

Anwendungsorientierte Analyseverfahren

Moderationsanalyse

Prof. Dr. Michael Scharkow


Sommersemester 2024

**Fragen zur Studienleistung oder
praktischen Übung?**

WIEDERHOLUNG: INFORMATION OVERLOAD

Parameter	Coefficient	95% CI	t(983)	p	Std. Coef.	Fit
(Intercept)	6.93	(5.89, 7.97)	13.09	< .001	0.03	
Gender (female)	0.72	(0.32, 1.12)	3.51	< .001	0.23	
Age	0.02	(0.00, 0.03)	2.06	0.039	0.07	
Education (Middle)	-0.40	(-1.01, 0.21)	-1.29	0.198	-0.13	
Education (High)	-0.62	(-1.23, -0.01)	-1.98	0.048	-0.20	
Outlets Used	0.10	(0.06, 0.13)	4.97	< .001	0.16	
AICc						5062.21
R2						0.04
R2 (adj.)						0.03
Sigma						3.11


Was tut eine intervenierende Variable?



(z.B. Werbeexposition)


(z.B. Kaufverhalten)

Moderation



(z.B. Effekt der Werbeexposition auf Kaufverhalten hängt von Voreinstellung ab)

Mediation




(z.B. Werbeexposition wirkt sich auf Kaufverhalten aus, weil sie Einstellung beeinflusst)

MODERATIONSANALYSE

- Diagnose: Effektheterogenität, d.h. der Zusammenhang von X und Y ist nicht für alle gleich
- der Effekt von X auf Y hängt von Moderatorvariable Z ab (“wird von Z moderiert”)
- die Größe und die Richtung des Regressionskoeffizienten ist davon abhängig, welche Ausprägung Z hat
- Beispiele:
 - Experimente mit min. 2 Faktoren, die sich gegenseitig beeinflussen
 - Effektheterogenität in verschiedenen Subgruppen der Stichprobe
- Effektheterogenität aktuell en vogue (person-specific media effects, Valkenburg et al., 2021), aber theoretisch und empirisch ggf. problematisch (Healy, 2017; Vuorre et al., 2022)


WORAN ERKENNEN WIR EFFEKTHETEROGENITÄT?

Effekthomogenität



Gruppe 1 Gruppe 2

Effektheterogenität (Moderation)



Gruppe 1 Gruppe 2

ANALYSEMÖGLICHKEITEN

(a) separate Regressionsmodelle pro Subgruppe schätzen

- kein direkter Test der Moderationshypothese
- weniger statistische Power wg. kleinerer Subsamples
- alle Regressionskoeffizienten werden unterschiedlich geschätzt
- bei metrischen Moderatoren Dichotomisierung o.ä. nötig

(b) Moderationsanalyse mit Interaktionstermen

- gezielt für spezifische Prädiktoren möglich
- statistische Power bleibt erhalten
- metrische Moderatoren problemlos integrierbar

BEISPIEL GETRENNTE ANALYSEN

<i>Predictors</i>	Overload (female)			Overload (male)		
	<i>Estimates</i>	<i>CI</i>	<i>p</i>	<i>Estimates</i>	<i>CI</i>	<i>p</i>
(Intercept)	7.79	6.47 – 9.11	<0.001	7.97	6.53 – 9.40	<0.001
Age	0.02	-0.00 – 0.04	0.090	0.01	-0.01 – 0.04	0.186
Education: Middle	0.08	-0.83 – 1.00	0.858	-0.59	-1.43 – 0.25	0.171
Education: High	0.12	-0.79 – 1.02	0.799	-0.72	-1.56 – 0.11	0.089
Observations	474			519		
R ² / R ² adjusted	0.006 / -0.000			0.009 / 0.004		

REGRESSIONSFORMEL FÜR MODERATION

- Bei der Moderationsanalyse gehen wir davon aus, dass der *Effekt* X auf Y eine Funktion von Z ist
$$Y = b_0 + f(Z)X + b_2Z + \epsilon$$
- Die Funktion $f(Z)$ sei definiert als lineare Funktion $f(Z) = b_1 + b_3Z$
$$Y = b_0 + (b_1 + b_3Z)X + b_2Z + \epsilon$$
- Durch Ausmultiplizieren erhalten wir einen Interaktionsterm XZ , der einfach das Produkt von X und Z ist
$$Y = b_0 + b_1X + b_2Z + b_3XZ + \epsilon$$

WAS BEDEUTEN DIE KOEFFIZIENTEN?

- Regressionsformel $Y = b_0 + b_1 X + b_2 Z + b_3 XZ + \epsilon$
- b_0 (Intercept) ist der erwartete Wert von Y , wenn $X = 0$ und $Z = 0$
- b_1 ist der (konditionale) Effekt von X , wenn $Z = 0$
- b_2 ist der (konditionale) Effekt von Z , wenn $X = 0$
- b_3 ist der eigentliche Interaktionseffekt, d.h. die Differenz in b_1 , wenn Z sich um eine Einheit ändert

INTERPRETATION KONDITIONALER EFFEKTE

- bei Moderationsanalysen wird oft nur auf die Signifikanz des Interaktionsterms geschaut.
- man kann und sollte aber auch die substantziellen Effekte betrachten, z.B. durch
 - Schätzung der konditionalen Regressionskoeffizienten für (typische) Werte von Z
 - Visualisierung der Modellvorhersagen für Y für (typische) Werte von Z

Wichtig: Bei Regressionsmodellen mit Interaktionseffekten XZ sind die Koeffizienten von X und Z nicht mehr unabhängig voneinander interpretierbar, d.h. die Effekte sind nicht mehr *unkonditional* für alle Fälle n gültig!

Wichtig: Damit die konditionalen Effekte überhaupt interpretierbar sind, sollten wir metrische Variablen zentrieren und kategorielle Variablen dummy- oder effektcodieren!

