

Lineare Gemischte Modelle (6) Poweranalyse & Modelldiagnostik



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.

- Angenommen, die Testung einer Schüler*in kostet 10€, und man hat 10.000€ zur Verfügung ...
 - 40 Klassen mit je 25 Schüler*innen?
 - 100 Klassen mit je 10 Schüler*innen?
- 3 Levels:
 - Jeweils 10 Klassen aus 10 Schulen mit je 10 Schüler*innen?
 - Jeweils 20 Klassen aus 5 Schulen mit je 10 Schüler*innen?
 - Jeweils 5 Klassen aus 10 Schulen mit je 20 Schüler*innen?
- Trade-off: Jede Schule kostet 500€ Zusatzgebühr (Anfahrt). Soll ich 50 Schüler*innen weniger erheben, dafür aber eine Schule extra auf L3 aufnehmen?

- Stichprobengrößen auf mehreren Ebenen
- Man benötigt a-priori Abschätzungen für Varianzkomponenten („Wie viel Varianz in den Intercepts erwarte ich?“) → schwer abzuschätzen, meist unbekannt
- Möglicherweise liegen Pilotdaten zur Abschätzung vor, allerdings sind diese meist zu klein um eine sinnvolle Abschätzung liefern zu können.
- Das Einführen von Kovariaten kann die optimalen Stichprobengrößen auf jedem Level ändern, je nachdem wie viel Varianz eine Kovariate innerhalb oder zwischen Gruppen erklärt.

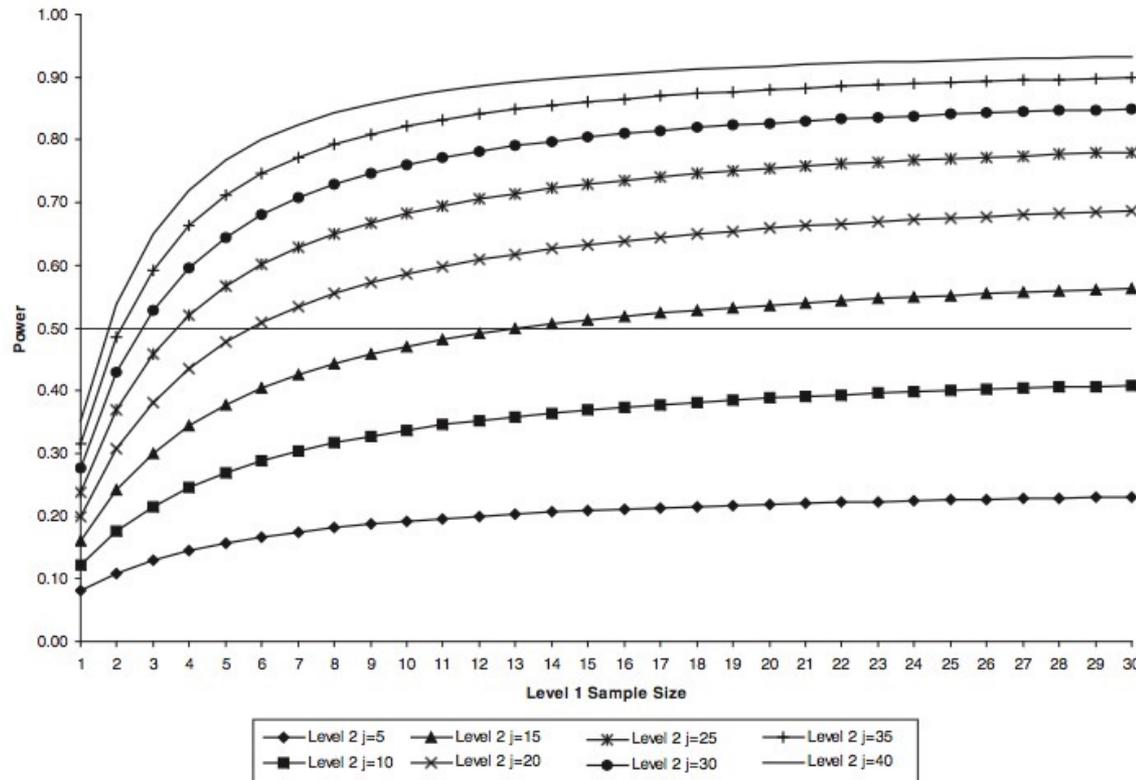
- Zusätzlich: Abhängigkeit vom ICC
 - Wenn ICC gegen 1 geht, unterscheiden sich die Einheiten innerhalb einer Gruppe kaum
 - jede einzelne L1-Einheit bietet kaum zusätzliche Information über die bereits vorhandenen L1-Einheiten hinaus
 - mehr L1-Einheiten bringen keinen Gewinn an zusätzlicher Information; es hilft hier nur, mehr L2-Einheiten zu messen
- „ICC values typically range between .05 and .20“ (Snijders & Bosker, 1999; Bliese, 2000)
- „values greater than .30 will be rare“ (Bliese, 2000)
- „median value of .12; this is likely an overestimate“ (James, 1982)
 - **„a value between .10 and .15 will provide a conservative estimate of the ICC when it cannot be precisely computed“**

Power im LMM

- Level-Abhängigkeit (wenn man 2 Level annimmt):
 - Für die Power von **L1-Prädiktoren** ist die Anzahl der L1-Einheiten (also z.B. Schüler*innen) relevant
 - Für die Power von **L2-Prädiktoren** ist die Anzahl der L2-Einheiten (also z.B. Schulen) sowie die Gruppengröße (also z.B. die Klassengröße) relevant.

