. die Fehler dürfen nicht mit den Erwartungswerten der Treatmentstufen korrelieren.



Einführung

Lineares
Modell

**Voraus-
setzungen**

Varianzanalyse

Einfaktorielle ANOVA – Prüfung der Annahmen

- ⊕ Die **Unabhängigkeit der Beobachtungen** wird i.d.R. „begründet angenommen“ (educated guess).
- ⊕ Zur Prüfung der **Normalverteilungsannahme** der Fehler (i.e. Zellresiduen) wird der Kolmogoroff-Smirnov Test verwendet
- ⊕ Zur Prüfung der **Homogenität der Fehlervarianzen** wird zumeist der Bartlett Test, seltener der Levene Test bzw. der F-Test verwendet.
- ⊕ Die **Unabhängigkeit der Treatmenteffekte und Messfehler** kann über einen Korrelationstest von Zellmittelwerten und Varianzen geprüft werden (selten praktiziert)