INTERAKTIONSTERME

- in R kann man Interaktionsterme direkt in die Modellformel für `lm()` aufnehmen:
 $y \sim x + z + x:z$ oder einfacher $y \sim x * z$
- alternativ werden Interaktionsterme manuell erstellt:
 - vor der Schätzung die beiden Variablen X und Z miteinander zu einer neuen Variable XZ multiplizieren
 - dieser Interaktionsterm XZ wird dann als zusätzliche Prädiktorvariable ins Modell aufgenommen
- für leichtere Interpretierbarkeit immer darauf achten, dass X und Z einen sinnvollen Wert für 0 haben

BEISPIELSTUDIE: VÖGELE & BACHL, 2017

Der Einfluss des Dialekts auf die Bewertung von Politikern

The effects of dialect on the evaluation of politicians

Catharina Vögele & Marko Bachl

Zusammenfassung: Wie eine Person spricht, trägt wesentlich dazu bei, welchen Eindruck wir von ihr gewinnen. Dies gilt auch für Politiker, die häufig als öffentliche Sprecher in Erscheinung treten. Regionale Dialekte gehören zu den auffälligsten Merkmalen gesprochener Sprache. Daher ist zu vermuten, dass der Gebrauch eines Dialekts durch einen Politiker dessen Bewertung beeinflusst. Auf Grundlage bisheriger Forschung schlagen wir ein konditionales Prozess-Modell vor, das den Effekt des Dialekts auf die Bewertung des sprechenden Politikers erklärt. Das Modell wird mit einem experimentellen Vergleich zweier Sprachversionen (hochdeutsch und schwäbisch) eines Radio-Interviews mit einem Politiker geprüft. Die Ergebnisse stützen das Modell: Der Effekt des Dialekts auf die Beurteilung von Politikern ist abhängig von der allgemeinen Voreinstellung der Zuhörer gegenüber dem Schwäbischen. Diese Effekte werden vermittelt über die Beurteilung des Klangs der Politikerstimme sowie über die Verständlichkeit seiner Ausdrucksweise. Die Befunde werden mit Blick auf weitere Forschung und die Kommunikation von Politikern diskutiert.

DATEN

- schwab: Experimentalbedingung
Dialekt schwäbisch 0 (nein), 1 (ja)
- atol: Attitude toward other language
= Einstellung zum Schwäbischen
(1-5)
- gesamt: Gesamtbewertung des
Politikers (Outcome-Variable, 1-5)

schwab	geschlecht_w	atol	gesamt
1	1	2.4	3
0	0	3.8	4
0	1	2.2	4
1	0	3.0	2
0	1	2.0	4

▶ 0:00 / 1:35



▶ 0:00 / 1:30



BIVARIATES MODELL (NUR VERSUCHSBEDINGUNG)

Parameter	Coefficient	95% CI	t(361)	p	Std. Coef.	Fit
(Intercept)	3.81	(3.67, 3.94)	55.54	< .001	0.00	
schwab	-0.20	(-0.39, -0.02)	-2.22	0.027	-0.12	
AICc						937.93
R2						0.01
R2 (adj.)						0.01
Sigma						0.88

Beispielanalyse: kategorielle Moderatoren

ZWEI PRÄDIKTOREN (NUR HAUPTEFFEKTE)

Parameter	Coefficient	95% CI	t(360)	p	Std. Coef.	Fit
(Intercept)	3.63	(3.46, 3.79)	43.52	< .001	0.00	
schwab	-0.21	(-0.39, -0.03)	-2.31	0.021	-0.12	
geschlecht w	0.34	(0.16, 0.52)	3.75	< .001	0.19	
AICc						926.08
R2						0.05
R2 (adj.)						0.05
Sigma						0.86

MODELL MIT KATEGORIELLEM MODERATOR

Parameter	Coefficient	95% CI	t(359)	p	Std. Coef.	Fit
(Intercept)	3.71	(3.51, 3.90)	37.37	< .001	0.00	
schwab	-0.36	(-0.62, -0.09)	-2.66	0.008	-0.12	
geschlecht w	0.19	(-0.07, 0.46)	1.42	0.158	0.19	
schwab × geschlecht w	0.27	(-0.09, 0.63)	1.49	0.137	0.08	
AICc						925.89
R2						0.06
R2 (adj.)						0.05
Sigma						0.86

Achtung: Durch das bloße Hinzufügen des Interaktionsterms ändert sich die Interpretation der Regressionskoeffizienten! Wir sehen jetzt die Effekte des Dialekts bei Männern (geschlecht_w = 0) bzw. den Geschlechtseffekt in der Bedingung

KONDITIONALE EFFEKTE

Durch Einsetzen in die Gleichung $f(Z) = b_1 + b_3Z$ lassen sich die konditionalen Effekte von X (Dialekt) bei verschiedenen Ausprägungen vom Moderator Z (Geschlecht) schätzen:

term	geschlecht_w	estimate	p.value	conf.low	conf.high
schwab	0	-0.36	0.01	-0.62	-0.09
schwab	1	-0.09	0.48	-0.33	0.15

AVERAGE MARGINAL EFFECTS (AME)

Die *durchschnittlichen* Effekte von X über die gesamte Stichprobe (average marginal effects) lassen sich bestimmen, indem für jeden einzelnen Fall der konditionale Effekt berechnet und dann gemittelt wird.

term	estimate	p.value	conf.low	conf.high
schwab	-0.21	0.02	-0.39	-0.03

Average Marginal Effects (AME) entsprechen im linearen Modell den unmoderierten Koeffizienten