- Generell: n auf L2 (bzw. auf dem höchsten Level) ist wichtiger als das n auf L1 (bzw. auf den niedrigeren Leveln)

Figure 1
Estimates of Statistical Power at a Medium Effect Size
for γ_{01} under Varying Sample Sizes at Level 1 and Level 2



Ganz grobe Faustregeln (werden aber oft kritisiert!)

- Generell: n auf L2 (bzw: auf dem höchsten Level) ist wichtiger als das n auf L1 (bzw. auf den niedrigeren Leveln)
- Entscheidend ist v.a. das Level, auf dem der fokale Effekt liegt.
- Kreft (1996): 30/30 Regel
 - ≥ 30 Gruppen auf L2
 - ≥ 30 L1-Einheiten pro L2-Gruppe
 - $30 * 30 = 900$ Einheiten auf L1
- Hox (1998): 50/20 Regel
 - ≥ 50 Gruppen auf L2
 - ≥ 20 L1-Einheiten pro L2-Gruppe
 - $50 * 20 = 1000$ Einheiten auf L1

- L1: Messzeitpunkte (5, 11, oder 21 pro Patient*in), geschachtelt in ...
- L2: Patient*innen (2, 4, oder 8 pro Therapeut*in), geschachtelt in...
- L3: Therapeut*innen (Fokus der Power-Analyse: Wie viele Therapeut*innen akquiriert man?)
- AV auf L1: Therapiefortschritt (Selbstbericht der Patient*innen)
- Fokaler Effekt: Therapeut*innen bekommen Feedback über Therapiefortschritt oder nicht (d.h., between-group Experimentalfaktor auf L3) → Effekt auf L1-Slope.
 - Ist der Therapiefortschritt über die Zeit (rate of change) schneller wenn die Therapeut*innen Feedback über den aktuellen Status bekommen?
 - Also: Ein L1-L3-Interaktionseffekt

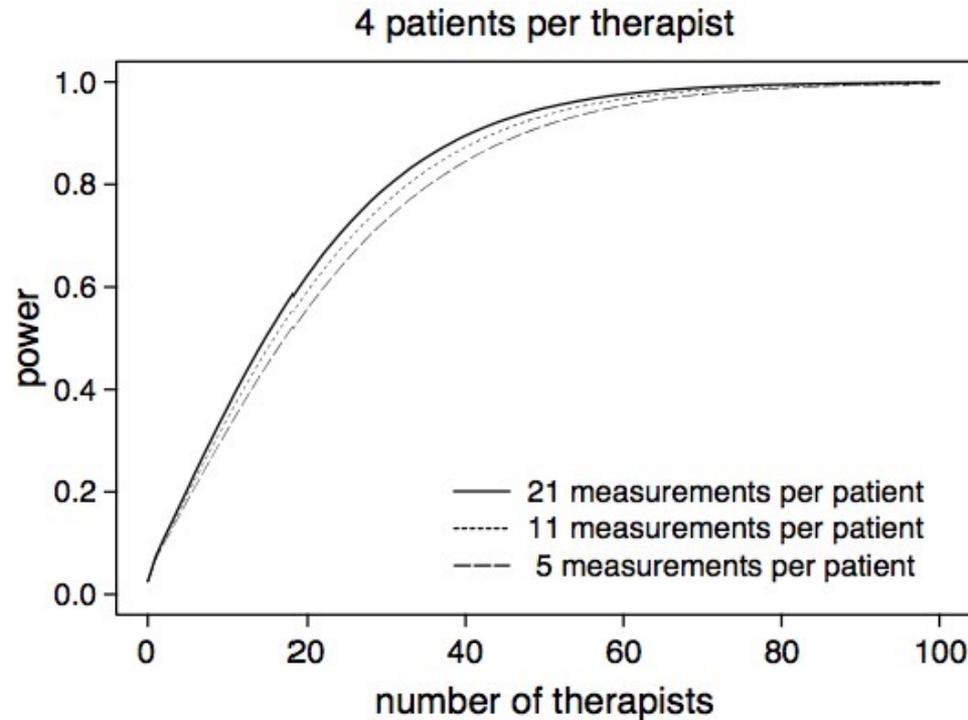


Figure III. Estimated power for a varying number of measurements per patient, randomization at the patient level.

- Sättigung ab ca. 60 Therapeut*innen:
mehr braucht es nicht, wenn jede Therapeut*in 4 Patient*innen hat
- Anzahl des Messzeitpunkte auf L1 relativ irrelevant

