

# Mehrebenenmodelle

Methoden der empirischen Kommunikations- und Medienforschung

Marko Bachl  
Freie Universität Berlin



FSI PuK

# Mehrebenenmodelle

# AGENDA (2 SITZUNGEN!)

1. Einführung und Begriffe
2. Beispielstudie
3. Null-Modell und Varianzzerlegung
4. L1-Prädiktoren im Random-Intercept-Modell
5. L2-Prädiktoren im Random-Intercept-Modell
6. Random-Slope-Modell und Cross-Level-Interaktion
7. Übungen

# COI: MEIN PROMOTIONSTHEMA

## **Analyse rezeptionsbegleitend gemessener Kandidatenbewertungen in TV-Duellen**

**Erweiterung etablierter Verfahren und Vorschlag einer  
Mehrebenenmodellierung**

Marko Bachl

(Bachl, 2014)

**Marko Bachl (2014): Analyse rezeptionsbegleitend gemessener Kandidatenbewertungen in TV-Duellen** Die Untersuchung der Bewertung von Kandidaten während einer TV-Debatte mit Real-Time-Response-Messungen hat sich in der politischen Kommunikationsforschung etabliert. Das Studiendesign ermöglicht es, detailliert zu erfassen, wie individuelle Rezipienten die Kandidaten infolge einzelner Aussagen bewerten. Um die Potenziale des aufwändigen Studiendesigns voll ausschöpfen zu können und der komplexen Datenstruktur der Echtzeitmessung sowohl theoretisch als auch statistisch gerecht zu werden, ist eine Reflexion über angemessene Analyseverfahren notwendig. In dieser Arbeit werden zum einen die etablierten analytischen Zugänge kritisch diskutiert und erweitert. Zum anderen wird eine Mehrebenenmodellierung vorgeschlagen, die sich in besonderer Weise eignet, die individuellen Prozesse der Kandidatenbewertungen abzubilden. Die etablierten Verfahren und die Mehrebenenmodellierung werden anhand einer Rezeptionsstudie zum TV-Duell vor der baden-württembergischen Landtagswahl 2011 praktisch demonstriert.

# Einführung und Begriffe

# WAS SIND MEHREBENEN-DATEN?

Hierarchisch: Level-1-Einheiten in Level-2-Einheiten (in Level-3-Einheiten ...)

- Schüler:innen | Klassen | Schulen | Bezirke | Bundesländer | Staaten
- Kommentare | Posts | Accounts
- Messungen | Personen (Panel-Daten: Personen sind L2-Einheiten)

Nicht-hierarchisch: Level-1-Einheit in Level-2a-Einheit und Level-2b-Einheit

- (Messung | Person) & (Messung | Stimulus) (Within-Subject-Experiment)
- (Artikel | Zeitung) & (Artikel | Publikationsjahr) (Längsschnittliche Inhaltsanalyse)

Hier zur Einführung: Hierarchische Struktur mit zwei Ebenen

# STRUKTURIERUNG DER DATEN

## ... als Störfaktor

- Regressionsannahme unabhängiger Fälle nicht erfüllt → zu kleine Standardfehler →  $\alpha$ -Fehler
- Analyse von L1-Variablen mit Anpassungen für Strukturierung
- Fixed-Effects-Modelle, cluster-robuste Standardfehler

## ... als inhaltlich interessante Eigenschaft der Daten

- Zerlegung der Varianz entlang der Strukturierung
- Adäquate Modellierung von Zusammenhängen mit Variablen auf verschiedenen Ebenen
- Mehrebenenmodelle

# GRUNDBEGRIFFE



Quelle: Chelsea Parlett auf Twitter; Sehr nerdig-lustig auf TikTok: @chelseaparlett

# GRUNDBEGRIFFE

- Mehrebenenmodell = Mehrebenenregression = multilevel model = mixed effects model = ...
- Null-Modell: Modell ohne Prädiktoren, das nur die Mehrebenenstruktur der Daten abbildet
- Between-Group-Varianz = Varianz, die durch Unterschiede in den Level-2-Einheiten erzeugt wird
- Within-Group-Varianz = Varianz, die durch Unterschiede der Level-1-Einheiten innerhalb derselben Level-2-Einheit erzeugt wird
- Fixed Effects = Zusammenhänge, die in allen Level-2-Kontexten gleich sind
- Random (Varying) Effects (Intercepts/Slopes) = Koeffizienten von L1-Variablen, die über die Level-2-Kontexte variieren
- Cross-Level-Interaktion = Zusammenhang zwischen Level-1-Effekt und Level-2-Kontextmerkmalen

Fragen?

