

# Lineare Gemischte Modelle (5) – Anwendungen, $R^2$ , Modellvergleiche



We are happy to share our materials openly:

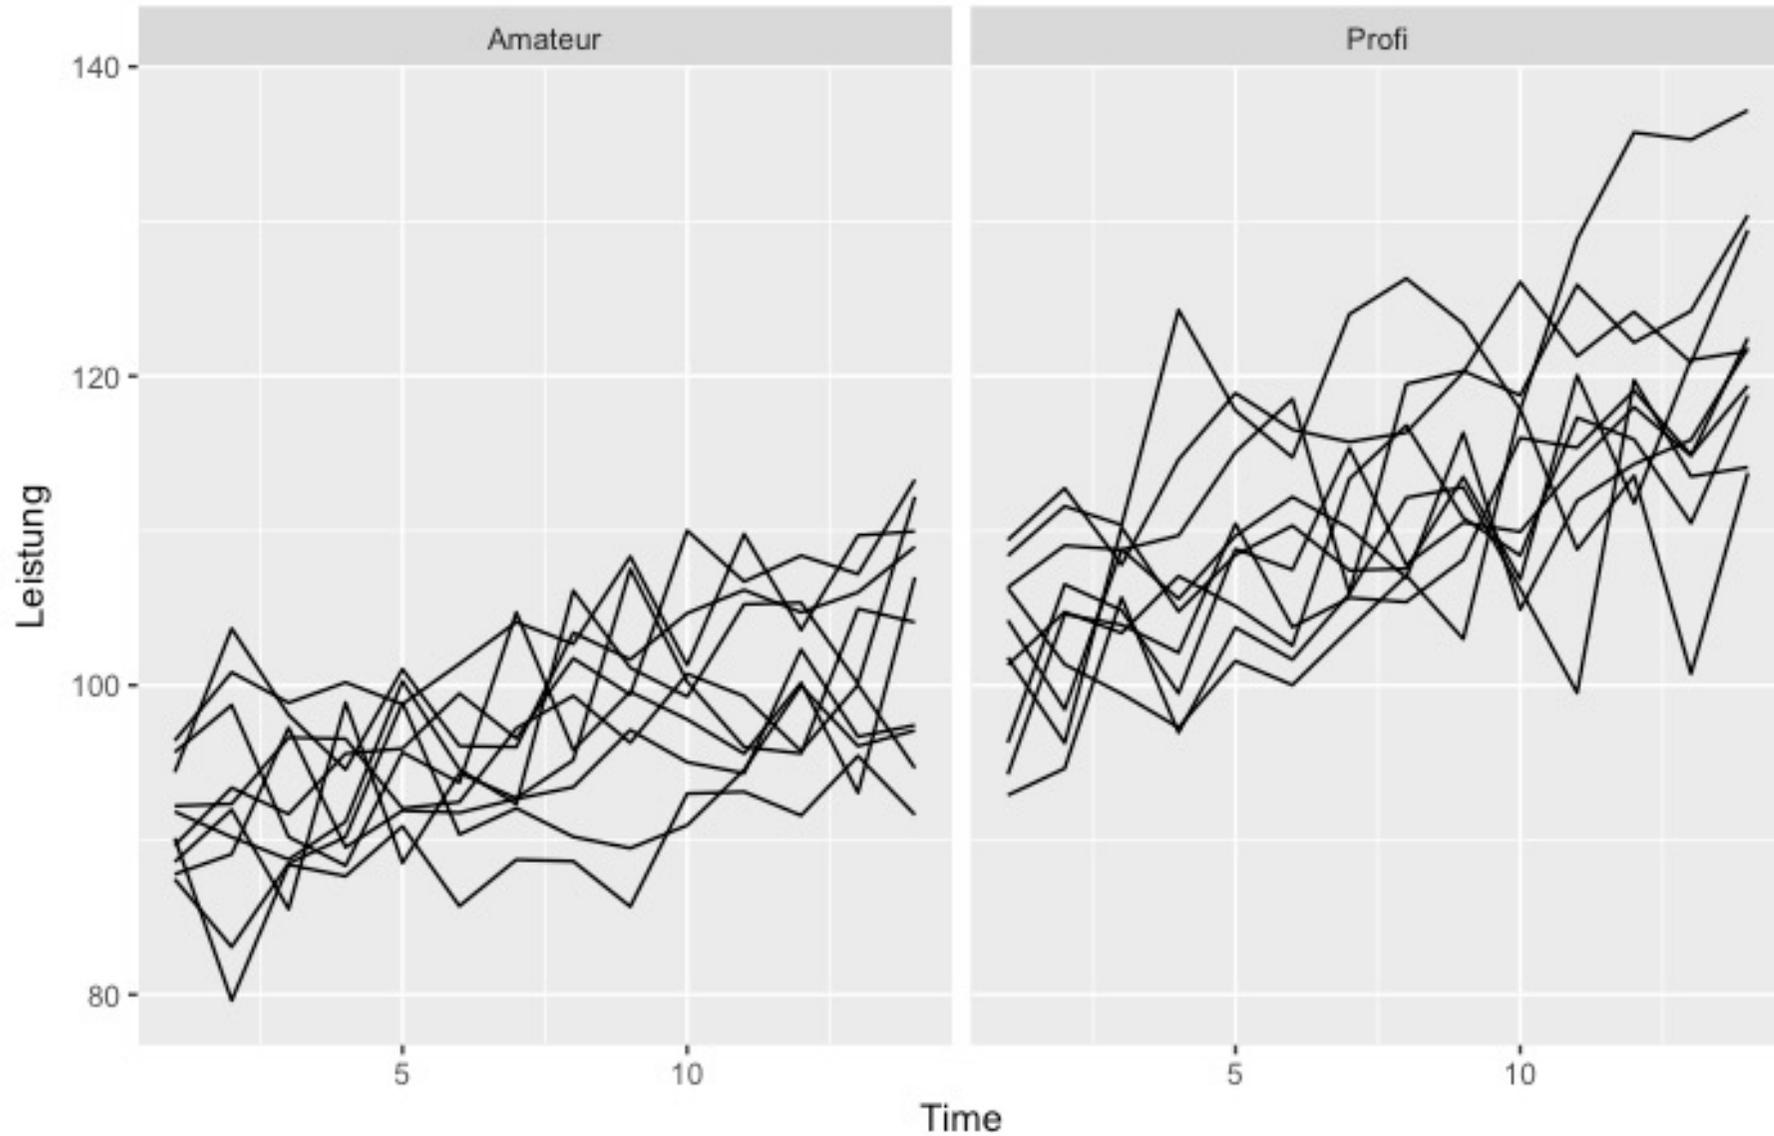
The content of these [Open Educational Resources](#) by [Lehrstuhl für Psychologische Methodenlehre und Diagnostik, Ludwig-Maximilians-Universität München](#) is licensed under [CC BY-SA 4.0](#). The CC Attribution-ShareAlike 4.0 International license means that you can reuse or transform the content of our materials for any purpose as long as you cite our original materials and share your derivatives under the same license.