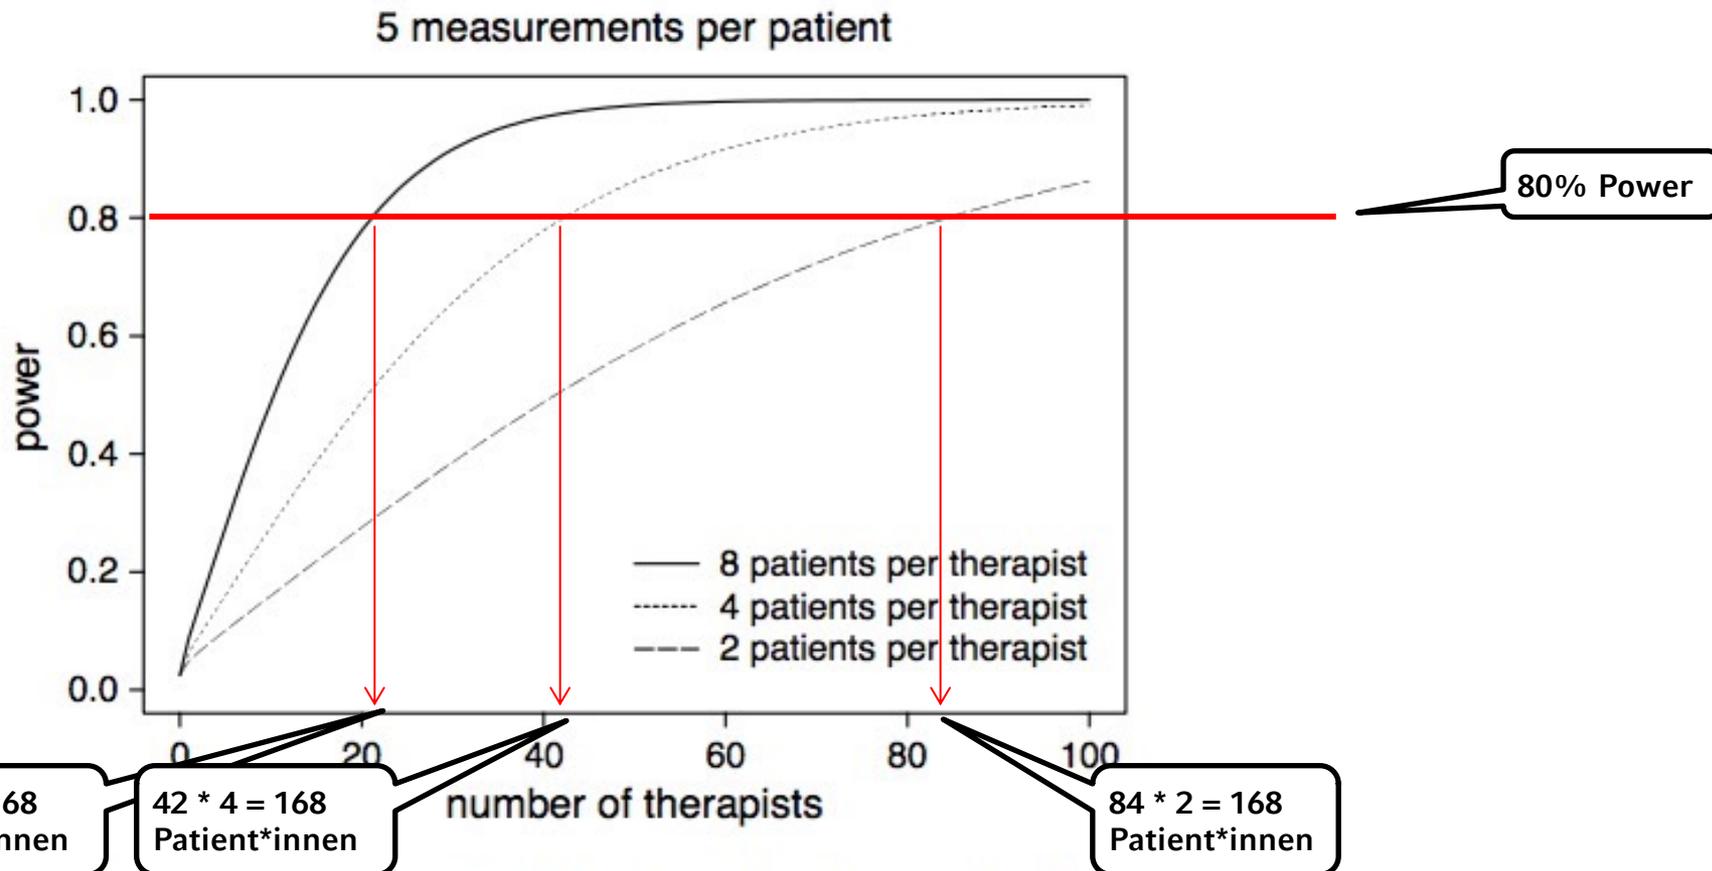
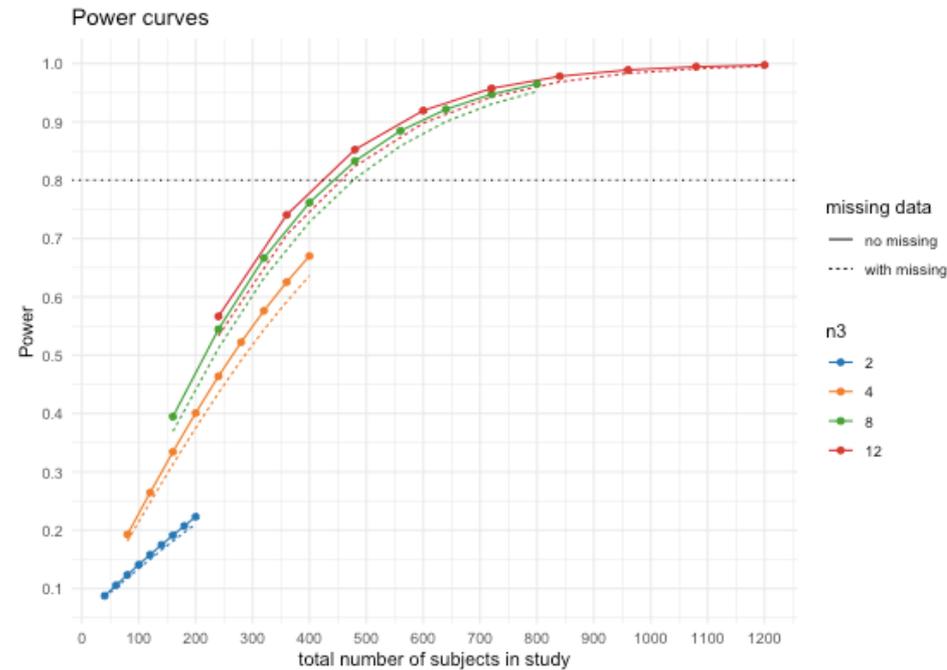
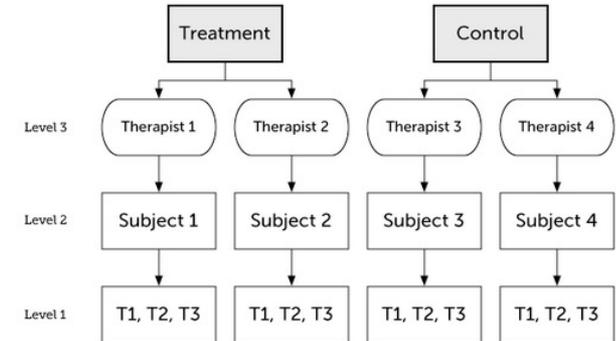


Figure I. Estimated power for the planned study, no significant slope variance at the therapist level.

