

(Wiederholung:) Bivariate lineare Regression

Methoden der empirischen Kommunikations- und Medienforschung

Marko Bachl
Freie Universität Berlin



HEUTE: (WIEDERHOLUNGSSITZUNG)

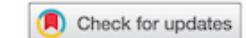
- Viele haben bereits Erfahrung mit der bivariaten Korrelation ([Pearsons] r), einige auch mit der linearen Regression. In dieser Sitzung werden wir unter anderem lernen, dass der Korrelationskoeffizient r nur eine spezielle Art ist, das Ergebnis einer bivariaten linearen Regression darzustellen.

AGENDA

1. Grundlagen der Regression
2. Regression und Mittelwertvergleich
3. Annahmen und ihre Überprüfung
4. Transformation von Variablen
5. Zusammenfassung
6. Übungsaufgaben

DATEN DER HEUTIGEN SITZUNG

POLITICAL COMMUNICATION
2021, VOL. 38, NO. 4, 407–425
<https://doi.org/10.1080/10584609.2020.1784328>



Why Don't We Learn from Social Media? Studying Effects of and Mechanisms behind Social Media News Use on General Surveillance Political Knowledge

Patrick F. A. van Erkel and Peter Van Aelst

Department of Political Science, University of Antwerp, Antwerp, Belgium

ABSTRACT

Does exposure to news affect what people know about politics? This old question attracted new scholarly interest as the political information environment is changing rapidly. In particular, since citizens have new channels at their disposal, such as Twitter and Facebook, which increasingly complement or even replace traditional channels of information. This study investigates to what extent citizens have knowledge about daily politics and to what extent news on social media can provide this knowledge. It does so by means of a large online survey in Belgium (Flanders), in which we measured what people know about current political events, their so-called general surveillance knowledge. Our findings demonstrate that unlike following news via traditional media channels, citizens do not gain more political knowledge from following news on social media. We even find a negative association between following the news on Facebook and political knowledge. We further investigate why this is the case. Our data demonstrate that this lack of learning on social media is not due to a narrow, personalized news diet, as is often suggested. Rather, we find evidence that following news via social media increases a feeling of information overload, which decreases what people actually learn, especially for citizens who combine news via social media with other news sources.

KEYWORDS

Political knowledge; social media; filter bubbles; information overload

(Van Erkel, 2020; Van Erkel & Van Aelst, 2021)

WARUM SO VIEL REGRESSION?

Parks and Rec - funny jail scene



WARUM SO VIEL REGRESSION?