# Wachstumskurvenmodelle

- Längsschnittanalyse: Die Zeit ist ein Prädiktor.
- Wachstumskurvenmodelle („growth curve models“)
- „the term growth curve model typically refers to statistical methods that allow for the estimation of inter-individual variability in intra-individual patterns of change over time. [...]  
In other words, growth models attempt to estimate between-person differences in within-person change.“ (Curran, Obeidat, & Losardo, 2010).
- „**estimate** between-person differences in within-person change“  
→ random slopes; wie viel Variabilität ist in den slopes?
- „**explain** between-person differences in within-person change“  
→ slopes-as-outcomes; kann man die Variabilität in den slopes durch einen L2-Prädiktor erklären?

- Bei Sportler\*innen wird über einen Zeitraum von 14 Tagen jeden Tag geprüft, wie sich ihre Leistung verbessert hat (simulierte Daten).
- Es gibt Profis ( $n = 10$ ) und Amateur\*innen ( $n = 10$ ).
- **Hypothese 1:** Es lässt sich für beide Typen Leistungszuwachs feststellen.
- **Hypothese 2:** Der Zuwachs ist für Profis größer als für Amateur\*innen.
- **Variablen:**
  - *Profi*: 0 = kein Profi, 1 = Profi
  - *Time.0*: 0 = 1. Tag der Messung, 13 = 14. Tag der Messung
  - *Leistung*: Leistungsmessung pro Tag pro Person

# Wachstumskurvenmodelle



$$Leistung_{ij} = \beta_{0j} + \beta_{1j}Time_{ij} + r_{ij}$$

$$\beta_{0j} = \gamma_{00} + \gamma_{01}Profi_j + u_{0j}$$

$$\beta_{1j} = \gamma_{10} + \gamma_{11}Profi_j + u_{1j}$$

Leistung  $\sim$  1 + Profi + Time.0 + Profi:Time.0 + (1 + Time.0 | Person)

## Anmerkungen

- Wir starten Time bei 0 und nicht bei 1, damit der Referenzpunkt der 1. MZP ist und nicht ein (nicht existierender) MZP vor der 1. Messung.
- $\gamma_{00}$  und  $\gamma_{10}$  sind dann der Intercept/Slope für eine Person, die  $Profi = 0$  ist, also eine Amateur\*in.
- Damit können wir nun untersuchen, welchen **Unterschied** es auf Level 2 macht, Profi zu sein, im Vergleich zu den Amateur\*innen.
- (In der Literatur werden bei Messwiederholungsdesigns die Parameter auf Level 1 häufig auch mit  $\pi$  bezeichnet, danach geht es auf Level 2 (Personenebene) mit  $\beta$  weiter.)

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )	
(Intercept)	90.9221	1.3304	18.0000	68.343	< 2e-16	***
Profi	11.6475	1.8815	18.0000	6.191	7.64e-06	***
Time.0	0.9055	0.1159	18.0000	7.816	3.41e-07	***
Profi:Time.0	0.4971	0.1639	18.0000	3.034	0.00714	**

$$\widehat{Leistung}_{ij} = 90.92 + 11.65Profi_j + 0.91Time.0_{ij} + 0.50Profi_jTime.0_{ij}$$

$$\widehat{Leistung}_{ij} = \begin{cases} 90.92 + 0.91Time.0_{ij} & \text{falls } Profi_j = 0, \\ (90.92 + 11.65) + (0.91 + 0.50)Time.0_{ij} & \text{falls } Profi_j = 1. \end{cases}$$

- i. Die geschätzte Leistung von Amateur\*innen zum Zeitpunkt Time.0 ist 90.92.
- ii. Profis haben zum Zeitpunkt Time.0 eine um 11.65 Punkte (signifikant) höhere geschätzte Leistung als Amateur\*innen.
- iii. Der Leistungszuwachs für Amateur\*innen beträgt geschätzt 0.91 Punkte pro Tag (was signifikant von Null verschieden ist).
- iv. Der geschätzte Leistungszuwachs der Profis pro Tag ist signifikant um 0.50 stärker als für Amateur\*innen (d.h., der *Unterschied* im slope ist signifikant von Null verschieden – der letzte Signifikanztest ist **nicht** der Test, ob der eigentliche slope der Profis von (0.91 + 0.50) signifikant von Null verschieden ist).

# Modellvergleiche

- Verbessern ein oder mehrere Terme in meiner Modellgleichung die Passung des Modells?
- Ockham Rasiermesser: Kann ich mein Modell vereinfachen? Bildet ein einfacheres Modell die Daten genauso gut ab wie ein komplexeres Modell?
- LMM: Modellvergleich per  $\chi^2$ -likelihood-ratio test (LRT)
  - Voraussetzungen:
    - Geschachtelte Modelle (d.h., das einfachere Modell lässt sich durch Null-Setzung einzelner Terme des komplexeren Modells herstellen)
    - Auf den gleichen Datensatz angewendet
    - Man kann nicht ein Modell mit random effects gegen ein Modell komplett ohne random effects testen (aber durchaus ein Modell mit 2 random effects gegen das einfachere mit nur 1 random effect, usf.).
  - Wenn der  $\chi^2$ -Test signifikant wird, ist das einfachere Modell (mit weniger Modellparametern) signifikant schlechter (in dem Fall bleibt man dann bei dem komplexeren).

```
> l1 <- lmer(MathAch ~ 1 + SES + (1 | School), data=HSB)
> l2 <- lmer(MathAch ~ 1 + SES + (1 + SES | School), data=HSB)
```

```
> summary(l1)
```