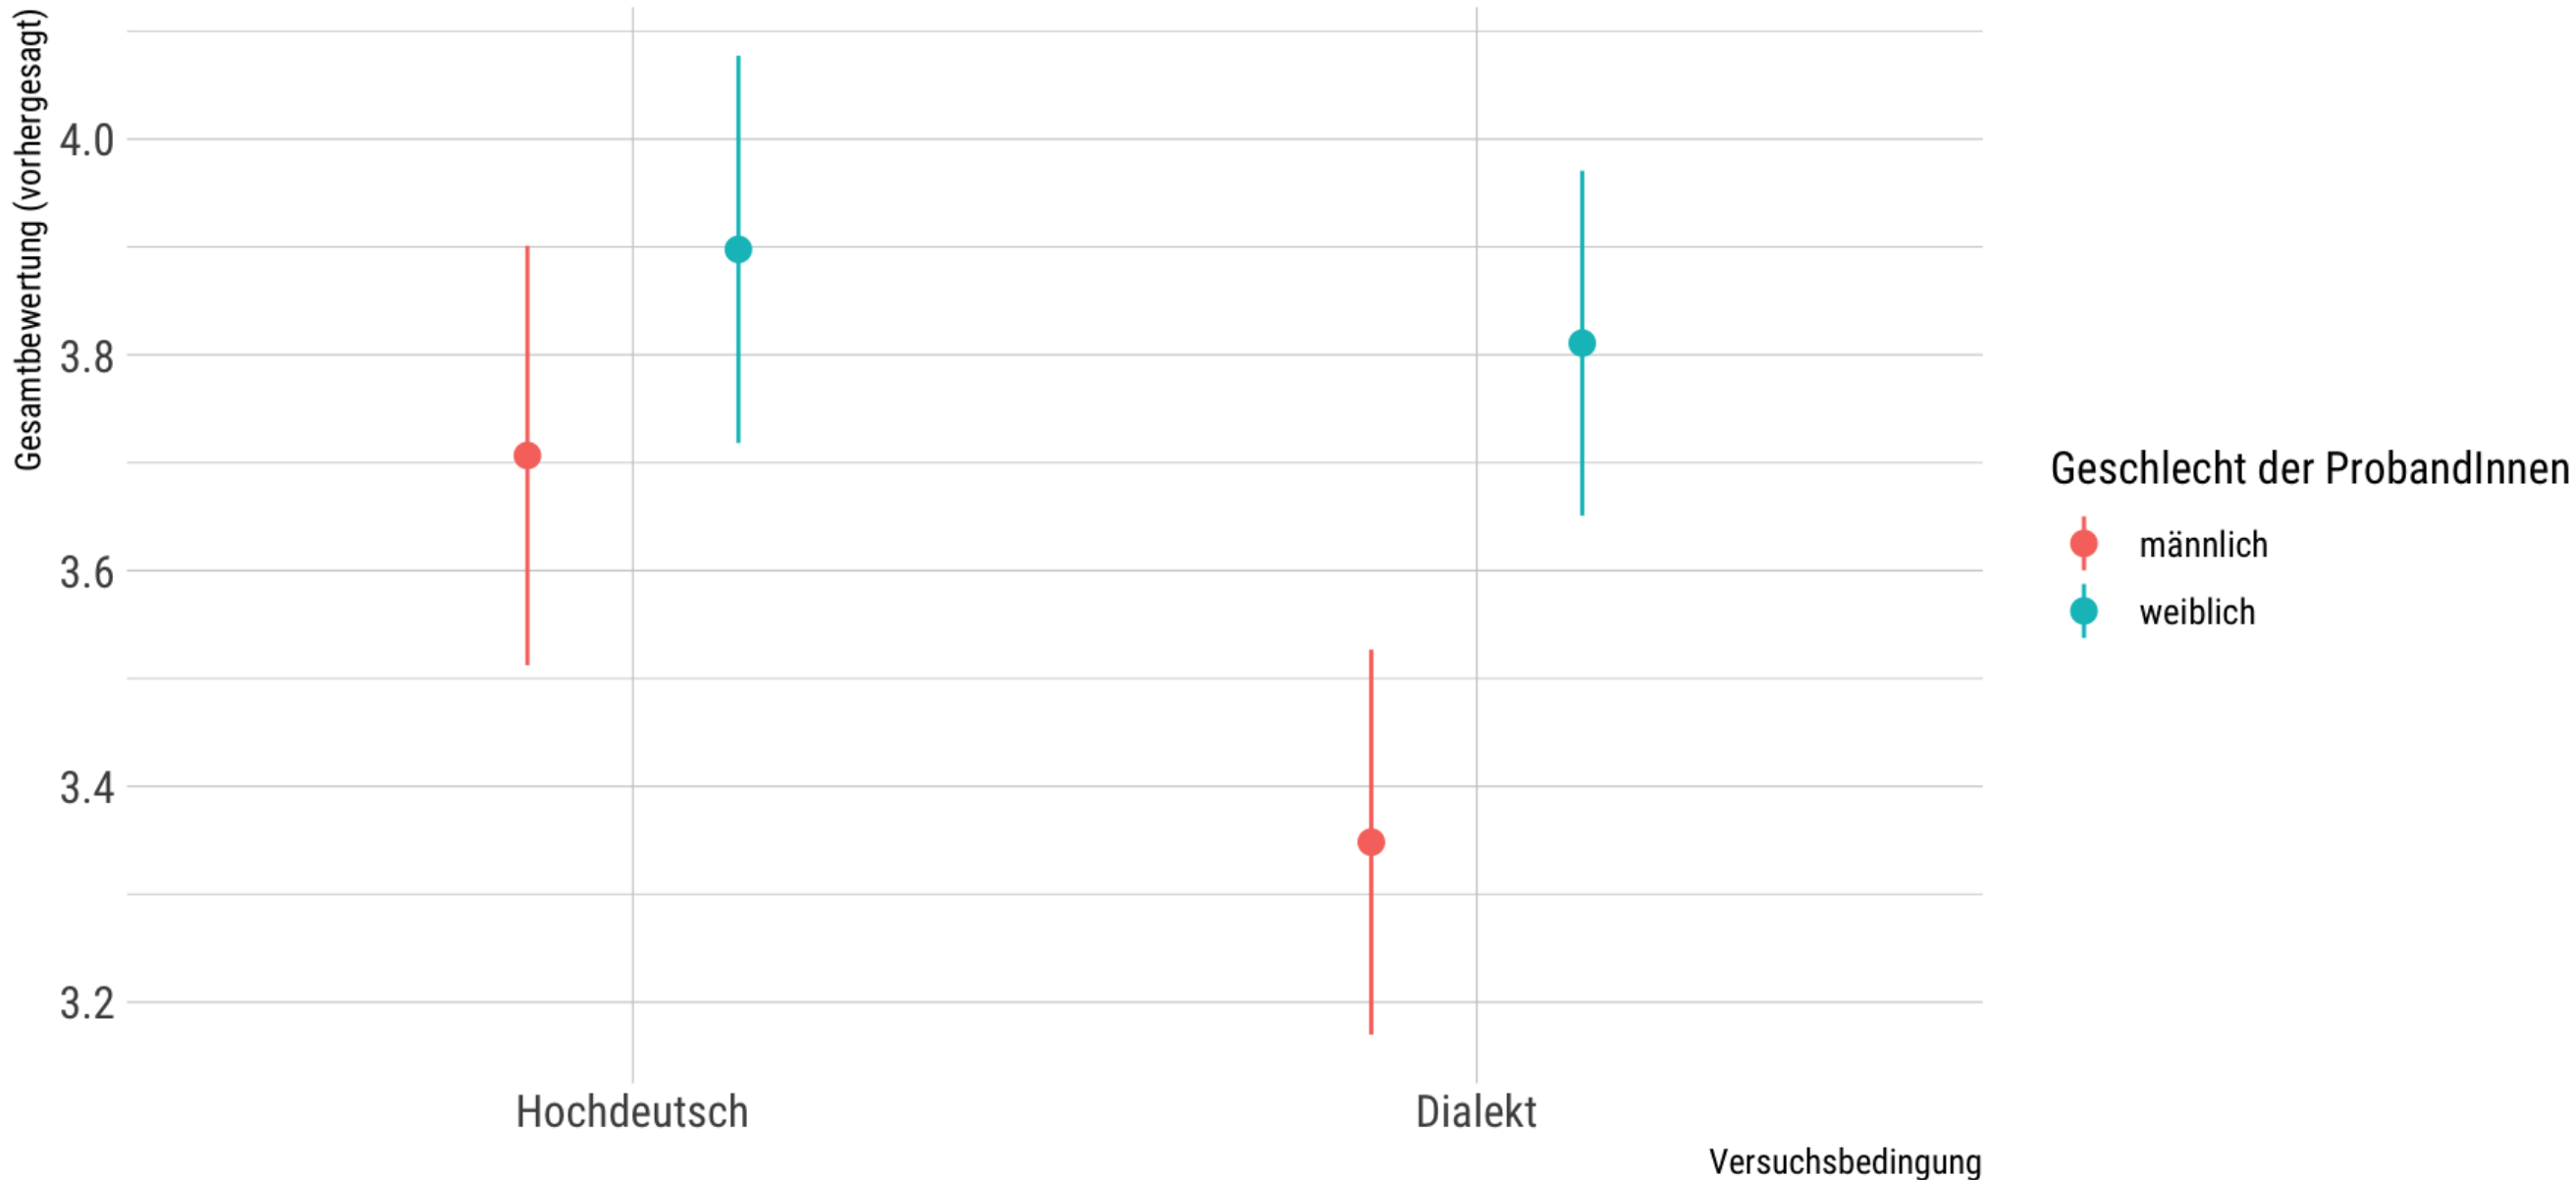
term	estimate	std.error	statistic	p.value
schwab	-0.21	0.09	-2.31	0.02
geschlecht_w	0.34	0.09	3.75	0.00