# Beispielstudie

# DATEN DER HEUTIGEN SITZUNG

## Evaluating universities' strategic online communication: how do Shanghai Ranking's top 50 universities grow stakeholder engagement with Facebook posts?

Birte Fähnrich

*Berlin-Brandenburgische Akademie der Wissenschaften, Berlin, Germany*

Jens Vogelgesang

*Department of Communication, University of Hohenheim, Stuttgart, Germany and Computational Science Lab (CSL), University of Hohenheim, Stuttgart, Germany, and*

Michael Scharkow

*Department of Communication, Johannes Gutenberg University Mainz, Mainz, Germany*

### Abstract

**Purpose** – This study is dedicated to universities' strategic social media communication and focuses on the fan engagement triggered by Facebook postings. The study contributes to a growing body of knowledge that addresses the strategic communication of universities that have thus far hardly dealt with questions of resonance and evaluation of their social media messages.

**Design/methodology/approach** – Using the Facebook Graph API, the authors collected posts from the official Facebook fan pages of the universities listed on Shanghai Ranking's Top 50 of 2015. Specifically, the authors retrieved all posts in a three-year range from October 2012 to September 2015. After downloading the Facebook posts, the authors used tools for automated content analysis to investigate the features of the post messages.

**Findings** – Overall, the median number of likes per 10,000 fans was 4.6, while the number of comments (MD = 0.12) and shares (MD = 0.40) were considerably lower. The average Facebook Like Ratio of universities per 10,000 fans was 17.93%, the average Comment Ratio (CR) was 0.56% and the average Share Ratio (SR) was 2.82%. If we compare the average Like Ratios (17.93%) and Share Ratios (2.82%) of the universities with the respective Like Ratios (5.90%) and Share Ratios (0.45%) of global brands per 10,000 fans, we may find that universities are three times (likes) and six times (shares) as successful as are global brands in triggering engagement among their fan bases.

**Research limitations/implications** – The content analysis was solely based on the publicly observable Facebook communication of the Top 50 Shanghai Ranking universities. Furthermore, the content analysis was limited to universities listed on the Shanghai Ranking's Top 50. Also, the Facebook posts have been sampled between 2012 and September 2015. Moreover, the authors solely focused on one social media channel (i.e., Facebook), which might restrict the generalizability of the study findings. The limitations notwithstanding, university communicators are invited to take advantage of the study's insights to become more successful in generating fan engagement.

**Practical implications** – First, posts published on the weekend generate significantly more engagement than those published on workdays. Second, the findings suggest that posts published in the evening generate more engagement than those published during other times of day. Third, research-related posts trigger a certain number of shares, but at the same time these posts tend to lower engagement with regard to liking and commenting.

**Originality/value** – To the authors' best knowledge, the automated content analysis of 72,044 Facebook posts of universities listed in the Top 50 of the Shanghai Ranking is the first large scale longitudinal investigation of a social media channel of higher education institutions.

**Keywords** Strategic communication, Universities, Engagement, Evaluation, Social media, Facebook, Content analysis, **Multilevel regression**, Global brands

(Fähnrich et al., 2020)

# STICHPROBE: STRUKTUR

<b>uni</b>	<b>n_posts</b>
Columbia U	576
Cornell U	404
Duke U	323
Harvard U	203
Imperial College London	179
Johns Hopkins U	481
MIT	243
New York U	407
Northwestern U	141
Princeton U	507
Rockefeller U	218
Stanford U	145
U Illinois	236
U Pennsylvania	608
U Toronto	99
U Washington	366
U Wisconsin-Madison	203

- Teilstichprobe: 10391 Posts von 42 Facebookseiten von Universitäten
- Nicht alle Prädiktoren
- Ergebnisse aus Fährnich et al. (2020) nicht genau reproduzierbar.

U British Columbia	207
U California	321
U Cambridge	207
U Chicago	151
U Colorado Boulder	245
U Edinburgh	43
U Manchester	87
U Maryland	143
U Melbourne	155
U Michigan	158
U Minnesota	143
U Oxford	167
U Southern California	239
UC Berkeley	280
UC Irvine	326

# STICHPROBE: UNABHÄNGIGE VARIABLEN (L1)

Descriptive Statistics

Variable	Summary
timeofday [morning], %	38.3
timeofday [afternoon], %	46.1
timeofday [evening], %	14.2
timeofday [night], %	1.4
type [status], %	5.4
type [link], %	37.4
type [photo], %	48.9
type [video], %	8.3
year [2015], %	26.9
year [2012], %	7.6
year [2013], %	32.8
year [2014], %	32.6