Random effects:

Groups	Name	Variance	Std.Dev.
School	(Intercept)	4.768	2.184
	Residual	37.034	6.086

Number of obs: 7185, groups: School, 160

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	12.6575	0.1880	148.3022	67.33	<2e-16 ***
SES	2.3902	0.1057	6838.0776	22.61	<2e-16 ***

```
> summary(l2)
```

Random effects:

Groups	Name	Variance	Std.Dev.	Corr
School	(Intercept)	4.8287	2.1974	
	SES	0.4129	0.6426	-0.11
	Residual	36.8301	6.0688	

Number of obs: 7185, groups: School, 160

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	12.6650	0.1898	145.5479	66.71	<2e-16 ***
SES	2.3938	0.1181	157.5299	20.27	<2e-16 ***

```
> l1 <- lmer(MathAch ~ 1 + SES + (1 | School))
> l2 <- lmer(MathAch ~ 1 + SES + (1 + SES | School))
```

```
> summary(l1)
```

Random effects:

Groups	Name	Variance	Std.Dev.
School	(Intercept)	4.768	2.184
	Residual	37.034	6.086

Number of obs: 7185, groups: School, 160

Fixed effect

(Intercept)

SES

```
> summary(l2)
```

Random effects:

Groups	Name	Variance	Std.Dev.	Corr
School	(Intercept)	4.8287	2.1974	
	SES	0.4129	0.6426	-0.11
	Residual	36.8301	6.0688	

Number of obs: 7185, groups: School, 160

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t )
(Intercept)	12.6650	0.1898	145.5479	66.71	<2e-16 ***
SES	2.3938	0.1181	157.5299	20.27	<2e-16 ***

```
> anova(l1, l2, model.names=c("simple", "complex"))

simple: MathAch ~ 1 + SES + (1 | School)
complex: MathAch ~ 1 + SES + (1 + SES | School)
      npar  AIC   BIC logLik deviance  Chisq Df Pr(>Chisq)
simple    4 46649 46677 -23320   46641      NA  NA      NA
complex  6 46648 46690 -23318   46636  4.5354  2    0.1035
```

**Das komplexe Modell hat 2 Parameter mehr:**  
- Die Random Slope Varianz  
- Die random Intercept – random Slope Kovariant  $\tau_{01}$

**Das einfachere Modell ist zu bevorzugen! (Das einfachere ist nicht signifikant schlechter)**

„Within the context of model selection, it is important to resist the reflex of choosing  $\alpha_{\text{LRT}} = 0.05$ . [...] For example, choosing  $\alpha_{\text{LRT}} = 0$ , an infinite penalty on the model complexity is implied and consequently the minimal model is always chosen as the best, irrespective of the evidence provided by the data. Choosing  $\alpha_{\text{LRT}} = 1$  implies an infinite penalty on the goodness-of-fit, and the maximal model is always chosen as the best. Therefore, choosing  $\alpha_{\text{LRT}} = 0.05$  may imply an overly strong penalty on the model complexity and hence select a reduced model even if data favor a more complex one. [...]

In fact, when comparing two nested models, the LRT with  $\alpha_{\text{LRT}} \approx 0.157$  is equivalent to the AIC.“

- Je kleiner  $\alpha$ , desto stärker favorisiert man simple Modelle. Je größer  $\alpha$ , desto stärker favorisiert man komplexe Modelle.
- $\alpha = .2$  wird häufig als Kompromiss gewählt.

Modellvereinfachung:  
Welche random effects sollte man ins  
Modell aufnehmen?