- Paket *powerlmm*
- Inklusive Shiny-Application
- Allerdings nur für eine bestimmte Klasse an Standarddesigns



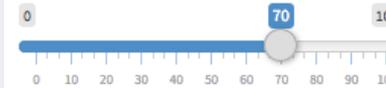
Download plot

Random effects

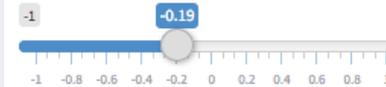
Level 1

Level 2

Baseline ICC at level 2

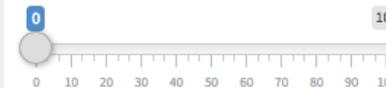


Correlation intercept-slope

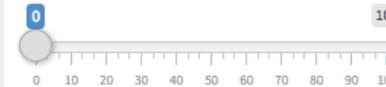


Level 3

Baseline ICC at level 3



Proportion (%) slope variance at level 3



- Gelman, A., & Hill, J. (2007). *Data analysis using regression and multilevel/hierarchical models*. Cambridge University Press.
Kapitel 20.5
- Kruschke, J. (2014). *Doing Bayesian data analysis: A tutorial with R, JAGS, and Stan* (2nd edition). Boston: Academic Press.
Kap. 13
- McElreath, R. (2020). *Statistical Rethinking: A Bayesian Course with Examples in R and Stan* (2nd edition). New York, CRC Press Taylor & Francis Group.
Keine Powerberechnungen, aber Daten Simulationen sehr ausführlich behandelt.
- Link zum „Self-paced tutorial: Advanced Power Analysis by Simulation“ von 2023:
<https://lmu-osc.github.io/Simulations-for-Advanced-Power-Analyses/>
Ch. 4: Linear Mixed Models / Multilevel models

Modelldiagnostik & ein paar praktische Tipps

- Annahme 1 (Verteilung der Residuen): Die Residuen sind normalverteilt
- Annahme 2 (Homoskedastizität): Die Fehlervarianz σ^2 ist konstant
- Annahme 3 (Linearität): Die Prädiktoren hängen linear mit dem Kriterium zusammen

Formula: $y \sim 1 + x + (1 + x \mid \text{pid})$

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t)	
(Intercept)	-13.04927	0.58144	298.00000	-22.44	<2e-16	***
x	7.03927	0.09371	298.00000	75.12	<2e-16	***

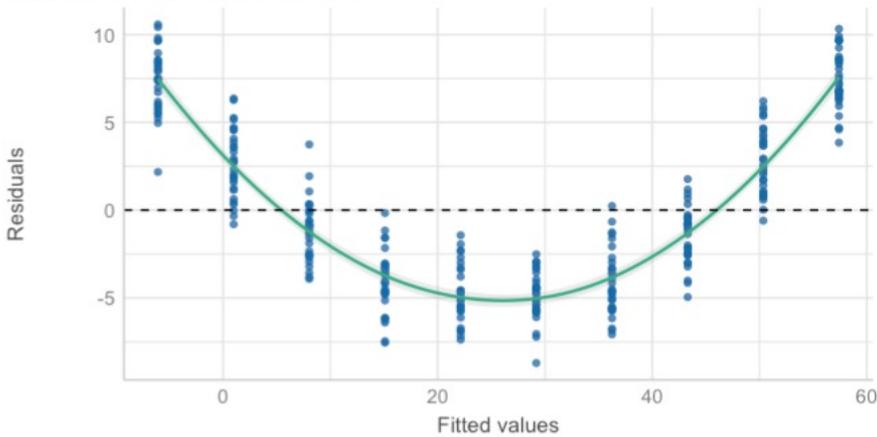
Formula: $y \sim 1 + x + x^2 + (1 + x \mid \text{pid})$

Fixed effects:

	Estimate	Std. Error	df	t value	Pr(> t)	
(Intercept)	5.513e-01	2.235e-01	1.141e+02	2.466	0.01513	*
x	2.390e-01	8.407e-02	2.621e+02	2.843	0.00482	**
x ²	6.182e-01	7.404e-03	2.390e+02	83.498	< 2e-16	***