Descriptive Statistics

Variable	Summary
topic_research [yes], %	28.0
topic_teaching [yes], %	25.6
topic_awards [yes], %	5.7
topic_event [yes], %	35.1
topic_interact [yes], %	37.2
topic_self [yes], %	16.8
Mean word_count (SD)	30.81 (24.71)
day_type [weekend], %	13.8

In der Vorlesung verwenden wir nur einen kleinen Auszug der unabhängigen L1-Variablen. Für die Übung stellen wir ein umfangreicheres Modell ähnlich wie in der Publikation zusammen.

# STICHPROBE: ABHÄNGIGE VARIABLEN (L1)

<b>Variable</b>	<b>n_Obs</b>	<b>Mean</b>	<b>SD</b>	<b>Median</b>	<b>MAD</b>	<b>Min</b>	<b>Max</b>	<b>Skewness</b>	<b>Kurtosis</b>	<b>percent</b>
likes_count	10391	425.22	1153.04	108	130.47	0	24847	9.10	129.01	
comments_count	10391	12.18	36.54	3	4.45	0	1556	15.73	456.79	
shares_count	10391	62.60	1441.28	9	11.86	0	145480	98.92	9976.61	

In der Vorlesung erklären wir die Zahl der Kommentare. In der Übung betrachten wir auch die Zahl der Shares und Likes.