## Ansatz 1: „Keep it maximal“ (Barr et al., 2013)

- *Alle* random effects aufnehmen, die logisch Sinn ergeben.
  - Intercepts, alle random slopes von Variablen und Interaktionen, die theoretisch zwischen Units eines höheren Levels variieren können.
  - z.B. bei einer 2-Level-Struktur: Alle L1-Haupteffekte und alle Interaktionen bei denen eine L1-Variable beteiligt ist (also z.B. Interaktion zweier L1-Variablen, oder die cross-level-Interaktion von einer L1 und einer L2-Variable).
- Simulationsstudien zeigen, dass nur dann die falsch-positiv-Rate (Typ 1 Fehler) auf dem nominalen 5%-Niveau ist, wenn alle random effects aufgenommen werden. Insbesondere wenn nur random intercepts verwendet werden (und keine random slopes), dann hat man eine erhöhte Falsch-positiv-Rate für die fixed effect slopes.
- Problem 1: Das maximale Modell konvergiert oftmals nicht – wie soll man es vereinfachen um Konvergenz zu erreichen?
- Problem 2: Verringerte statistische Power, wenn es tatsächlich *keine* (oder nur sehr kleine) random variance für die slopes gibt. (Dann sollte der Parameter zwar nahe Null geschätzt werden, der zusätzliche Parameter verringert jedoch die Power, einen vorhandenen fixed effect zu entdecken).

## Ansatz 2: „Parsimonious Mixed Models“ (Bates et al. 2015; Matuschek et al., 2017)

- Ziel: Falsch-positiv-Rate auf dem nominalen (z.B. 5%) Niveau kontrollieren, und *gleichzeitig* die Power erhöhen, einen vorhandenen Effekt zu entdecken.
- Methode: Durch Modellvergleiche das Modell finden, das so einfach wie möglich ist (d.h., so wenige random effects wie möglich), und gleichzeitig so komplex wie nötig, um die Daten adäquat abbilden zu können.
- „backward-selection heuristic“: Starte mit dem komplexesten Modell und nimm solange random effects heraus, bis die Reduktion bei einem LRT zu einem signifikant schlechteren Modell führt ( $p < \alpha = .20$ )
- Erste Reduktion: Korrelationen zwischen random effects auf Null setzen (d.h., Korrelationen zwischen random intercepts und random slopes, oder zwischen mehreren random slopes)
  - lme4-Syntax für eine random-effects-Struktur *ohne* diese Korrelationen:  
( **1 + A + B || School** ). (also: Doppel-Pipe: ||)
- Ab dann: schrittweise jeweils den random effect der höchsten Ordnung herausnehmen, jeweils mit dem vorherigen Modell vergleichen.
  - Also erst den random effect der Dreifachinteraktion, dann eine der beiden Zweifachinteraktionen (oder beide gleichzeitig)

- Drei L1-Variablen, alle Interaktionen:
  - Sex (m/w), Minority (Ja/nein), SES (kontinuierlich)

• `m.maximal <- MathAch ~`

• `1 + Sex + Minority + SES + Sex:Minority + Sex:SES + Minority:SES +  
Sex:Minority:SES +`

fixed effects

• `(1 + Sex + Minority + SES + Sex:Minority + Sex:SES + Minority:SES +  
Sex:Minority:SES | School)`

alle random  
effects

```
singular fit
Warnmeldungen:
1: In commonArgs(par, fn, control, environment()) :
  maxfun < 10 * length(par)^2 is not recommended.
2: In optwrap(optimizer, devfun, getStart(start, rho$lower, rho$pp), :
  convergence code 1 from bobyqa: bobyqa -- maximum number of function evaluations exceeded
3: Model failed to converge with 3 negative eigenvalues: -9.3e+00 -1.6e+01 -1.4e+03
> m.maximal
```

```
Linear mixed model fit by REML ['lmerModLmerTest']
Formula: MathAch ~ 1 + Sex * Minority * SES + (1 + Sex * Minority * SES | School)
Data: hsb
REML criterion at convergence: 46307.63
Random effects:
```

Groups	Name	Std.Dev.	Corr
School	(Intercept)	1.4549	
	SexMale	1.3243	0.15
	MinorityYes	1.5791	0.66 0.19
	SES	0.6544	-0.76 0.45 -0.66
	SexMale:MinorityYes	0.8017	-0.69 -0.12 0.04 0.30
	SexMale:SES	1.4226	0.18 -0.78 -0.04 -0.63 -0.04
	MinorityYes:SES	1.3880	0.89 -0.15 0.39 -0.76 -0.84 0.31
	SexMale:MinorityYes:SES	2.4266	-0.41 0.75 0.05 0.72 0.43 -0.90 -0.64
	Residual	5.9076	

„failed to converge“:  
Ergebnisse *nicht*  
interpretieren!