VORHERGESAGTE WERTE

- Durch Einsetzen der Werte von X in die Regressionsgleichung lassen sich wie immer die vorhergesagten Werte in Y schätzen.
- Im Beispiel gibt es nur 4 typische Bedingungen (2 Treatment x 2 Geschlecht), die wir explizit vorhersagen.

schwab	geschlecht_w	estimate	std.error	conf.low	conf.high
0	0	3.71	0.10	3.51	3.90
1	0	3.35	0.09	3.17	3.53
0	1	3.90	0.09	3.72	4.08
1	1	3.81	0.08	3.65	3.97

VISUALISIERUNG DER VORHERSAGEN



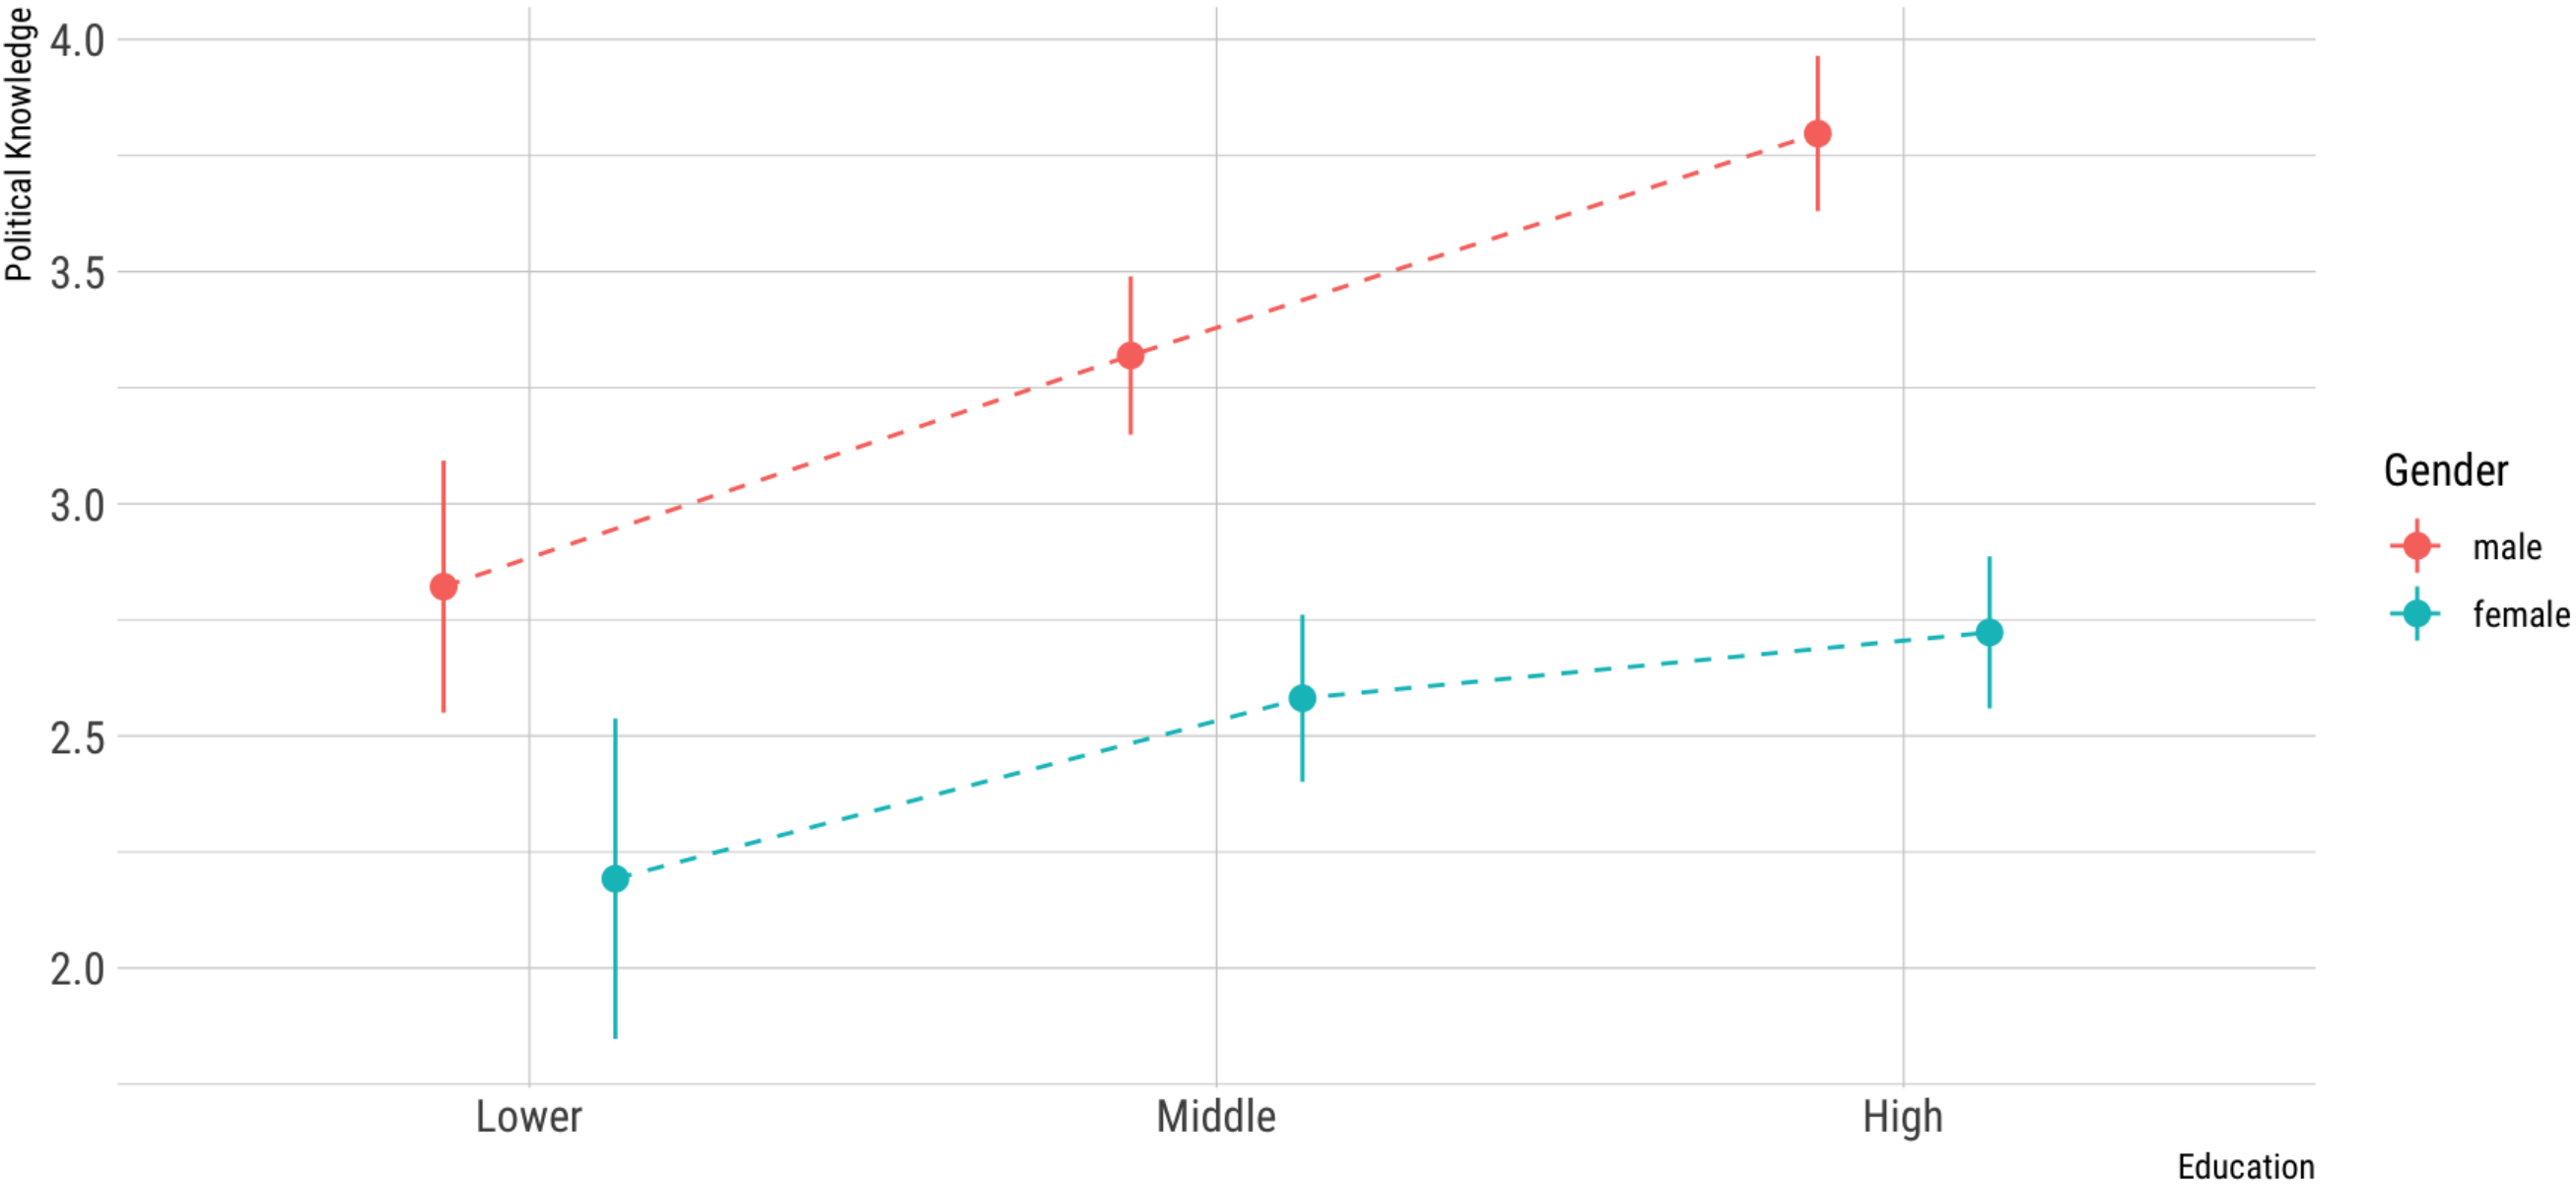
ERWEITERUNGEN

- dieselbe Analyselogik gilt auch für Moderatoren mit mehr als zwei Ausprägungen, d.h.
 - alle konditionalen Effekte gelten dann für die Referenzgruppe
 - es gibt jeweils $k - 1$ Haupt- und Interaktionseffekte
- in (zum Glück) seltenen Fällen gibt es auch 3-Wege-Interaktionen (2 Moderatoren)
 - Einbeziehung bzw. Berechnung der Interaktionsterme XZ_1 , XZ_2 und XZ_1Z_2
 - Interpretation doppelt konditionaler Effekt sehr kompliziert

BEISPIEL MODERATION MIT 3 GRUPPEN

Parameter	Coefficient	95% CI	t(987)	p	Std. Coef.	Fit
(Intercept)	2.82	(2.55, 3.09)	20.37	< .001	-0.16	
Gender (female)	-0.63	(-1.07, -0.19)	-2.81	0.005	-0.46	
Education (Middle)	0.50	(0.18, 0.82)	3.04	0.002	0.37	
Education (High)	0.98	(0.66, 1.30)	6.00	< .001	0.72	
Gender (female) × Education (Middle)	-0.11	(-0.61, 0.40)	-0.42	0.672	-0.08	
Gender (female) × Education (High)	-0.45	(-0.94, 0.05)	-1.75	0.080	-0.33	
AICc						3300.42
R2						0.14
R2 (adj.)						0.13
Sigma						1.27