# STICHPROBE: UNABHÄNGIGE VARIABLEN (L2)

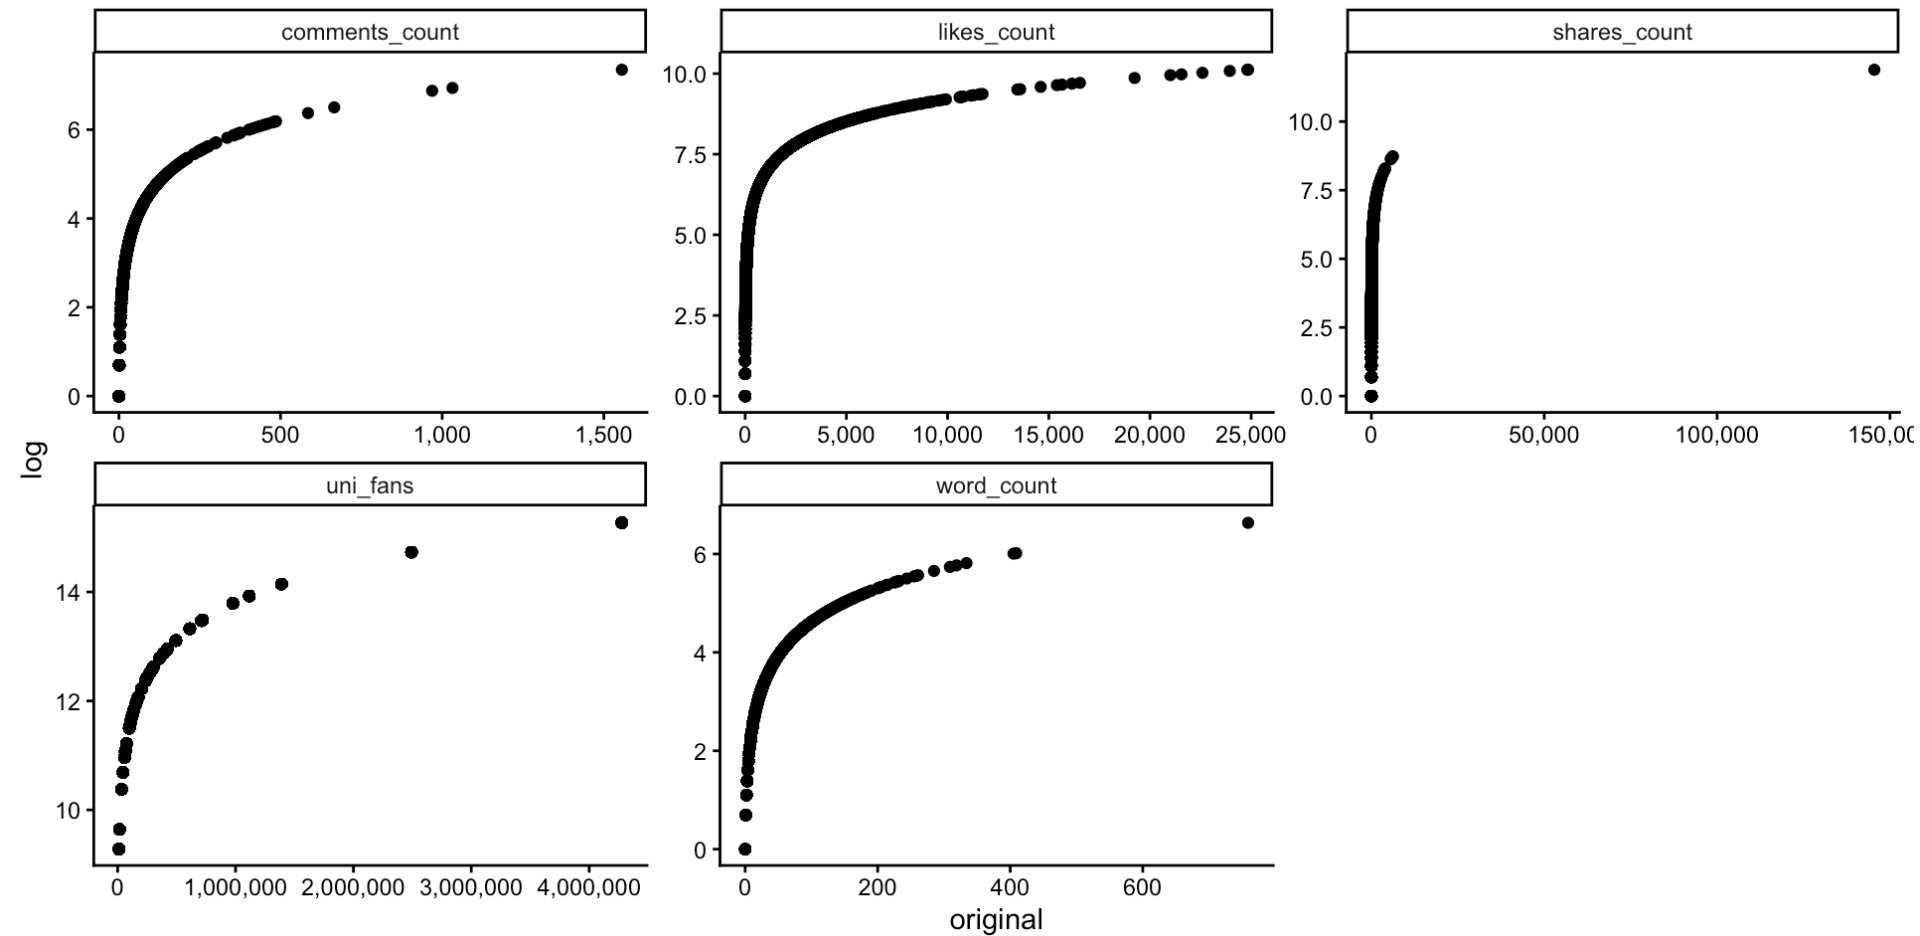
## Descriptive Statistics

<b>Variable</b>	<b>Summary</b>
Mean uni_fans (SD)	435063.17 (758868.02)
uni_us [US], %	85.7

# STICHPROBE: LOG-TRANSFORMATION

```
1 d <- d |>
2   mutate(
3     word_count_log = log1p(word_count),
4     uni_fans_log = log(uni_fans),
5     likes_count_log = log1p(likes_count),
6     comments_count_log = log1p(comments_count),
7     shares_count_log = log1p(shares_count)
8   )
```

# STICHPROBE: LOG-TRANSFORMATION



- Wiederholung: Bivariate Regression, vor allem Transformation von Variablen im Regressionsmodell

# STICHPROBE: DATENSATZ IM “LONG FORMAT”

<b>comments_count_log</b>	<b>topic_research</b>	<b>uni</b>	<b>uni_fans_log</b>
0.00	no	Columbia U	12.37
0.69	no	Columbia U	12.37
0.69	no	Columbia U	12.37
2.77	no	Columbia U	12.37
0.00	no	Cornell U	12.52
4.03	no	Cornell U	12.52
0.69	yes	Cornell U	12.52
1.61	no	Cornell U	12.52
1.61	no	Duke U	12.58

<b>comments_count_log</b>	<b>topic_research</b>	<b>uni</b>	<b>uni_fans_log</b>
---------------------------	-----------------------	------------	---------------------

---

0.00

no

Duke U

12.58

[...]

Fragen?