Korrelationen zwischen  
random effects

## Reduktion 1: Volle Dreifach-IA, ohne Korrelationen zwischen random effects

- `m.R1 <- MathAch ~`
  - `1 + Sex + Minority + SES + Sex:Minority + Sex:SES + Minority:SES + Sex:Minority:SES +`
  - `(1 + Sex + Minority + SES + Sex:Minority + Sex:SES + Minority:SES + Sex:Minority:SES || School)`

fixed effects

random effects

singular fit

mindestens 1 random effect ist  $\sim 0$   
→ Reduktionspotential!

```
Random effects:
Groups   Name              Variance Std.Dev.
School   (Intercept)        2.582e+00 1.607e+00
School.1 Sex            1.361e+00 1.167e+00
School.2 Minority       3.253e+00 1.804e+00
School.3 SES            1.760e-13 4.195e-07
School.4 Sex:Minority   1.089e-11 3.300e-06
School.5 Sex:SES        1.680e-01 4.099e-01
School.6 Minority:SES   2.724e-01 5.219e-01
School.7 Sex:Minority:SES 0.000e+00 0.000e+00
Residual                          3.522e+01 5.934e+00
Number of obs: 7185, groups: School, 160
```

## Reduktion 2: ohne Dreifach-IA-random effect

- `m.R2 <- MathAch ~`
  - `1 + Sex + Minority + SES + Sex:Minority + Sex:SES + Minority:SES + Sex:Minority:SES +`
  - `(1 + Sex + Minority + SES + Sex:Minority + Sex:SES + Minority:SES || School)`

fixed effects

random effects

singular fit

mindestens 1 random effect ist ~ 0  
→ Reduktionspotential!

```
Random effects:
Groups  Name      Variance
School (Intercept) 2.5817
School.1 Sex        1.3609
School.2 Minority   3.2532
School.3 SES         0.0000
School.4 Sex:Minority 0.0000
School.5 Sex:SES     0.1680
School.6 Minority:SES 0.2724
Residual                    35.2163
```

Modellvergleich:  
`anova(m.R1, m.R2)`

	Df	AIC	BIC	logLik	deviance	Chisq	Chi	Df	Pr(>Chisq)
m.R2	16	46370	46480	-23169	46338				
m.R1	17	46372	46489	-23169	46338	0	1	1	1

Das einfachere  
Modell ist nicht  
signifikant  
schlechter → wir  
bevorzugen das  
einfachere Modell

## Reduktion 3: ohne Zweifach-IA-random effect Sex:Minority

- `m.R3 <- MathAch ~`
  - `1 + Sex + Minority + SES + Sex:Minority + Sex:SES +`  
`Minority:SES + Sex:Minority:SES +`
  - `(1 + Sex + Minority + SES + Sex:SES +`  
`Minority:SES || School)`

fixed effects

random  
effects

singular fit

mindestens 1 random effect ist  $\sim 0$   
→ immer noch Reduktionspotential!

```
Random effects:
Groups   Name              Variance
School  (Intercept)         2.58172
School.1 Sex              1.36085
School.2 Minority        3.25317
School.3 SES              0.00000
School.4 Sex:SES          0.16799
School.5 Minority:SES    0.27242
Residual                          35.21627
```

Das einfachere  
Modell ist nicht  
signifikant  
schlechter → wir  
bevorzugen das  
einfachere Modell

Modellvergleich:  
`anova(m.R2, m.R3)`

	Df	AIC	BIC	logLik	deviance	Chisq	Chi	Df	Pr(>Chisq)
m.R3	15	46368	46471	-23169	46338				
m.R2	16	46370	46480	-23169	46338	0		1	1