BEISPIEL MODERATION MIT 3 GRUPPEN



BEISPIEL 3-WAY-INTERACTION

Table 3. Retweets of left troll tweets about presidential candidates or parties addressing outgroups, containing incivility, and based on troll persistence ($n = 2,586$)

	Model 1		Model 2		Model 3		Model 4	
	IRR	CI	IRR	CI	IRR	CI	IRR	CI
Intercept	0.23	0.14–0.37	0.25	0.16–0.39	0.22	0.14–0.34	0.23	0.15–0.36
URL present	3.79	3.19–4.52	3.88	3.26–4.63	3.87	3.25–4.61	3.71	3.12–4.42
Hashtag count	1.08	1.02–1.14	1.08	1.02–1.14	1.09	1.03–1.15	1.09	1.03–1.15
Mention count	0.52	0.45–0.61	0.52	0.45–0.60	0.52	0.45–0.60	0.52	0.45–0.60
Persistence			1.49	1.32–1.67	1.53	1.35–1.75	1.46	1.28–1.67
Discuss outgroup (0 = no; 1 = yes)			1.00	0.88–1.13	1.16	1.01–1.33	1.14	1.00–1.31
Incivility (0 = no; 1 = yes)			0.93	0.78–1.10	1.62	1.22–2.15	1.42	1.06–1.89
Persistence × Outgroup					0.92	0.83–1.03	1.03	0.91–1.16
Persistence × Incivility					1.01	0.88–1.17	1.62	1.27–2.07
Outgroup × Incivility					0.40	0.28–0.57	0.49	0.34–0.71
Persistence × Outgroup × Incivility							0.49	0.37–0.67

Quelle: Rains et al. (2023)

ZWISCHENFAZIT

- Moderationsanalysen mit kategoriellen Variablen sind technisch leicht durchführbar, erfordern aber eine neue Interpretation
- die Interpretation der stat. Signifikanz der Interaktionsterme ist einfach, die substantielle Interpretation schwierig
- durch Hinzunahme des Interaktionsterms werden aus den beteiligten Haupteffekten automatisch konditionale Effekte in der Referenzgruppe (!)
- die Koeffizienten der Prädiktoren ohne Interaktionsterm bleiben unkonditional (!)

Fragen?

Beispielanalyse: metrische Moderatoren

REGRESSION MIT METRISCHEM MODERATOR

- Anstelle einer dichotomen Variable kann man auch eine metrische Moderatorvariable berücksichtigt werden, hier zum Beispiel die Voreinstellung gegenüber dem schwäbischen Dialekt (atol).
- Hypothese: Je positiver die Einstellung zum schwäbischen Dialekt bei einer Versuchsperson, desto positiver der Effekt der Experimentalbedingung
- Reminder: der Koeffizient für Dialekt bezieht sich nun auf einen konkreten Wert von atol (konditionaler Effekt)

REGRESSION MIT METRISCHEM MODERATOR

Parameter	Coefficient	95% CI	t(359)	p	Std. Coef.	Fit
(Intercept)	4.19	(3.60, 4.79)	13.79	< .001	0.01	
schwab	-1.53	(-2.32, -0.74)	-3.80	< .001	-0.11	
atol	-0.12	(-0.29, 0.06)	-1.30	0.196	0.09	
schwab × atol	0.40	(0.17, 0.64)	3.40	< .001	0.18	
AICc						926.98
R2						0.05
R2 (adj.)						0.05
Sigma						0.86

Achtung: Der konditionale Effekt für Dialekt macht nur Sinn, wenn atol auch 0 sein kann (Skala ist aber 1-5!)

KONDITIONALE EFFEKTE DURCH ZENTRIERUNG

- Zentrierung von atol mit 1, d.h. Koeffizient für Dialekt gilt für atol = 1 (Minimum)


Parameter	Coefficient	95% CI	t(359)	p	Std. Coef.	Fit
(Intercept)	4.08	(3.65, 4.51)	18.69	< .001	0.10	
schwab	-1.13	(-1.69, -0.56)	-3.91	< .001	0.06	
atol - 1	-0.12	(-0.29, 0.06)	-1.30	0.196	0.09	
schwab × atol - 1	0.40	(0.17, 0.64)	3.40	< .001	0.18	
AICc						926.98
R2						0.05
R2 (adj.)						0.05
Sigma						0.86

CONDITIONAL EFFECTS

- wie bei Modellvorhersagen können wir für typische Werte des Moderators den Koeffizienten von X schätzen

term	atol	estimate	p.value	conf.low	conf.high
schwab	1	-1.13	0.00	-1.69	-0.56
schwab	2	-0.72	0.00	-1.07	-0.37
schwab	3	-0.32	0.00	-0.51	-0.13
schwab	4	0.08	0.50	-0.16	0.32
schwab	5	0.48	0.03	0.05	0.92

CONDITIONAL EFFECTS PLOT



JOHNSON-NEYMAN INTERVALLE

- es werden Intervallgrenzen geschätzt, jenseits derer die Regressionskoeffizienten von X signifikant sind

JOHNSON-NEYMAN INTERVAL

When atol is OUTSIDE the interval [3.35, 4.74], the slope of schwab is $p < .05$.

Note: The range of observed values of atol is [1.00, 5.00]