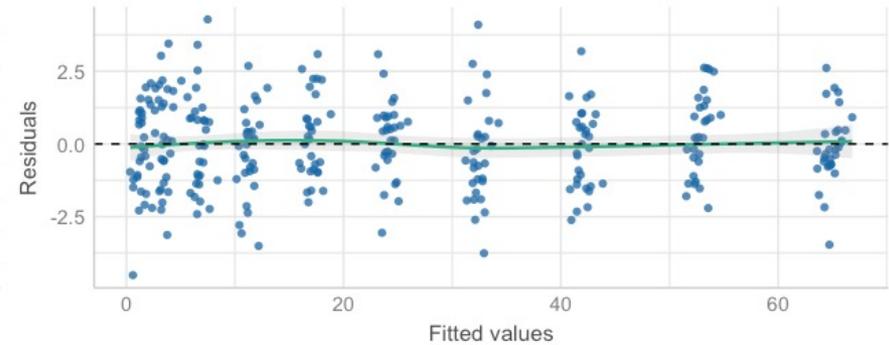
$$y \sim 1 + x$$

Linearity
Reference line should be flat and horizontal



$$y \sim 1 + x + x^2$$

Linearity
Reference line should be flat and horizontal

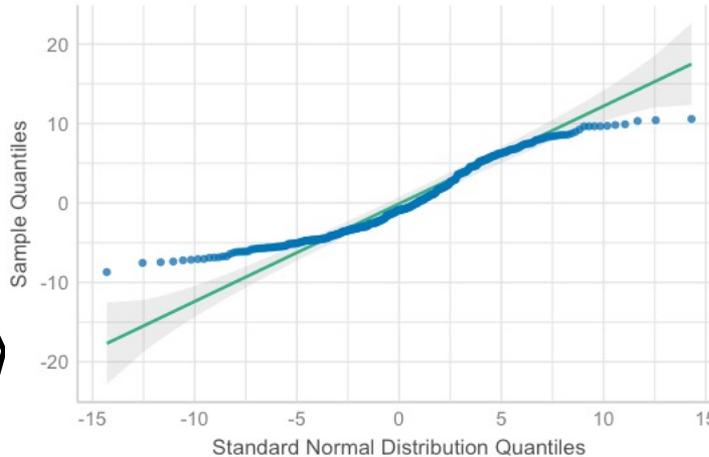


Die Residuen sollten
unsystematisch um die
gestrichelte 0-Linie
herum schwanken

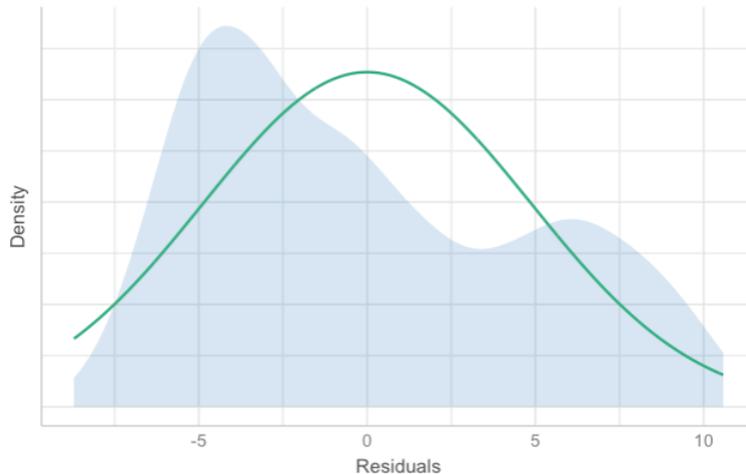
Annahme: Normalverteilung der Residuen

$$y \sim 1 + x$$

Normality of Residuals
Dots should fall along the line

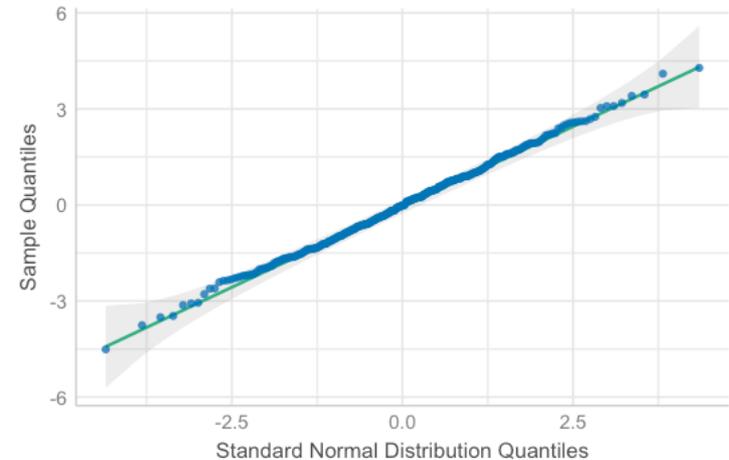


Normality of Residuals
Distribution should be close to the normal curve

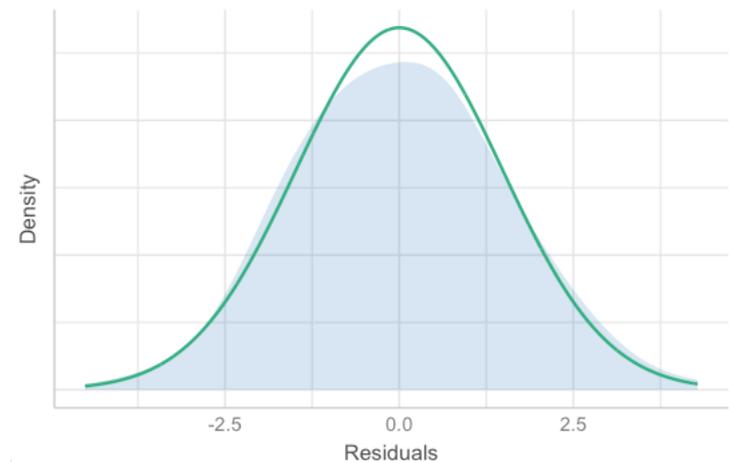


$$y \sim 1 + x + x^2$$

Normality of Residuals
Dots should fall along the line



Normality of Residuals
Distribution should be close to the normal curve

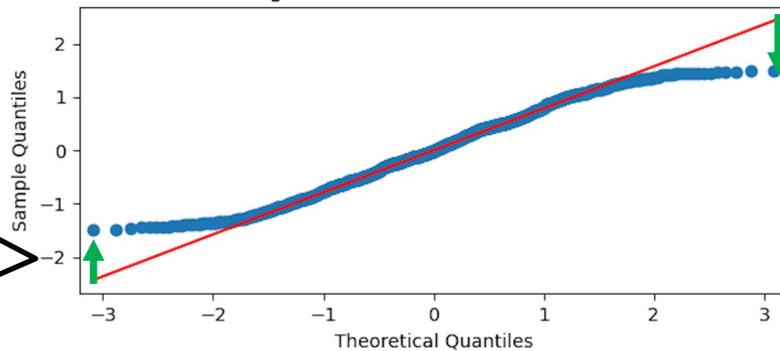


Q-Q Plot =
Quantile-
quantile-plot:
Quantile der
Normalverteilung
vs. Quantile der
empirischen
Verteilung der
Residuen.
Sollten auf der
grünen Linie
liegen, innerhalb
der grauen
Konfidenzbänder