- `m.R4 <- MathAch ~`
  - `1 + Sex + Minority + SES + Sex:Minority + Sex:SES +`  
`Minority:SES + Sex:Minority:SES +`
  - `(1 + Sex + Minority + Sex:SES +`  
`Minority:SES || School)`

fixed effects

random effects

```
Random effects:  
Groups   Name          Variance  
School   (Intercept)    2.5817  
School.1 Sex          1.3609  
School.2 Minority    3.2532  
School.3 Sex:SES      0.1680  
School.4 Minority:SES 0.2724  
Residual                   35.2163
```

kein singular fit mehr

Das einfachere  
Modell ist nicht  
signifikant  
schlechter → wir  
bevorzugen das  
einfachere Modell

Modellvergleich:  
`anova(m.R3, m.R4)`

	Df	AIC	BIC	logLik	deviance	Chisq	Chi	Df	Pr(>Chisq)
m.R4	14	46366	46463	-23169	46338				
m.R3	15	46368	46471	-23169	46338	0		1	1

## Reduktion 5 – können wir noch weiter machen? Ohne beide Zweifach-IA-random effects

- `m.R5 <- MathAch ~`
  - `1 + Sex + Minority + SES + Sex:Minority + Sex:SES +`  
`Minority:SES + Sex:Minority:SES +`
  - `(1 + Sex + Minority || School)`

fixed effects

random effects

```
Random effects:  
Groups   Name                Variance  
School   (Intercept)          2.577  
School.1 Sex              1.368  
School.2 Minority        3.370  
Residual                          35.287
```

kein singular fit mehr

Das einfachere  
Modell ist nicht  
signifikant  
schlechter → wir  
bevorzugen das  
einfachere Modell

Modellvergleich:  
`anova(m.R4, m.R5)`

	Df	AIC	BIC	logLik	deviance	Chisq	Chi	Df	Pr(>Chisq)
m.R5	12	46363	46445	-23170	46339				
m.R4	14	46366	46463	-23169	46338	0.6098		2	0.7372

## Reduktion 6 – ganz ohne random slopes?

- `m.R6 <- MathAch ~`
  - `1 + Sex + Minority + SES + Sex:Minority + Sex:SES +`  
`Minority:SES + Sex:Minority:SES +`
  - `(1 | School)`

fixed effects

random  
intercept

```
Random effects:
Groups   Name      Variance
School  (Intercept) 3.75
Residual                    35.82
```

Jetzt ist es zu einfach – das  
einfachere Modell wird signifikant  
schlechter ( $p < .20$ ).

Wir bleiben bei R5!

**Modellvergleich:**  
`anova(m.R5, m.R6)`

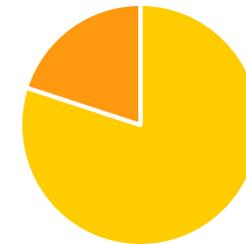
```
      Df   AIC   BIC logLik deviance Chisq Chi Df   Pr(>Chisq)
m.R6  10 46388 46457 -23184   46368
m.R5  12 46363 46445 -23170   46339 29.361     2 0.0000004211 ***
```

- Barr, D. J. (2013). Random effects structure for testing interactions in linear mixed-effects models. *Frontiers in Psychology*, 4. doi:[10.3389/fpsyg.2013.00328](https://doi.org/10.3389/fpsyg.2013.00328)
- Barr, D. J., Levy, R., Scheepers, C., & Tily, H. J. (2013). Random effects structure for confirmatory hypothesis testing: Keep it maximal. *Journal of Memory and Language*, 68, 255–278. doi:[10.1016/j.jml.2012.11.001](https://doi.org/10.1016/j.jml.2012.11.001)
- Bates, D., Kliegl, R., Vasishth, S., & Baayen, H. (2015). Parsimonious mixed models. *arXiv:1506.04967 [stat]*. Abgerufen von <http://arxiv.org/abs/1506.04967>
- Matuschek, H., Kliegl, R., Vasishth, S., Baayen, H., & Bates, D. (2017). Balancing Type I error and power in linear mixed models. *Journal of Memory and Language*, 94, 305–315. doi:[10.1016/j.jml.2017.01.001](https://doi.org/10.1016/j.jml.2017.01.001)

# $R^2$ : Erklärte Varianz in LMMs

- „Klassisches“  $R^2$ : Wie viel % der Varianz der abhängigen Variable wird durch die Prädiktoren aufgeklärt?