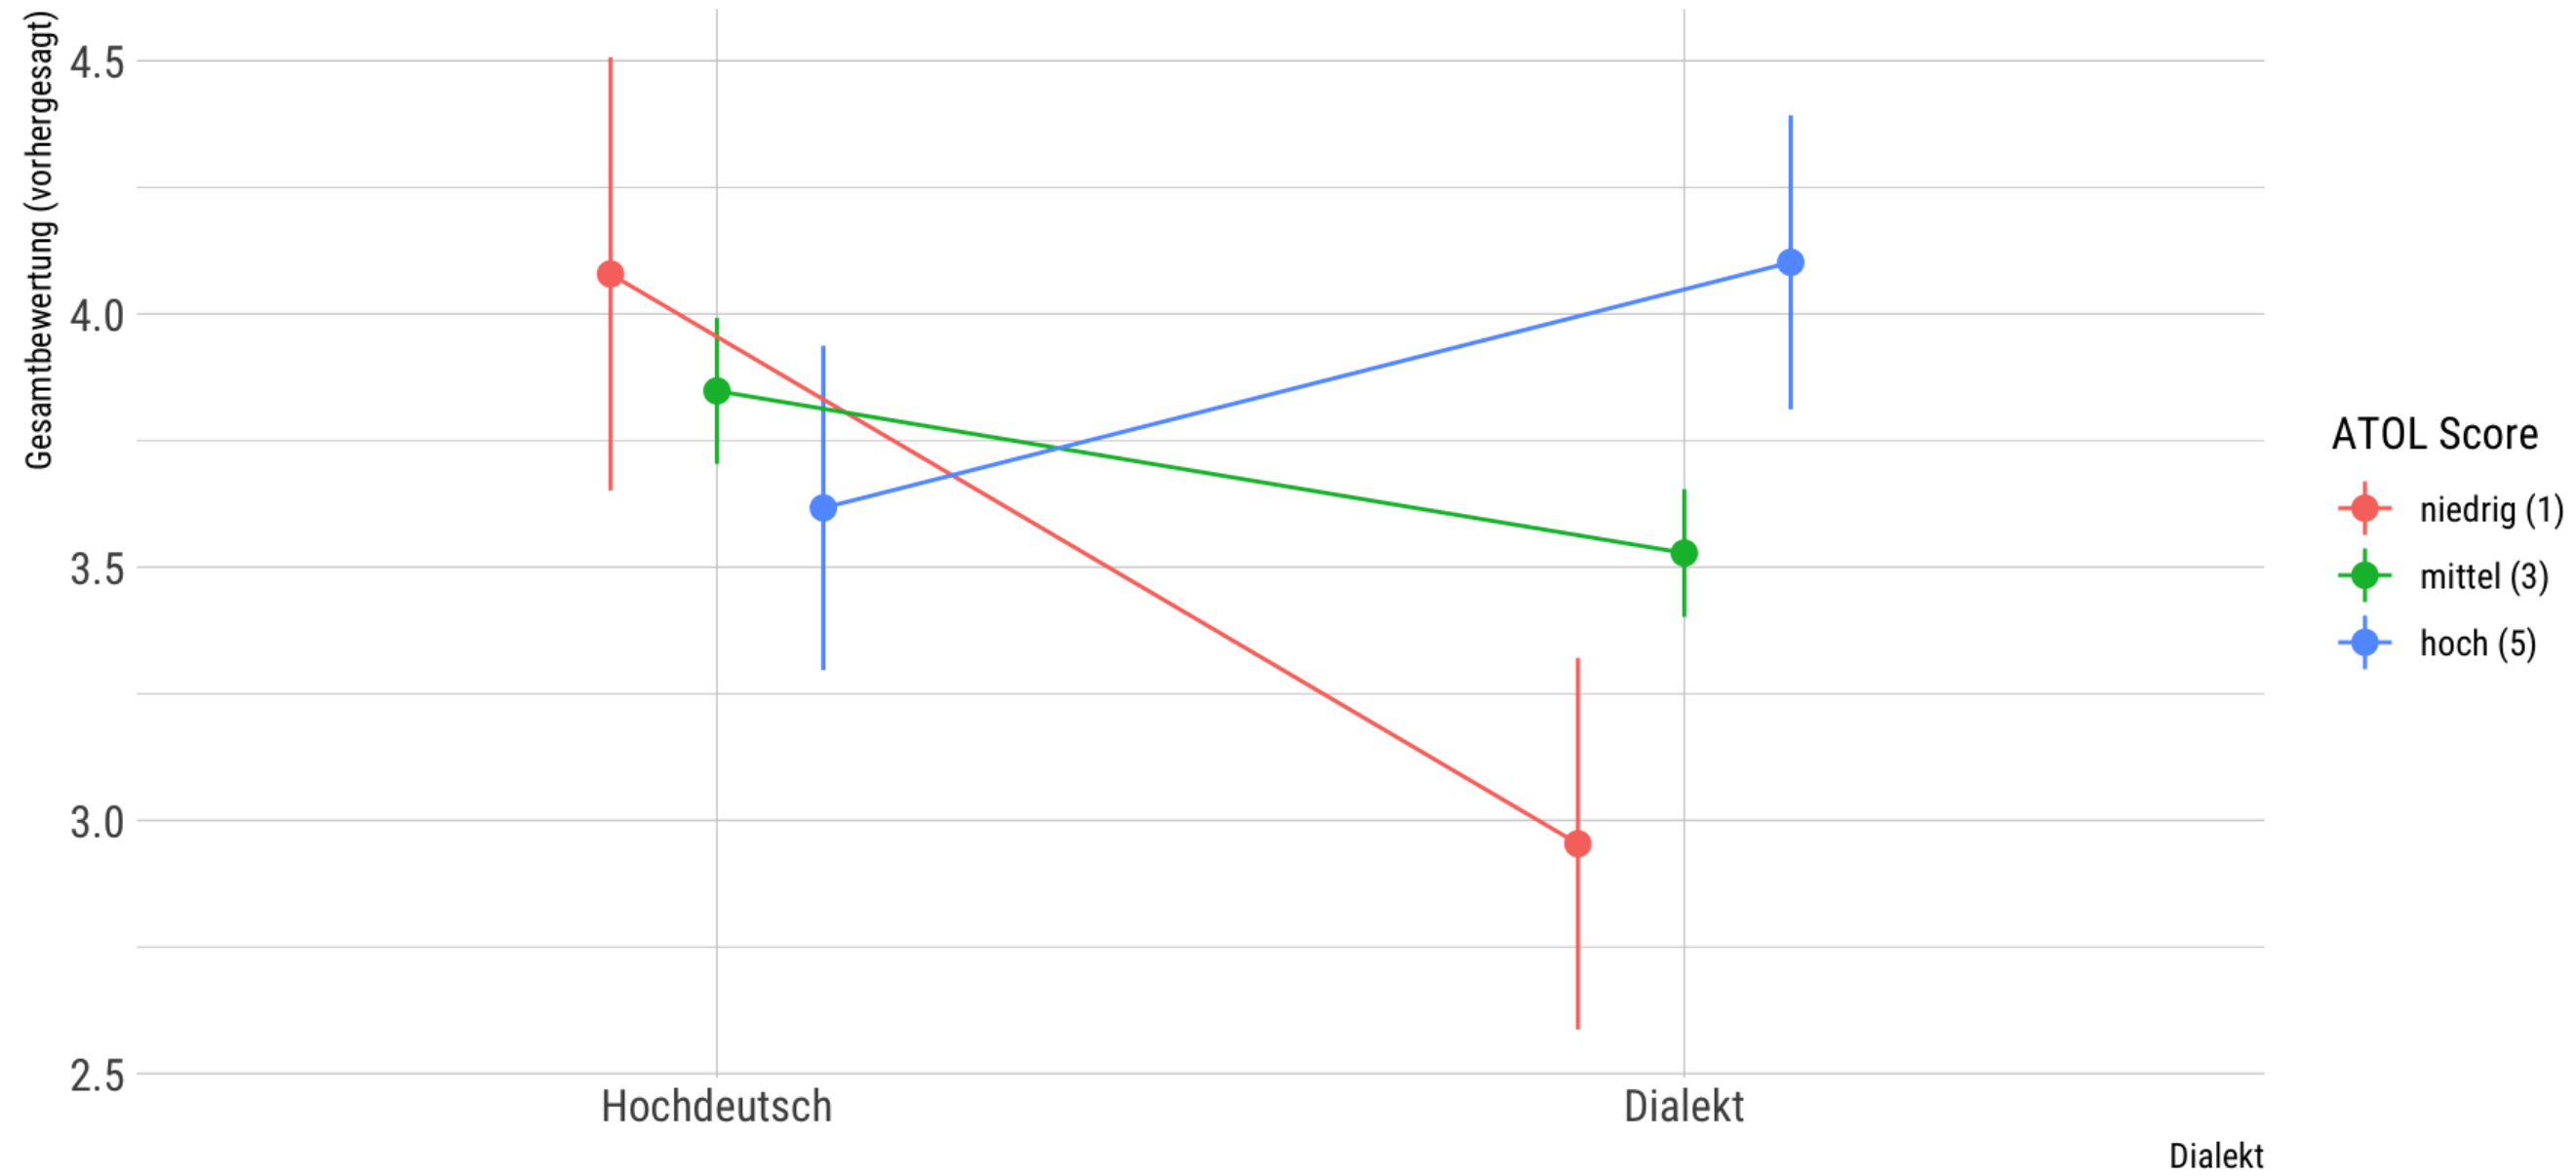
- Problem 1: Alpha-Fehler durch (sehr) häufige Tests
- Problem 2: “The difference between significant and insignificant is not itself significant” (Andrew Gelman), sprich: die Punkte, an denen die stat. Signifikanz “umspringt”, haben keinerlei besondere Eigenschaften
- nicht verwenden!