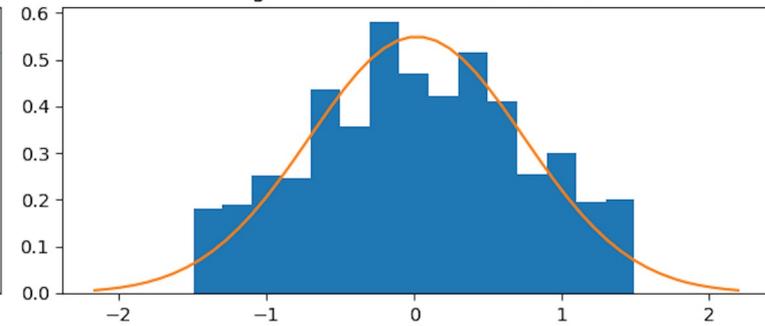
Alternative
Darstellung
als Verteilung

... und die oberen
Quantile nicht
positiv genug.

light-tailed:truncnorm(-1.5, 1.5)

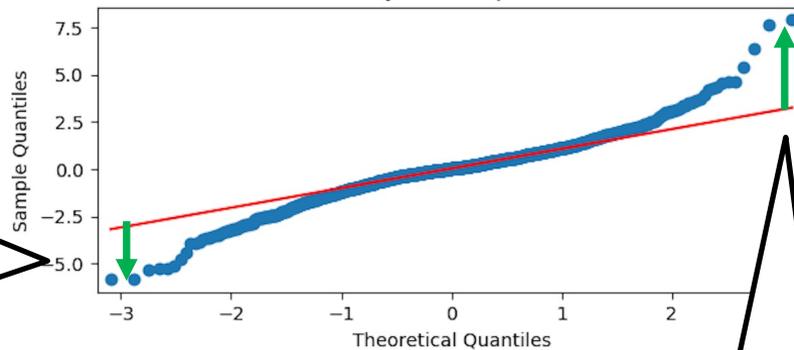


light-tailed:truncnorm(-1.5, 1.5)

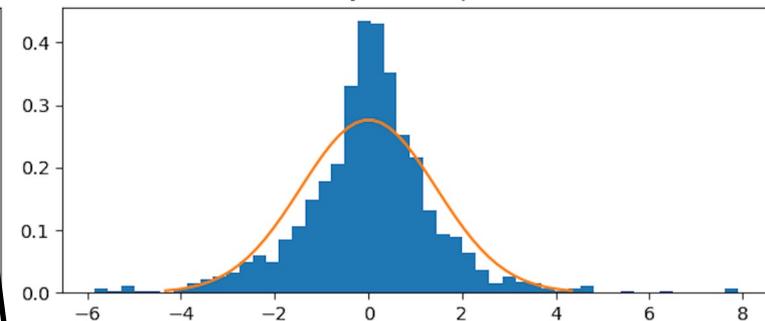


Empirisch sind
die unteren
Quantile nicht
negativ genug ...

heavy-tailed:laplace()



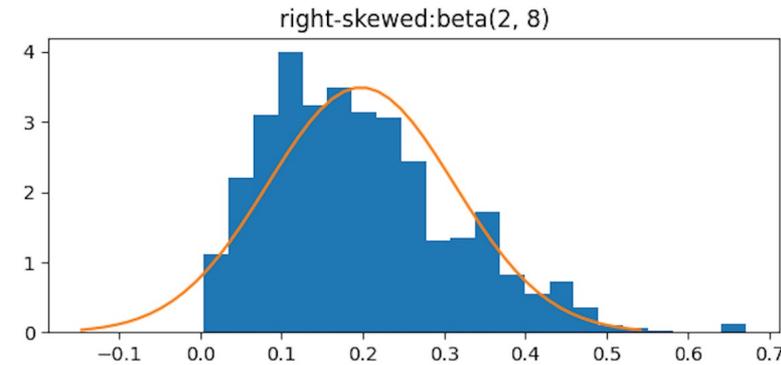
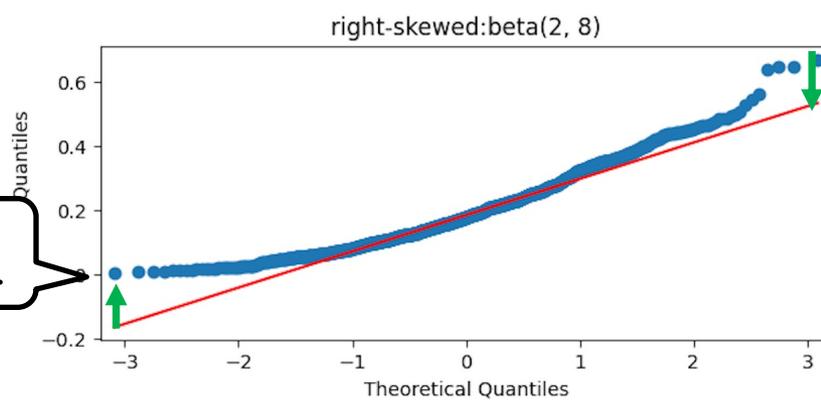
heavy-tailed:laplace()