$$R^2 = \frac{\textit{explained variance}}{\textit{outcome variance}}$$



- Aufgeklärte Varianz
- Fehlervarianz

- Ein CWC(M)-zentrierter **L1-Prädiktor** kann *nur within-cluster* Varianz aufklären
- Ein **L2-Prädiktor** (entweder ein „echter“, oder der Gruppenmittelwert aus einer CWC(M)-Zentrierung) kann *nur between-cluster* Varianz aufklären

- In LMMs lassen sich Varianzanteile im outcome verschiedenen Kategorien zuordnen (Rights & Sterba, 2019). Annahme: Alle L1-Prädiktoren wurden CWC(M)-zentriert, es gibt nur 2 Level:
  - Varianz, die durch L1 fixed effects aufgeklärt wird („ $f1$ “)
  - Varianz, die durch L2 fixed effects aufgeklärt wird („ $f2$ “)
  - Varianz, die durch Unterschiede in den Mittelwerten der Gruppen entsteht („ $m$ “ für mean – das ist  $\tau_{00}$ )
  - Varianz, die durch Unterschiede in den random slopes entsteht („ $v$ “)
  - Residualvarianz auf L1 ( $\sigma^2$ )
- Was kommt in den Nenner vom  $R^2$ ? Nur die outcome variance, die für den interessierenden Prädiktor relevant ist. Drei Möglichkeiten:
  - total variance (also die ganze Varianz des outcomes): Subscript  $t$
  - within-cluster variance: Subscript  $w$
  - between-cluster variance: Subscript  $b$

	Source of variance	Explanation	total	within	between
<b>single</b> variance source	f1	fixed effects L1	✓	✓	
	f2	fixed effects L2	✓		✓
	v	random slope variation	✓	✓	
	m	random intercept variation	✓		✓
<b>combined</b> variance source	f	all fixed effects (L1 + L2)	✓		
	fv	fixed effects + random slopes	✓	✓	
	fvm	fixed effects + random slopes + random intercepts	✓		

\$Decompositions

	total	within	between
fixed, within	0.0439	0.0536	NA
fixed, between	0.1245	NA	0.6882
slope variation	0.0063	0.0077	NA
mean variation	0.0564	NA	0.3118
sigma2	0.7689	0.9388	NA
	$\Sigma=1$	$\Sigma=1$	$\Sigma=1$

\$R2s

	total	within	between
f1	0.0439	0.0536	NA
f2	0.1245	NA	0.6882
v	0.0063	0.0077	NA
m	0.0564	NA	0.3118
f	0.1684	NA	NA
fv	0.1747	0.0612	NA
fvm	0.2311	NA	NA

\$R2s

	total	within	between
f1	0.0439	0.0536	NA
f2	0.1245	NA	0.6882
v	0.0063	0.0077	NA
m	0.0564	NA	0.3118
f	0.1684	NA	NA
fv	0.1747	0.0612	NA
fvm	0.2311	NA	NA

- SES.gc (L1-Prädiktor) klärt 5.36% der within-Varianz auf ( $R_w^2(f_1)$ )
  - Da dieser Prädiktor ja ausschließlich within-Varianz erklären kann, könnte man argumentieren, dass man ihn auch nur an der within-Varianz relativieren sollte.
- SES.gmc (L2-Prädiktor) klärt 68.82% der between-Varianz auf ( $R_b^2(f_2)$ )
  - Da dieser Prädiktor ja ausschließlich between-Varianz erklären kann, könnte man argumentieren, dass man ihn auch nur an der between-Varianz relativieren sollte.
- SES.gmc (L2-Prädiktor) klärt 12.45% der Gesamtvarianz auf ( $R_t^2(f_2)$ )
- **Die fixed effects von allen Prädiktoren klären 16.84% der Gesamtvarianz auf ( $R_t^2(f)$ )**
  - Dieses  $R^2$  wurde früher „marginal  $R^2$ “ genannt und wird am häufigsten berichtet: Die gesamte Varianzaufklärung aller fixed effects. Das ist am ehesten äquivalent zum  $R^2$  einer single-level Regression.

## Decomposition