# Null-Modell und Varianzzerlegung

# NULL-MODELL MIT RANDOM INTERCEPTS

Das Null-Modell mit  $i$  Individuen in  $j$  Gruppen besteht aus je einem Null-Modell pro Ebene:

$$\text{Level 1: } y_{ij} = b_{0j} + \epsilon_{ij}$$

$$\text{Level 2: } b_{0j} = \gamma_{00} + u_{0j}$$

$$\text{oder zusammengenommen: } y_{ij} = \gamma_{00} + u_{0j} + \epsilon_{ij}$$

$\gamma_{00}$  ist der gewichtete Mittelwert von  $y$ ,  $u_{0j}$  ist die gruppenspezifische Abweichung vom gewichteten Mittelwert und  $\epsilon_{ij}$  ist das individuelle Residuum.

# NULL-MODELL MIT RANDOM INTERCEPTS

- Eine **1** anstelle von Variablennamen spezifiziert ein Modell nur mit Intercepts.
- Im Paket **{lme4}** In Klammern und mit **|** wird die Struktur des Modells spezifiziert: **(1 | uni)**.


```
1 m0 <- lmer( # Funktion für lineares Mehrebenenmodell
2   comments_count_log ~ # abhängige Variable
3     1 + # Gewichteter Gesamtmittelwert
4     (1 | uni), # Struktur des Modells
5   data = d
6 ) # Daten
```

# NULL-MODELL MIT RANDOM INTERCEPTS

Parameter	Coefficient	95% CI	t(10388)	p	Effects	Group	Fit
(Intercept)	1.72	(1.47, 1.96)	13.73	< .001	fixed		
	0.81				random	uni	
	1.01				random	Residual	
R2 (conditional)							0.39
R2 (marginal)							0.00

- $b_0 = 1.72$ : Gewichteter Mittelwert (grand mean) der logarithmierten Zahl der Kommentare
- $u_{0j} = 0.81$ : Standardabweichung der Abweichungen der Unis von diesem Mittelwert
- $\epsilon_{ij} = 1.01$ : Standardabweichung der L1-Residen; Abweichung der beobachteten Zahl der Kommentare der einzelnen Posts von der Modellvorhersage.

# VORHERSAGE DES NULL-MODELLS



# INTRA-CLASS-CORRELATION (ICC)

- Null-Modell dient vor allem der Berechnung der Intra-Class-Correlation (ICC).
- ICC = Anteil der Varianz in einer Variable, der durch die Kontexte (L2) erklärt wird.
- Technisch: der Anteil Between-Group-Varianz (also die Varianz von  $u_{0j}$ ) an der Gesamtvarianz von  $y$ .
- Wenn der ICC hoch ist (viel Gruppenvarianz), lohnt sich die Betrachtung von Level-2-Prädiktoren
- Wenn der ICC niedrig ist (wenig Gruppenvarianz), sind Level-1-Prädiktoren ein sinnvolleres Ziel
- Selbst bei kleinem ICC ist Mehrebenenanalyse sinnvoll, da sie nie “schlechter” als ein einfaches Regressionsmodell ist.

# INTRA-CLASS-CORRELATION (ICC)

<b>Group</b>	<b>ICC</b>
uni	0.39

$$1 \quad 0.81^2 / (0.81^2 + 1.01^2)$$

[1] 0.3914211

- 39% der Varianz in der logarithmierten Zahl der Kommentare können durch Unterschiede zwischen den Facebook-Seiten der Unis (L2-Einheiten) erklärt werden.
- Es lohnt sich, L2-Prädiktoren zu berücksichtigen.
- Ein Modell, dass die Struktur in den Daten nicht berücksichtigt, wäre falsch spezifiziert und hätte erhöhte  $\alpha$ -Fehler-Gefahr.

Fragen?

# L1-Prädiktoren im Random-Intercept-Modell

# L1-PRÄDIKTOREN IM RANDOM-INTERCEPT-MODELL

- Intercepts dürfen gruppenspezifisch variieren, Regressionskoeffizienten  $\beta$  sind für alle Level-2-Einheiten gleich

$$y_{ij} = \gamma_{00} + u_{0j} + \beta_1 x_1 + \beta_2 x_2 + \dots + \epsilon_{ij}$$

- Die variierenden Intercepts  $u_{0j}$  sind die Abweichungen der Level-2-Einheiten vom globalen Intercept.
- Ausgabe und Interpretation der Regressionskoeffizienten entspricht dem bekannten linearen Regressionsmodell.
- Standardisierte Koeffizienten sind eher unüblich, da nicht klar ist, an welcher Standardabweichung die Standardisierung vorgenommen werden soll.