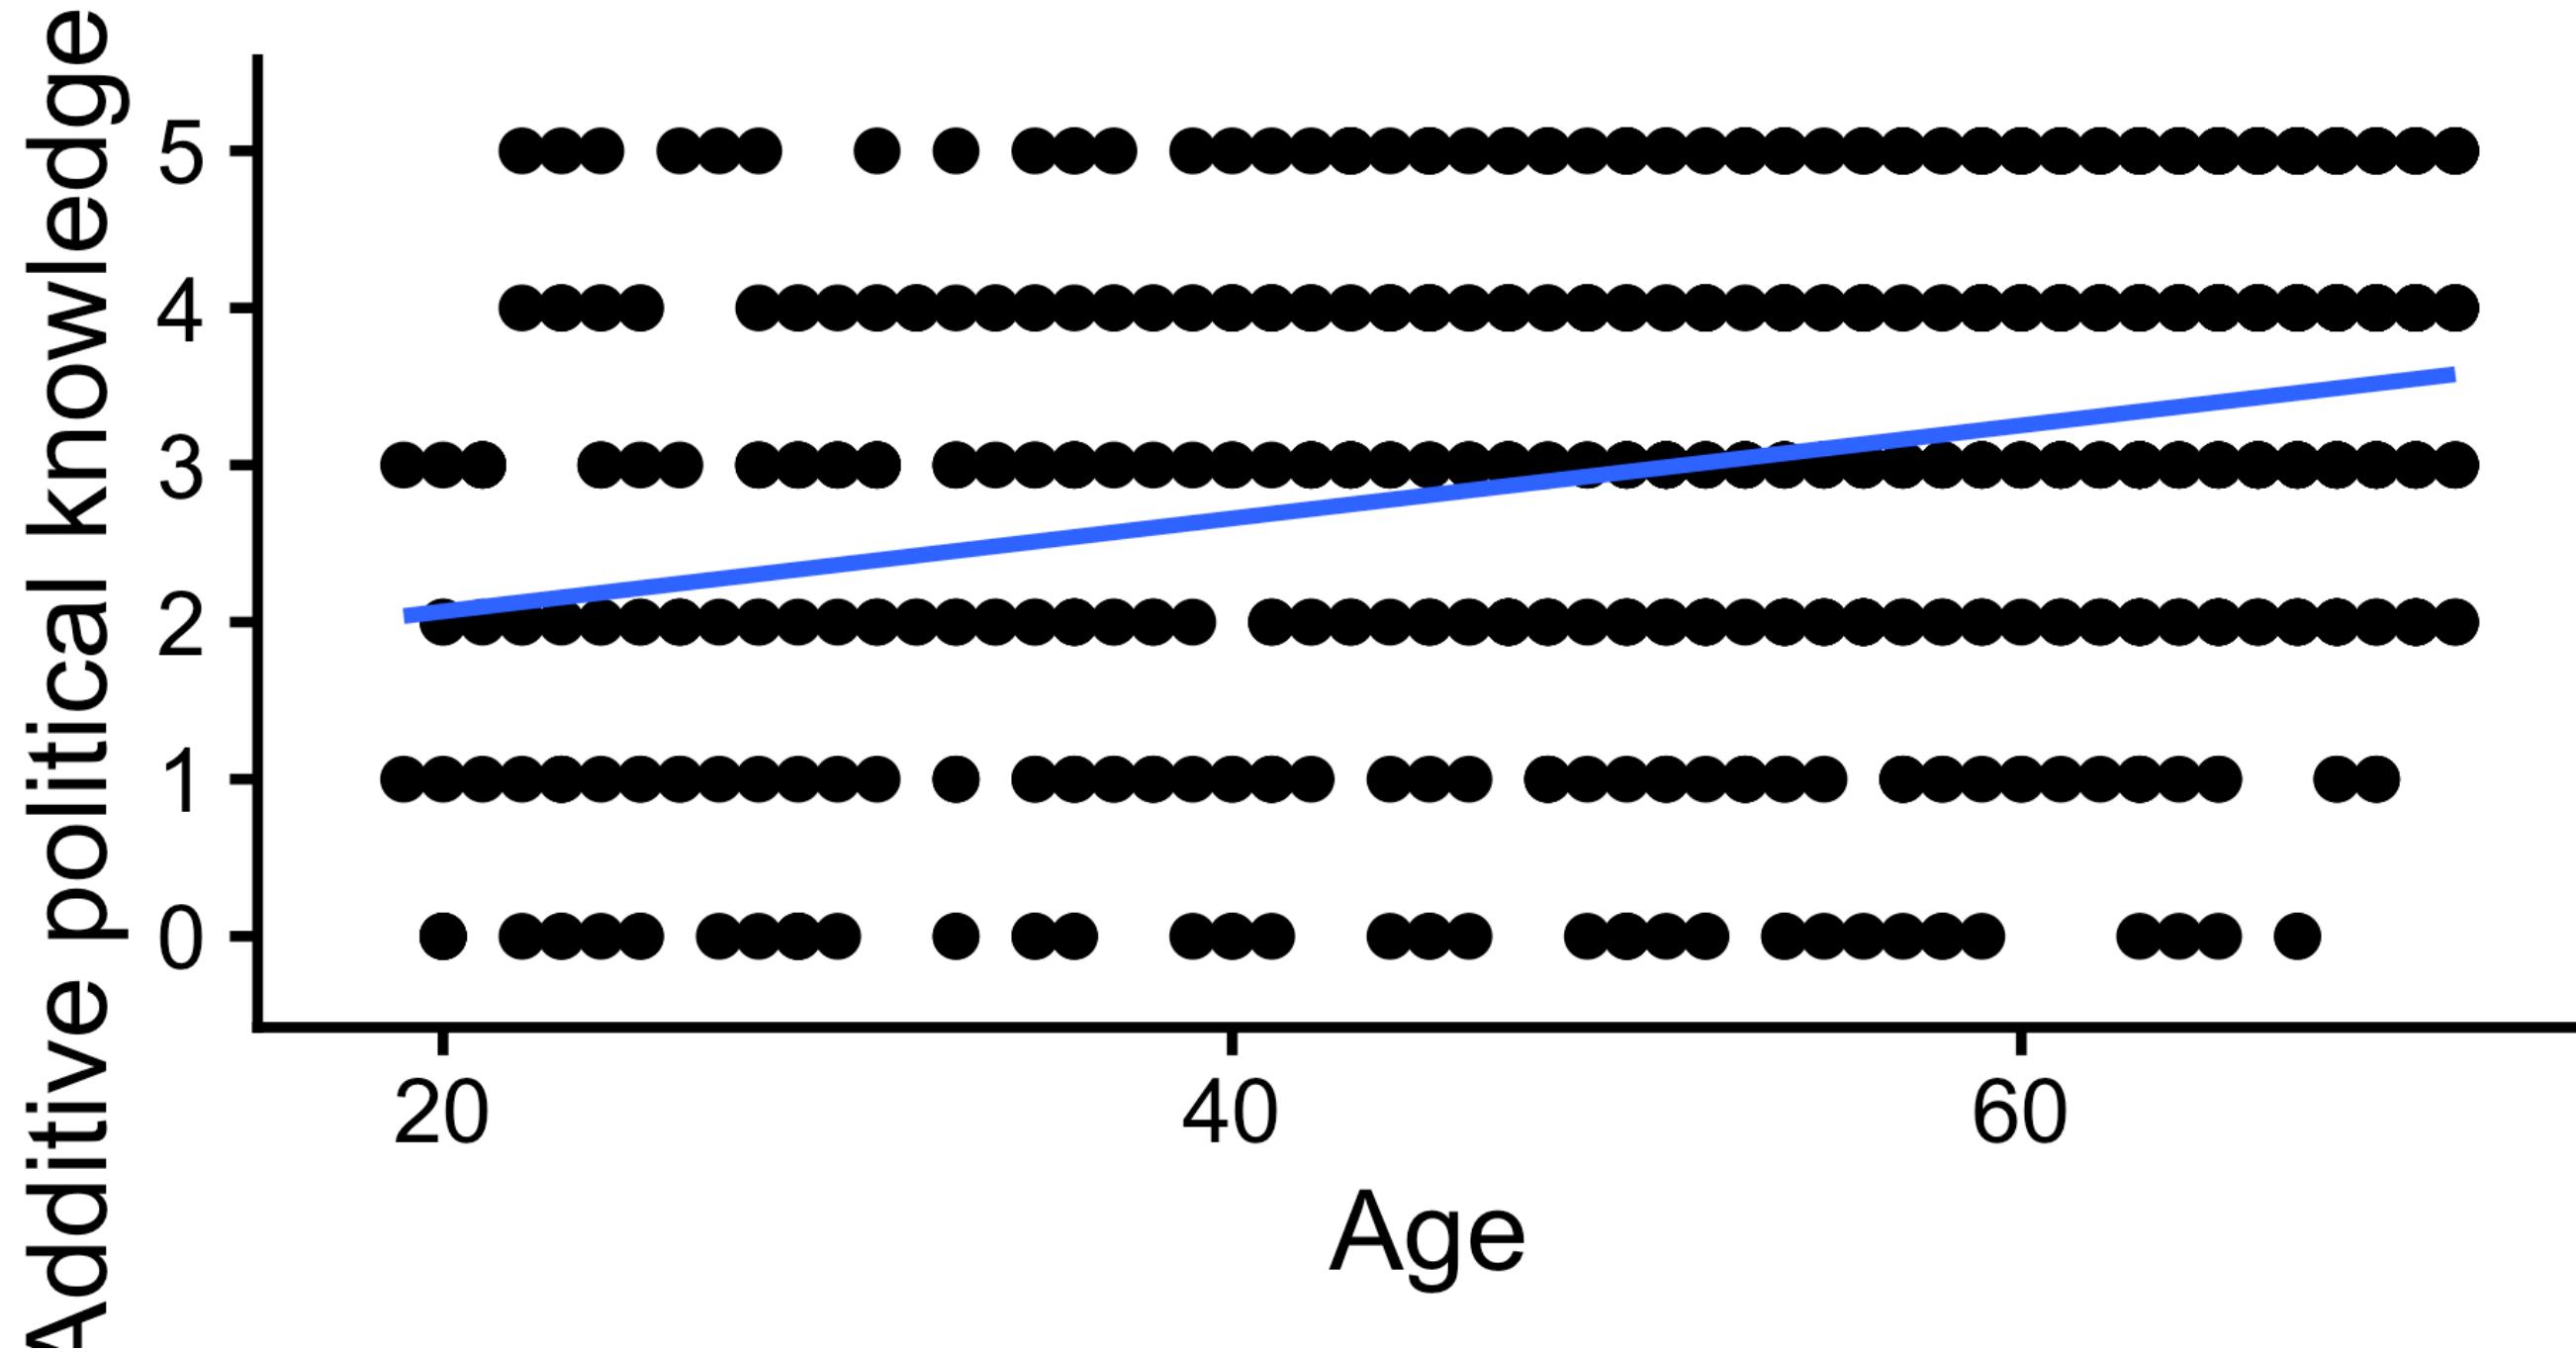


Grundlagen der Regression

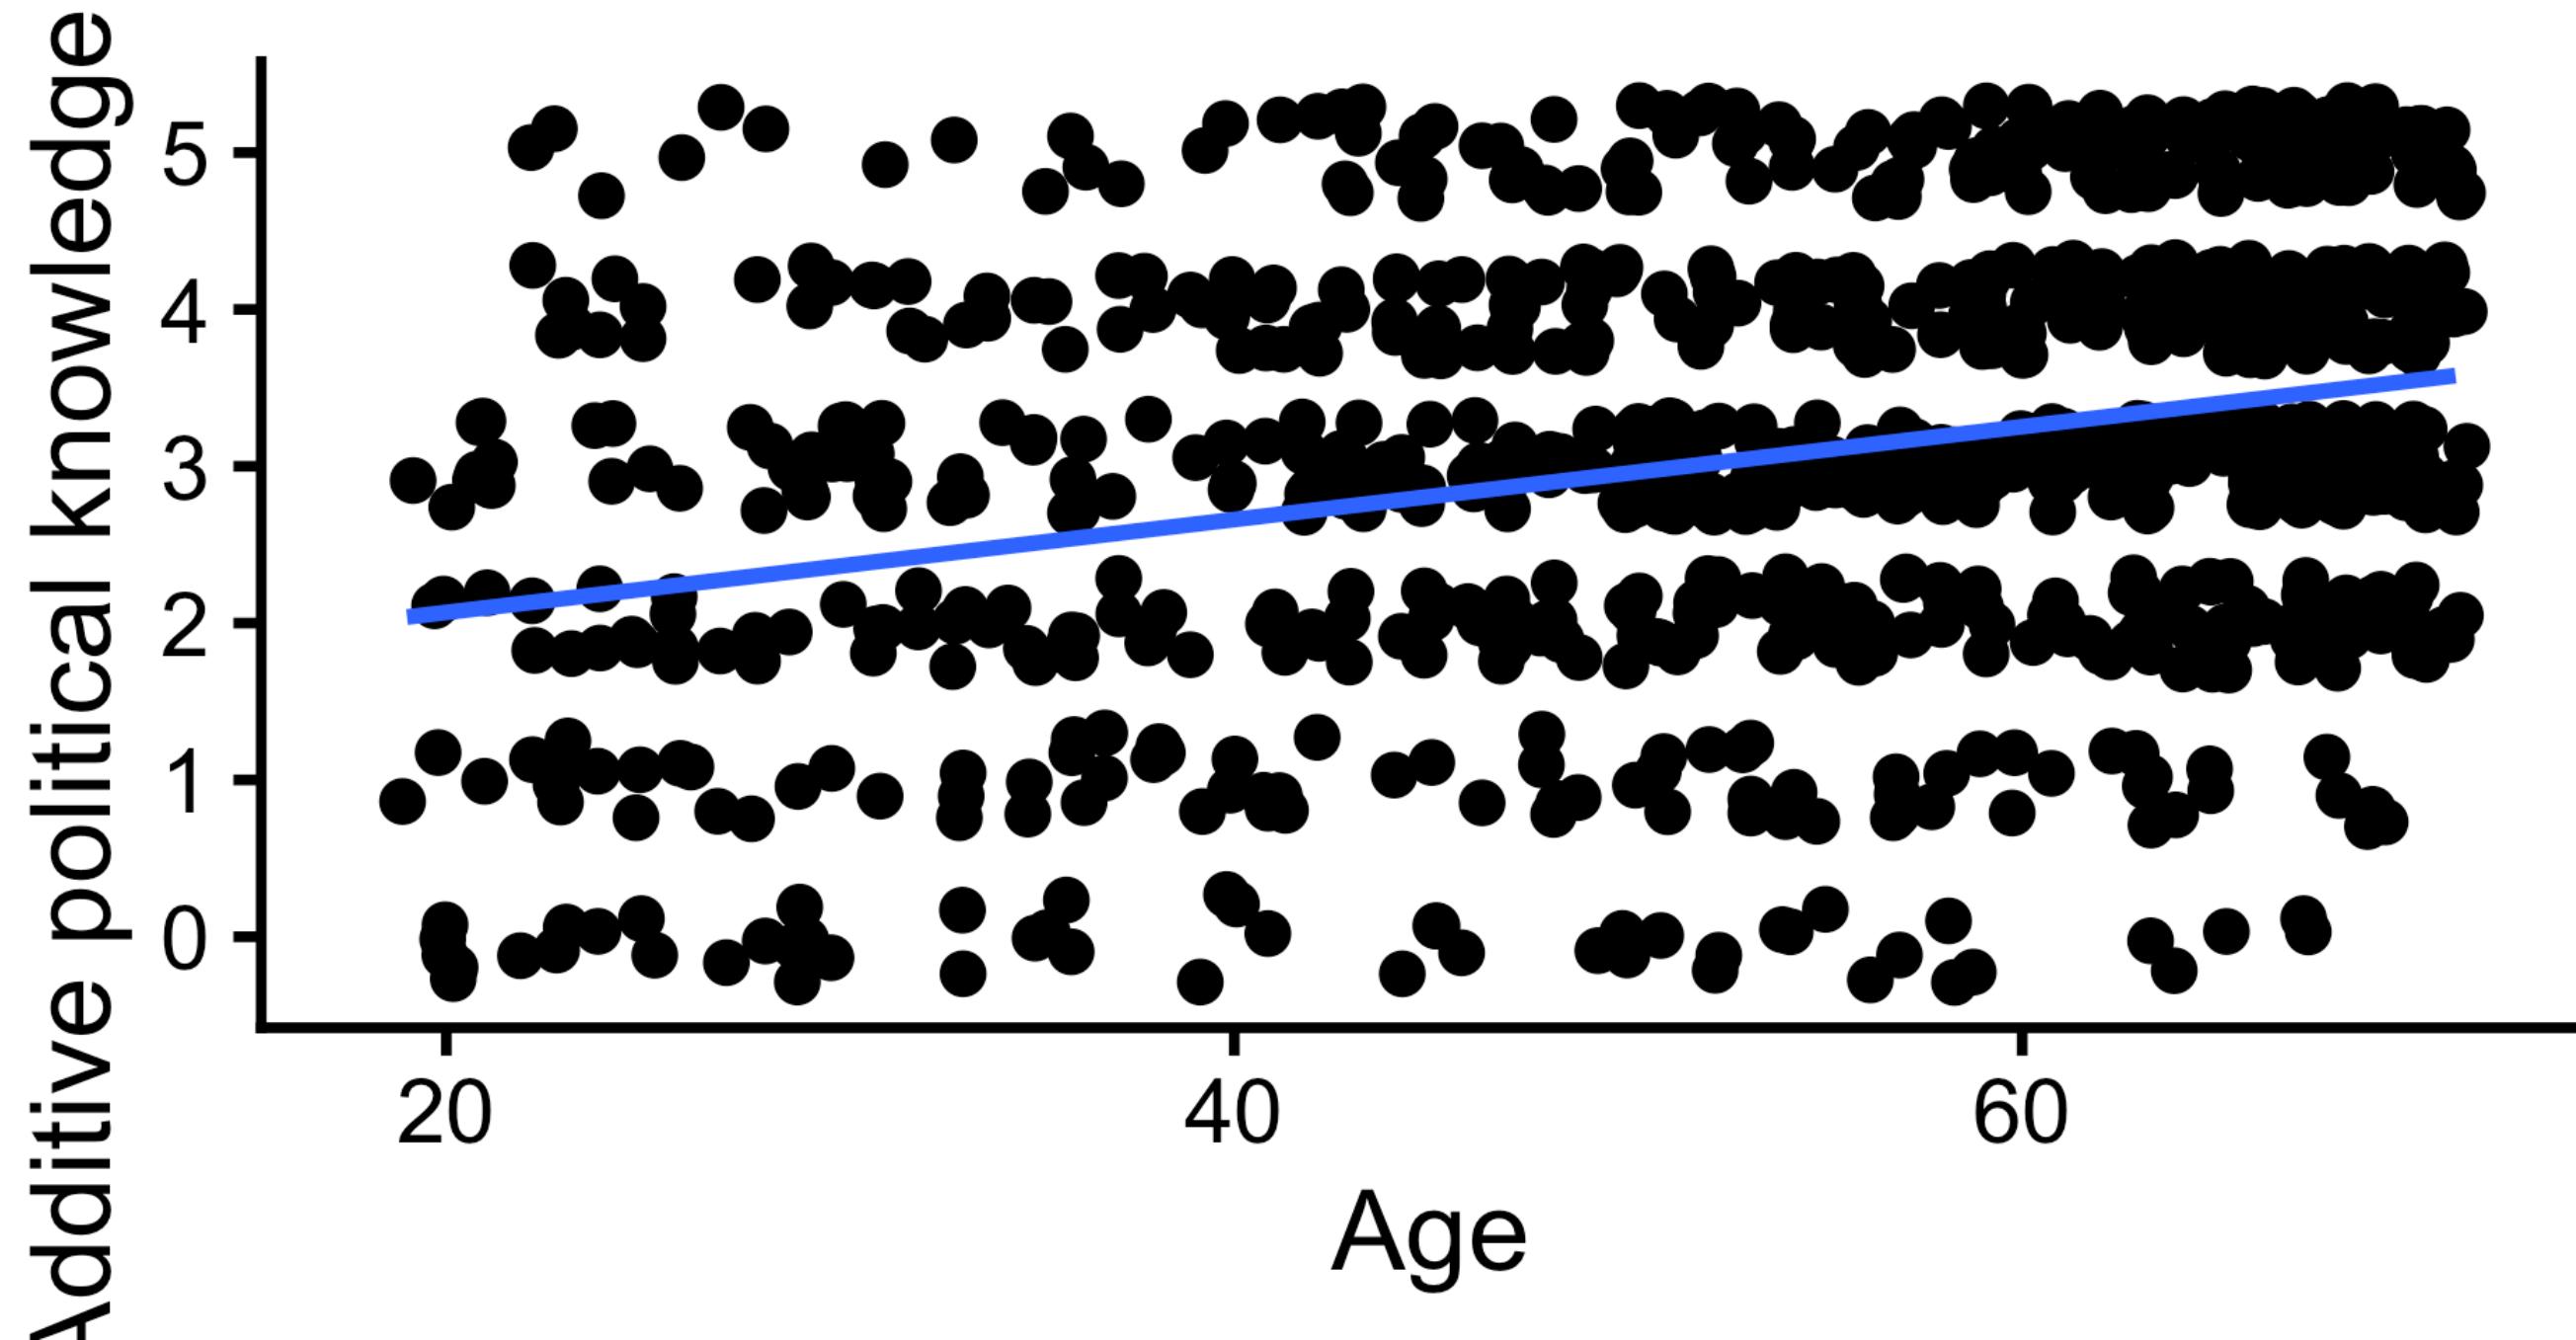
GRUNDLAGEN DER REGRESSION

- **Frage:** Welche (lineare) Beziehung besteht zwischen zwei metrischen Variablen?
- **Funktion:** Beschreibung der bivariaten Verteilung zweier metrischer Variablen
- **Konvention:** Mit *Regression* ist meist eine lineare Regression mit OLS-Schätzung (ordinary least squares, Methode der kleinsten Quadrate) gemeint