MODELLVORHERSAGEN

- wie immer lassen sich mit ausgewählten Werten der Prädiktoren auch Vorhersagen berechnen

schwab	atol	estimate	std.error	conf.low	conf.high
0	1	4.08	0.22	3.65	4.51
1	1	2.95	0.19	2.59	3.32
0	3	3.85	0.07	3.70	3.99
1	3	3.53	0.06	3.40	3.65
0	5	3.62	0.16	3.30	3.94
1	5	4.10	0.15	3.81	4.39

VISUALISIERUNG DER MODELLVORHERSAGEN



TIPPS

- auf korrekte Interpretation der Referenzgruppen achten bei kategorialen Moderatoren
- metrische Variablen zentrieren, die keinen interpretierbaren Nullpunkt haben, bevor man Interaktionsterme einfügt
- immer auch X und Z im Modell zu haben, wenn der Interaktionsterm XZ im Modell ist
- pragmatischer Vorschlag: wenn kein signifikanter Interaktionseffekt, dann lieber unkonditionales Modell (ohne Moderator) berichten
- substantielle Interpretation durch Berechnung und Visualisierung von conditional effects und Modellvorhersagen

FAZIT

- lineare Modelle mit Moderation sind in der Regel sehr (zu!) leicht zu spezifizieren, aber zumeist deutlich schwieriger substantiell zu interpretieren (außer Signifikanz des Interaktionseffekts)
- auch wenn die Regressionstabelle optisch sehr ähnlich aussieht, ändert sich Interpretation grundsätzlich
- viele SozialwissenschaftlerInnen interpretieren moderierte Effekte entweder gar nicht oder falsch
- Moderationshypothesen sind nicht per se theoretisch wertvoll, und auch bei Moderationsanalysen gibt es Alpha-Fehler

TAKE-HOME AUFGABE #3

Altay et al. (2022) untersuchen experimentell, ob falsche Nachrichten weniger als wahre geteilt werden, und wie dies von der Interessanztheit der Nachricht abhängt.

Beantworten Sie folgende Forschungsfragen mit Hilfe der Studien-Daten:

1. Werden wahre Nachrichten eher geteilt als falsche?
2. Werden interessante Nachrichten eher geteilt als uninteressante?
3. Gibt es den im Titel des Artikels angesprochenen Effekt eines zusätzlichen “interesting-if-true” Effekts auf das Teilen von Nachrichten? Wie fällt dieser aus?

TAKE-HOME AUFGABE #3

1. Stellen Sie die Ergebnisse des/der geschätzten Modells/Modelle sinnvoll tabellarisch oder grafisch dar (Screenshot reicht).
2. Beantworten Sie die Forschungsfragen anhand von Ihnen ausgewählter Kennwerte bzw. Quantities of Interest (2-3 Sätze pro Forschungsfrage)
3. Lösung als PDF-Datei bitte bis 03.07.2024, 12 Uhr in Moodle hochladen.

TAKE-HOME AUFGABE #3

```
# Daten laden  
altay22 = read_tsv("data/altay2022.tsv")
```

Share	Type	Interesting
2	TN	3
1	TN	6
1	TN	4

- **Share** = Wahrscheinlichkeit, die Nachricht mit anderen zu teilen (1-6, höher ist wahrscheinlicher)
- **Type** = Nachrichtentyp (experimentell variiert, **TN**=wahr, **FN**=falsch)
- **Interesting** = Wahrgenommene Interessanztheit der Nachricht (1-7, höher ist interessanter)

LITERATUR

Healy, K. (2017). Fuck nuance. *Sociological Theory*, 35(2), 118-127.

Rains, S. A., Harwood, J., Shmargad, Y., Kenski, K., Coe, K., & Bethard, S. (2023). Engagement with partisan Russian troll tweets during the 2016 US presidential election: a social identity perspective. *Journal of Communication*, 73(1), 38-48.

Valkenburg, P., Beyens, I., Pouwels, J. L., van Driel, I. I., & Keijsers, L. (2021). Social media use and adolescents' self-esteem: Heading for a person-specific media effects paradigm. *Journal of Communication*, 71(1), 56-78.

Vögele, C., & Bachl, M. (2017). Der Einfluss des Dialekts auf die Bewertung von Politikern. *SCM Studies in Communication and Media*, 6(2), 196-215.

Vuorre, M., Johannes, N., & Przybylski, A. K. (2022). Three objections to a novel paradigm in social media effects research.