# L1-PRÄDIKTOREN IM RANDOM-INTERCEPT-MODELL

- In Klammern und mit | wird die Struktur des Modells spezifiziert: `(1 | uni)`.
- Die Prädiktoren werden wie gewohnt in die Modell-Formel geschrieben.
- Hier: Erklärung der logarithmierten Zahl der Kommentare zu einem Post durch drei binäre Variablen, die angeben, ob die Themen Interaktion, Forschung und Lehre vorkommen.


```
1 m1 <- lmer( # Funktion für lineares Mehrebenenmodell
2   comments_count_log ~ # abhängige Variable
3     topic_interact + topic_research + topic_teaching + # Prädiktoren
4     (1 | uni), # Struktur des Modells
5   data = d
6 )
```

# L1-PRÄDIKTOREN IM RANDOM-INTERCEPT-MODELL

Parameter	Coefficient	95% CI	t(10385)	p	Effects	Group	Fit
(Intercept)	1.77	(1.52, 2.01)	14.13	< .001	fixed		
topic interact (yes)	0.08	(0.04, 0.12)	3.98	< .001	fixed		
topic research (yes)	-0.20	(-0.24, -0.15)	-8.68	< .001	fixed		
topic teaching (yes)	-0.09	(-0.13, -0.04)	-3.76	< .001	fixed		
	0.80				random	uni	
	1.00				random	Residual	
R2 (conditional)							0.39
R2 (marginal)							0.01

- Wie Regressionskoeffizienten in der einfachen linearen Regression: Posts zum Thema Forschung erhalten zu ansonsten thematisch vergleichbaren Posts etwa 20% (genauer:  $e^{-0.20} - 1 = -18\%$  — log-transformierte aV) weniger Kommentare als Posts, in denen Forschung nicht vorkommt.
- Zwei  $R^2$ -Werte (Nakagawa et al., 2017):
  - Conditional  $R^2$ : Das gesamte Modell inklusive der Mehrebenenstruktur (hier: Random Intecepts für die Uni-Seiten) erklärt 39% der Varianz in der logarithmierten Zahl der Kommentare.
  - Marginal  $R^2$ : Die Fixed Effects (hier: Themen der Posts) erklären zusätzlich zur Mehrebenenstruktur 1% der Varianz in der logarithmierten Zahl der Kommentare.

# L1-PRÄDIKTOREN IM RANDOM-INTERCEPT-MODELL



Fragen?

# L2-Prädiktoren im Random-Intercept-Modell

# L2-PRÄDIKTOREN IM RANDOM-INTERCEPT-MODELL

- L2-Prädiktoren werden genau wie L1-Prädiktoren in die Modell-Formel eingefügt.


```
1 m2 <- lmer(comments_count_log ~ topic_interact + topic_research +  
2   topic_teaching + uni_fans_log + (1 | uni), data = d)
```

## L2-PRÄDIKTOREN IM RANDOM-INTERCEPT-MODELL

Parameter	Coefficient	95% CI	t(10384)	p	Effects	Group	Fit
(Intercept)	-4.88	(-6.32, -3.44)	-6.65	< .001	fixed		
topic interact (yes)	0.09	(0.04, 0.13)	4.07	< .001	fixed		
topic research (yes)	-0.20	(-0.24, -0.15)	-8.67	< .001	fixed		
topic teaching (yes)	-0.09	(-0.13, -0.04)	-3.77	< .001	fixed		
uni fans log	0.54	(0.43, 0.66)	9.10	< .001	fixed		
	0.46				random	uni	
	1.00				random	Residual	
R2 (conditional)							0.38
R2 (marginal)							0.25

- Wenn wir zwei Posts mit denselben Themen vergleichen, die auf zwei unterschiedlichen Seiten veröffentlicht wurden, erhält der Post auf einer Seite mit 1% mehr Fans um 0.54% mehr Kommentare.
- Etwas zugespitzt: Wenn wir zwei Posts mit denselben Themen vergleichen, die auf zwei unterschiedlichen Seiten veröffentlicht wurden, erhält der Post auf einer Seite mit doppelt so vielen Fans (100% mehr) etwa 50% mehr Kommentare.
- Ein L2-Prädiktor kann nur Between-Group-Varianz erklären:
  - Modell ohne L2-Prädiktor:  $SD_{u_{0j}} = 0.80$ ;  $SD_{\epsilon_{ij}} = 1.00$
  - Modell mit L2-Prädiktor **uni fans log**:  $SD_{u_{0j}} = 0.46$ ;  $SD_{\epsilon_{ij}} = 1.00$

# L2-PRÄDIKTOREN IM RANDOM-INTERCEPT-MODELL



Fragen?