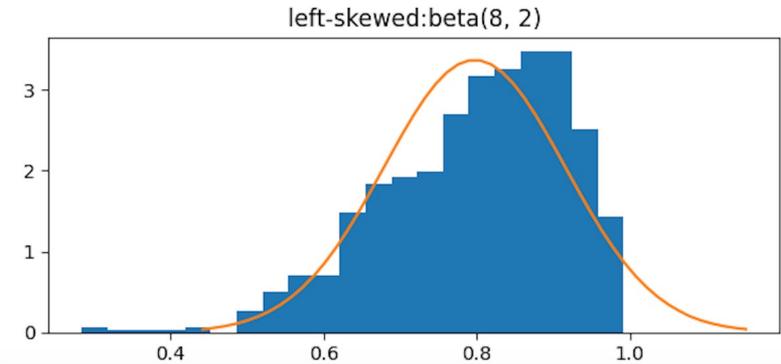
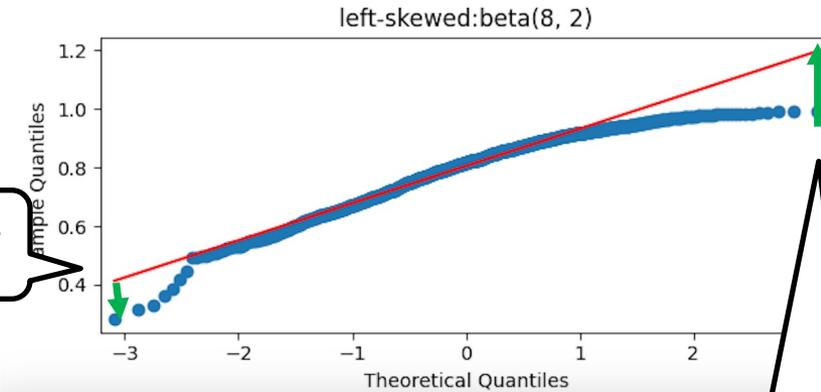
... und die oberen
Quantile zu
positiv.

Empirisch sind die
unteren Quantile
zu negativ ...

... und rechts zu
viel



Rechtsschief:
Links zu wenig ...



Linksschief: Links
zu viel ...

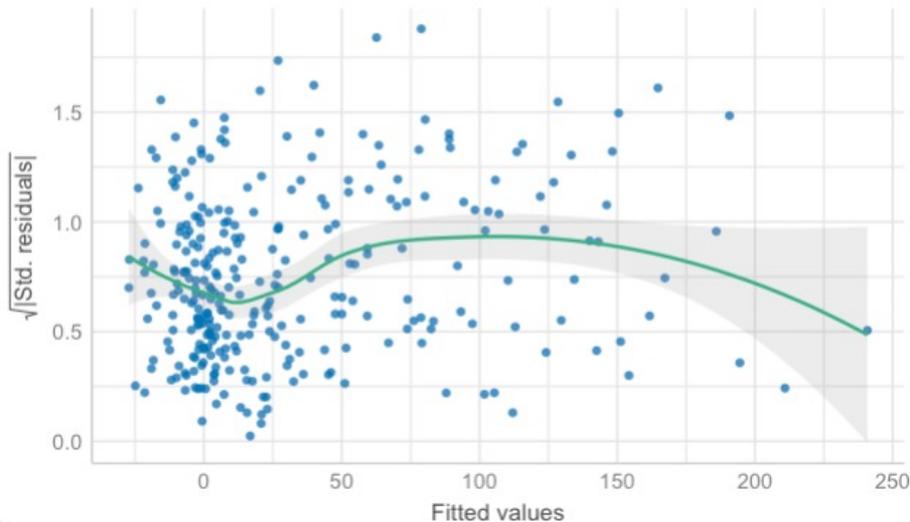
... und rechts zu
wenig.

$y \sim 1 + x + x^2$, heterogene Simulation

Warning: Heteroscedasticity (non-constant error variance)
detected ($p < .001$)

Homogeneity of Variance

Reference line should be flat and horizontal

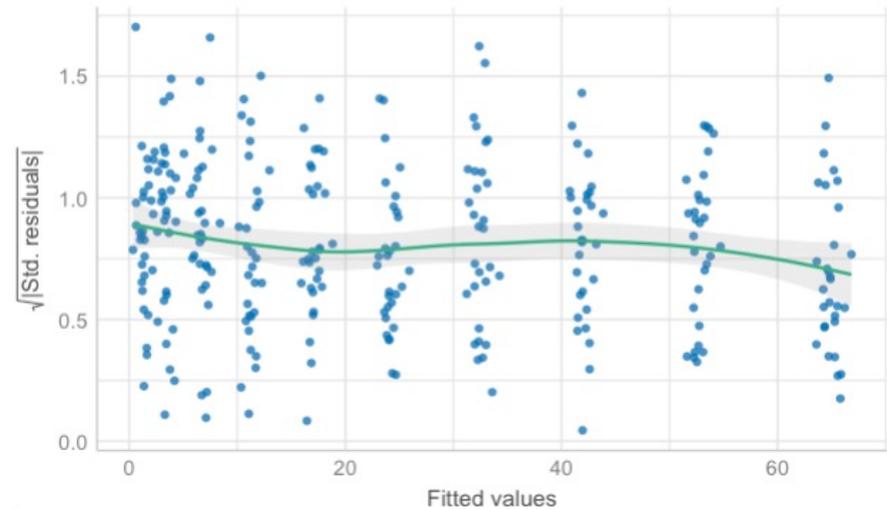


$y \sim 1 + x + x^2$, homogene Simulation

OK: Error variance appears to be homoscedastic
($p = 0.381$).