# Random-Slope-Modell und Cross-Level-Interaktion

# RANDOM-SLOPE-MODELL

- Zusätzlich zu Random Intercepts können wir auch Regressionskoeffizienten von L1-Prädiktoren zwischen den L2-Einheiten variieren lassen.
- Entspricht konzeptionell einer Interaktion zwischen einem Prädiktor und einem Strukturierungsmerkmal.
- Effektheterogenität zwischen Gruppen schätzen und explorieren
- Voraussetzung für Cross-Level-Interaktionen zwischen L1- und L2-Prädiktoren
- Ob die Berücksichtigung eines Random Slope das Modell verbessert, prüfen wir mit einem Modellvergleich.

# RANDOM-SLOPE-MODELL

- Der Prädiktor, dessen Koeffizienten wir zwischen den Uni-Seiten variieren wollen lassen, fügen wir in den Klammern vor dem | ein: `(topic_research | uni)`.
- Damit fügen wir dem Modell 2 Parameter hinzu: Die Varianz des Koeffizienten zwischen den Gruppen und die Kovarianz zwischen den Random Intercepts und den Random Slopes.

```
1 m3 <- lmer(  
2   comments_count_log ~ topic_interact + topic_research +  
3   topic_teaching + uni_fans_log +  
4   (topic_research | uni), # Koeffizient von topic_research darf zwischen Uni-Seiten variieren  
5   data = d  
6 )
```

## RANDOM-SLOPE-MODELL: MODELLVERGLEICH

Modell	npar	AIC	BIC	logLik	-2*log(L)	Chisq	Df	Pr(>Chisq)
Random Intercept	7	29744.85	29795.59	-14865.43	29730.85			
Random Slope	9	29729.08	29794.32	-14855.54	29711.08	19.77	2	0.00

- Mit der Funktion `anova(m2, m3)` vergleichen wir das Random-Intercept-Modell mit dem Random-Slope-Modell.
- *AIC* und *BIC* sind Informationskriterien. Sie quantifizieren die Passung des Modells relativ zur Modellkomplexität. Niedrigere Werte sprechen für eine bessere Passung zu den Daten.
- *logLik* = Logarithmus der Likelihood: Dieser Wert wird bei der Modellschätzung mit Maximum-Likelihood-Methoden optimiert. Interessiert uns hier inhaltlich nicht.
- Auf Basis der Deviance ( $-2 * \log\text{Lik}$  — aber egal) können wir einen Signifikanz-Test für die Verbesserung der Modellpassung durch die weiteren Parameter berechnen. Die Differenz der Deviance ist mit der Differenz der Parametern als Freiheitsgraden  $\chi^2$ -verteilt unter der  $H_0$ , dass beide Modelle gleich gut zu den Daten passen.
- Hier: Das Modell, in dem der Koeffizient des Themas Forschung zwischen den Uni-Seiten variiert, passt statistisch signifikant besser zu den Daten:  $\chi^2(2) = 19.77, p < .001$

# RANDOM-SLOPE-MODELL: FIXED EFFECTS

<b>Parameter</b>	<b>Coefficient</b>	<b>95% CI</b>	<b>t(10382)</b>	<b>p</b>
(Intercept)	-4.87	(-6.29, -3.44)	-6.68	< .001
topic interact (yes)	0.09	(0.04, 0.13)	4.06	< .001
topic research (yes)	-0.20	(-0.27, -0.13)	-5.40	< .001
topic teaching (yes)	-0.08	(-0.13, -0.04)	-3.61	< .001
uni fans log	0.54	(0.43, 0.66)	9.15	< .001

- Die Interpretation der Fixed-Effects-Koeffizienten bleibt unverändert.


# RANDOM-SLOPE-MODELL: RANDOM EFFECTS

## Random Effects

<b>Parameter</b>	<b>Coefficient</b>	<b>95% CI</b>
SD (Intercept: uni)	0.46	
SD (topic_researchyes: uni)	0.18	
Cor (Intercept~topic_researchyes: uni)	-0.17	
SD (Residual)	1.00	

- Mit einer Standardabweichung von 0.18 besteht im Vergleich zum Fixed-Effects-Koeffizienten des Themas Forschung (-0.20) eine substantiell bedeutsame Varianz.
- Es gibt eine negative Korrelation zwischen Random Intercept und Random Slope auf Ebene der Uni-Seiten. Je mehr Kommentare ein Post einer Seite im Durchschnitt erhält, desto negativer ist der Effekt des Themas Forschung auf die Zahl der Kommentare.
- Inferenzstatistik für Random Intercepts und Random Slopes ist nicht trivial. Wir verzichten hier darauf und interpretieren die Werte nur bezogen auf die Stichprobe.

# RANDOM-SLOPE-MODELL: RANDOM EFFECTS



# CROSS-LEVEL-INTERAKTION

- Cross-Level-Interaktion = Zusammenhang zwischen L1-Effekt und L2-Kontextmerkmalen
- Voraussetzung Effektheterogenität: Nur wenn die Effekte zwischen den Gruppen variieren, kann eine Interaktion mit einer L2-Variable diese Heterogenität erklären.
- Die Interaktion spezifizieren wir wie in der einfachen Regression mit `*`, also `topic_research * uni_fans_log`.

```
1 m4 <- lmer(comments_count_log ~ topic_interact +  
2   topic_research * uni_fans_log + # Cross-Level-Interaktion  
3   topic_teaching + (topic_research | uni), data = d)
```

# CROSS-LEVEL-INTERAKTION

Parameter	Coefficient	95% CI	t(10381)	p
(Intercept)	-5.11	(-6.57, -3.65)	-6.88	< .001
topic interact (yes)	0.09	(0.04, 0.13)	4.06	< .001
topic research (yes)	0.38	(-0.31, 1.08)	1.08	0.282
uni fans log	0.56	(0.44, 0.68)	9.29	< .001
topic teaching (yes)	-0.08	(-0.13, -0.04)	-3.60	< .001
topic research (yes) × uni fans log	-0.05	(-0.10, 0.01)	-1.64	0.100

- Die Interaktion zwischen dem Thema Forschung und der logarithmierten Zahl der Fans ist **nicht** statistisch signifikant.
- Die Interpretation erfolgt wie im einfachen Regressionsmodell am besten mit Grafiken.

# CROSS-LEVEL-INTERAKTION



- Wäre die Interaktion statistisch signifikant: Je mehr Fans eine Seite hat, desto weniger Kommentare erhalten Posts zum Thema Forschung.
- Wiederholung: Moderation und Interaktion

Fragen?

# FAZIT

- In der Kommunikationswissenschaft (und darüber hinaus) sind Mehrebenen-Daten nahezu überall anzutreffen, sei es bei Inhaltsanalysen, Panel- oder Mehrländer-Befragungen.
- Oft sind auch Personen die Level-2-Einheiten, z.B. bei Experience-Sampling-Daten oder Within-Subject-Experimenten.
- Die Grundlogik des linearen Mehrebenenmodells entspricht der multiplen linearen Regression (hier: Interpretation der Fixed-Effects-Koeffizienten; Interaktionsterme; auch möglich: Mehrebenen-SEM und Mehrebenen-Mediation, verallgemeinerte lineare Mehrebenenmodelle).
- Berücksichtigung der Mehrebenen-Struktur im Modell vermeidet Fehler (Verletzung der Annahme unabhängiger Beobachtungen) und schafft inhaltlichen Mehrwert (Varianz-Zerlegung mit ICC, L2-Prädiktoren, Effektheterogenität).

# HAUSAUFGABE

1. Reproduzieren Sie die Mehrebenenmodelle aus der Vorlesung. Interpretieren Sie die Ergebnisse.
2. Schätzen Sie die umfangreicheren Modelle im Übungsskript. Passen Sie die Modelle nach Ihren Interessen an. Interpretieren Sie die Ergebnisse.

# Nächste Einheit

Noch nicht entschieden

# Danke

Marko Bachl

[marko.bachl@fu-berlin.de](mailto:marko.bachl@fu-berlin.de)

# LITERATUR

Bachl, M. (2014). *Analyse rezeptionsbegleitend gemessener Kandidatenbewertungen in TV-Duellen*. epubli.  
<https://d-nb.info/1058399934/34>

Fähnrich, B., Vogelgesang, J., & Scharkow, M. (2020). Evaluating universities' strategic online communication: how do Shanghai Ranking's top 50 universities grow stakeholder engagement with Facebook posts? *Journal of Communication Management*, 24(3), 265–283. <https://doi.org/10/gmjs23>

Nakagawa, S., Johnson, P. C. D., & Schielzeth, H. (2017). The coefficient of determination  $R^2$  and intra-class correlation coefficient from generalized linear mixed-effects models revisited and expanded. *Journal of The Royal Society Interface*, 14(134), 20170213. <https://doi.org/10/gddpnq>