Homogeneity of Variance

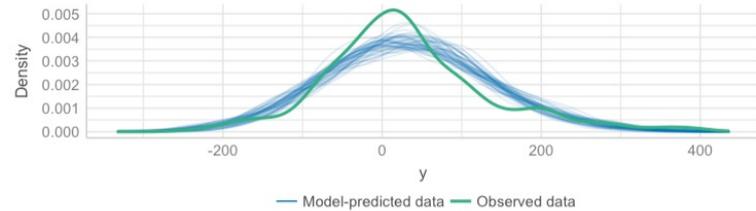
Reference line should be flat and horizontal



```
library(performance)
l2 <- lmer(...)
check_heteroscedasticity(l2)
plot(check_heteroscedasticity(l2))
```

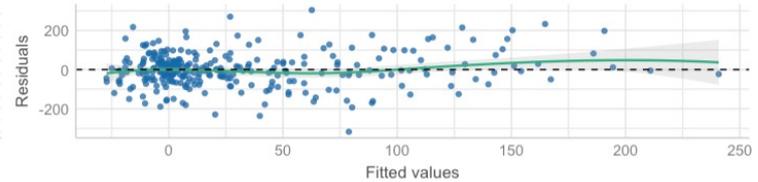
Posterior Predictive Check

Model-predicted lines should resemble observed data line



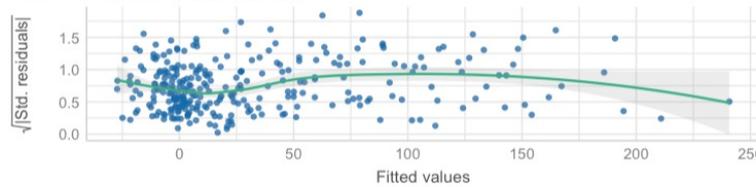
Linearity

Reference line should be flat and horizontal



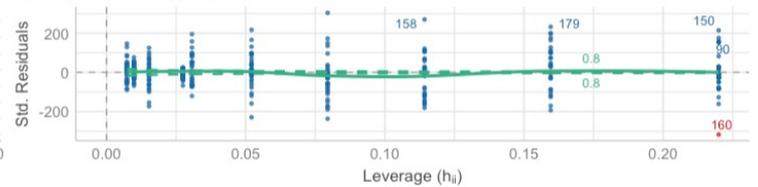
Homogeneity of Variance

Reference line should be flat and horizontal



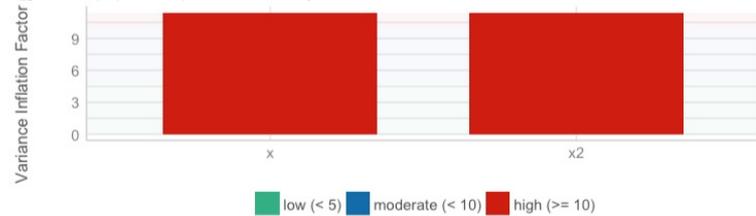
Influential Observations

Points should be inside the contour lines



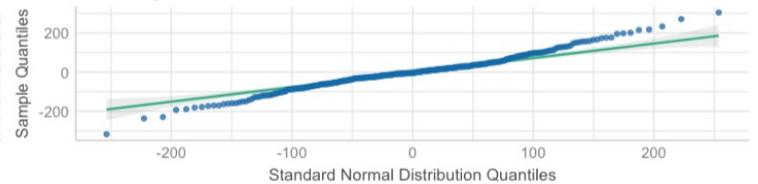
Collinearity

Higher bars (>5) indicate potential collinearity issues



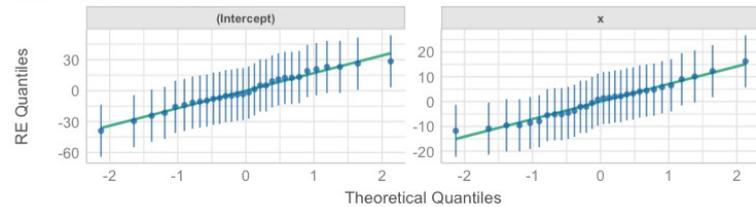
Normality of Residuals

Dots should fall along the line



Normality of Random Effects (pid)

Dots should be plotted along the line



```
library(performance)
l2 <- lmer(...)
check_model(l2)
```

- „model failed to converge“ Warnung
 - lme4 konnte auf keine Lösung konvergieren. **Selbst wenn ein Ergebnis zurückgegeben wird, sollten Sie dieses nicht interpretieren!** Die Werte können völlig daneben liegen.
 - Lösungsansätze:
 - Modell vereinfachen (siehe „parsimonious models“ in VL-Sitzung 6)
 - Variablen zentrieren/standardisieren
 - Weitere Lösungsansätze: siehe ?convergence im lme4-Paket in R
- „singular fit“ Warnung
 - Bedeutet, dass mindestens eine random variance Komponente Null ist, oder dass eine Korrelation zwischen random effects -1 oder +1 ist.
 - Ist nicht unbedingt ein Problem, aber ein Hinweis darauf, dass man das Modell noch mal genau ansehen sollte, und evtl. im Sinne von Ockhams Rasiermesser das Modell vereinfachen könnte, indem man den nicht benötigten random term aus dem Modell herausnimmt.
 - Könnte auch an hohen Kollinearitäten von Prädiktoren liegen.
 - siehe auch: <https://bbolker.github.io/mixedmodels-misc/glmmFAQ.html#singular-models-random-effect-variances-estimated-as-zero-or-correlations-estimated-as---1>

Das war's mit den linearen
gemischten Modellen!