SCATTERPLOT UND REGRESSIONSGRADE

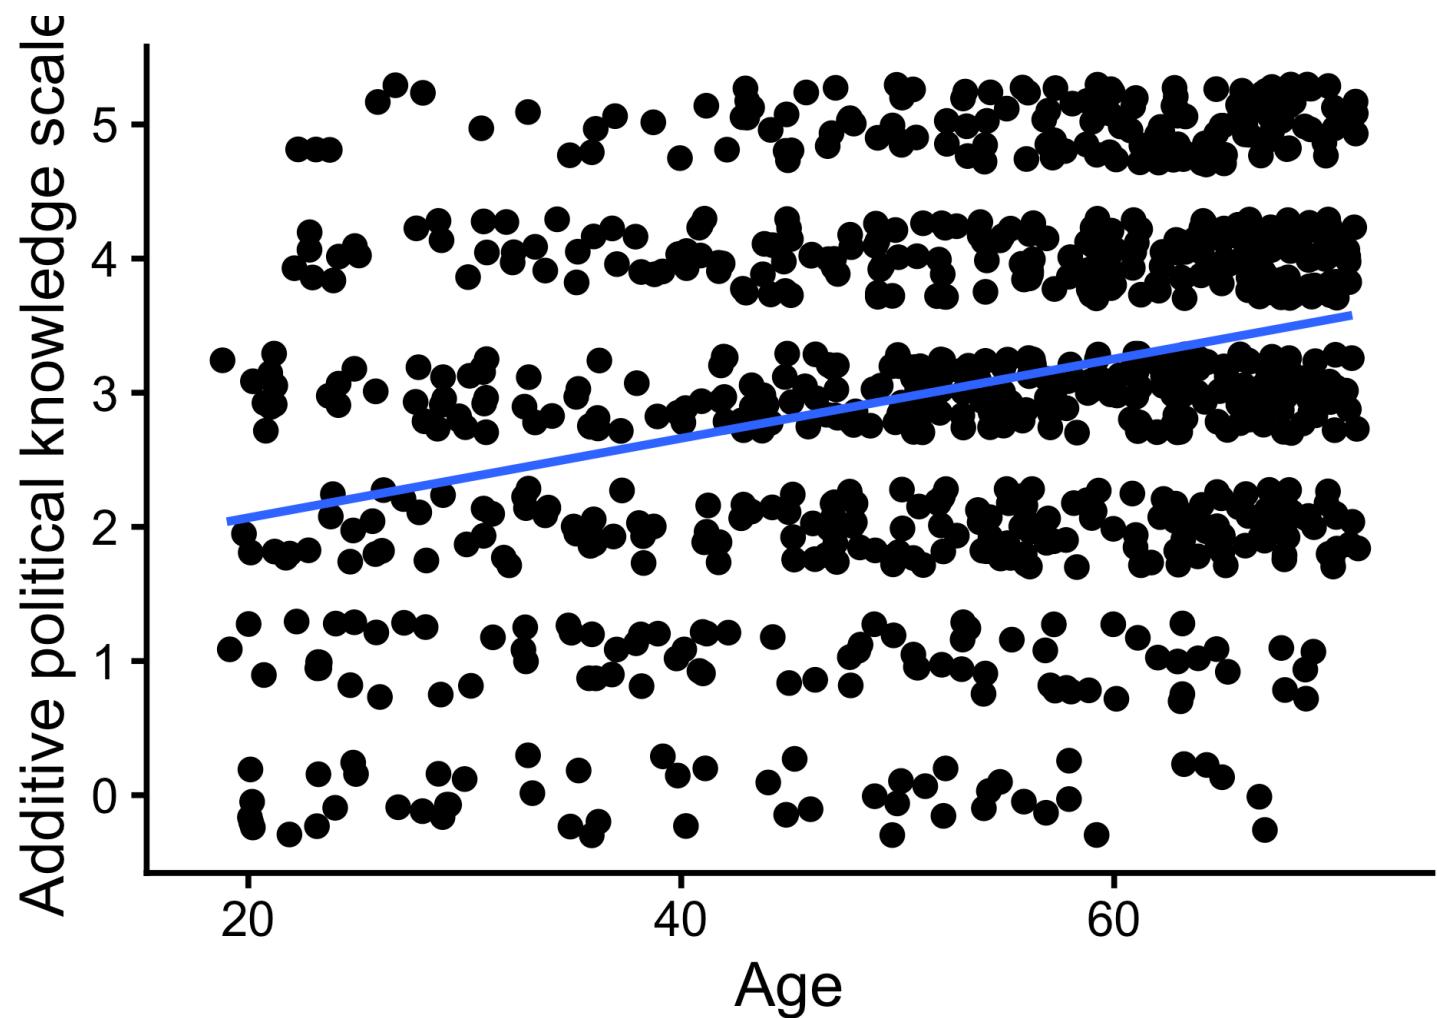


JITTERED SCATTERPLOT UND REGRESSIONSGERADE



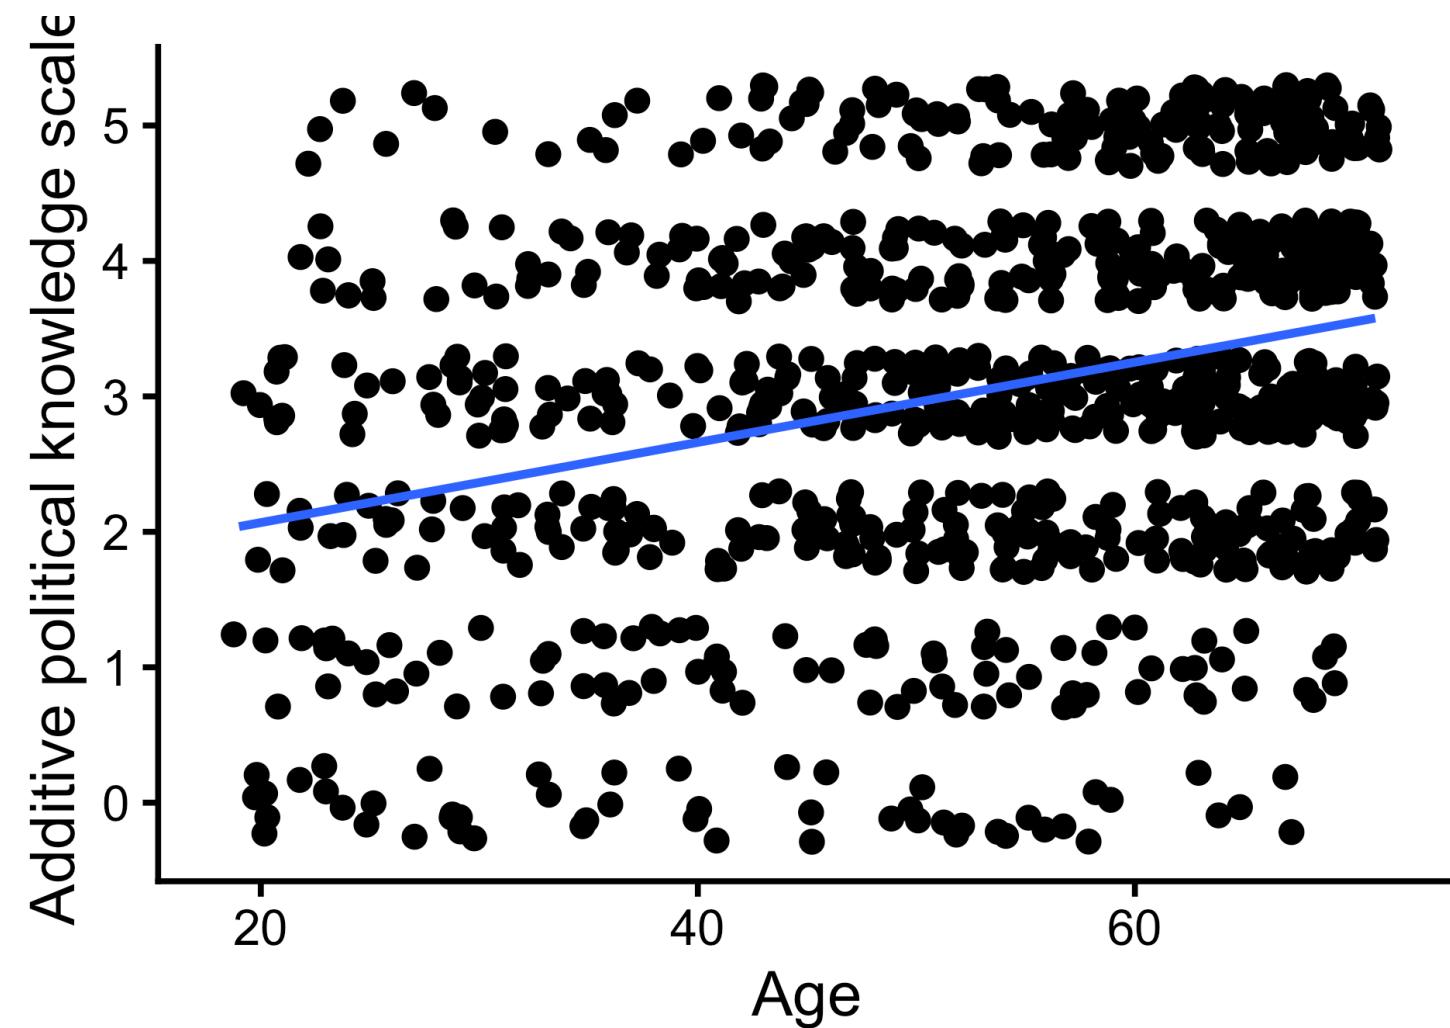
KOEFFIZIENTEN

```
Call:  
lm(formula = Political_knowledge ~ Age, data = d)  
  
Coefficients:  
(Intercept)          Age  
       1.4761        0.0296
```



KOEFFIZIENTEN

- In der bivariaten Regression wird eine Gerade durch die Punkte des Streudiagramms gelegt
- Die Gerade wird durch die durch eine lineare Gleichung mit zwei Koeffizienten definiert:
- allgemein: $y = b_0 + b_1 * x$
- hier: Political_knowledge = 1.48 + 0.03 * Age
- Mit b_0 Schnittpunkt mit Y-Achse (Konstante, Intercept) und b_1 Steigung der Gerade (Slope)
- b_0 : Wenn Age den Wert 0 hat, dann hat Political_knowledge den Wert 1.48.
- b_1 : Wenn Age um 1 Jahr steigt, dann steigt Political_knowledge um 0.03.

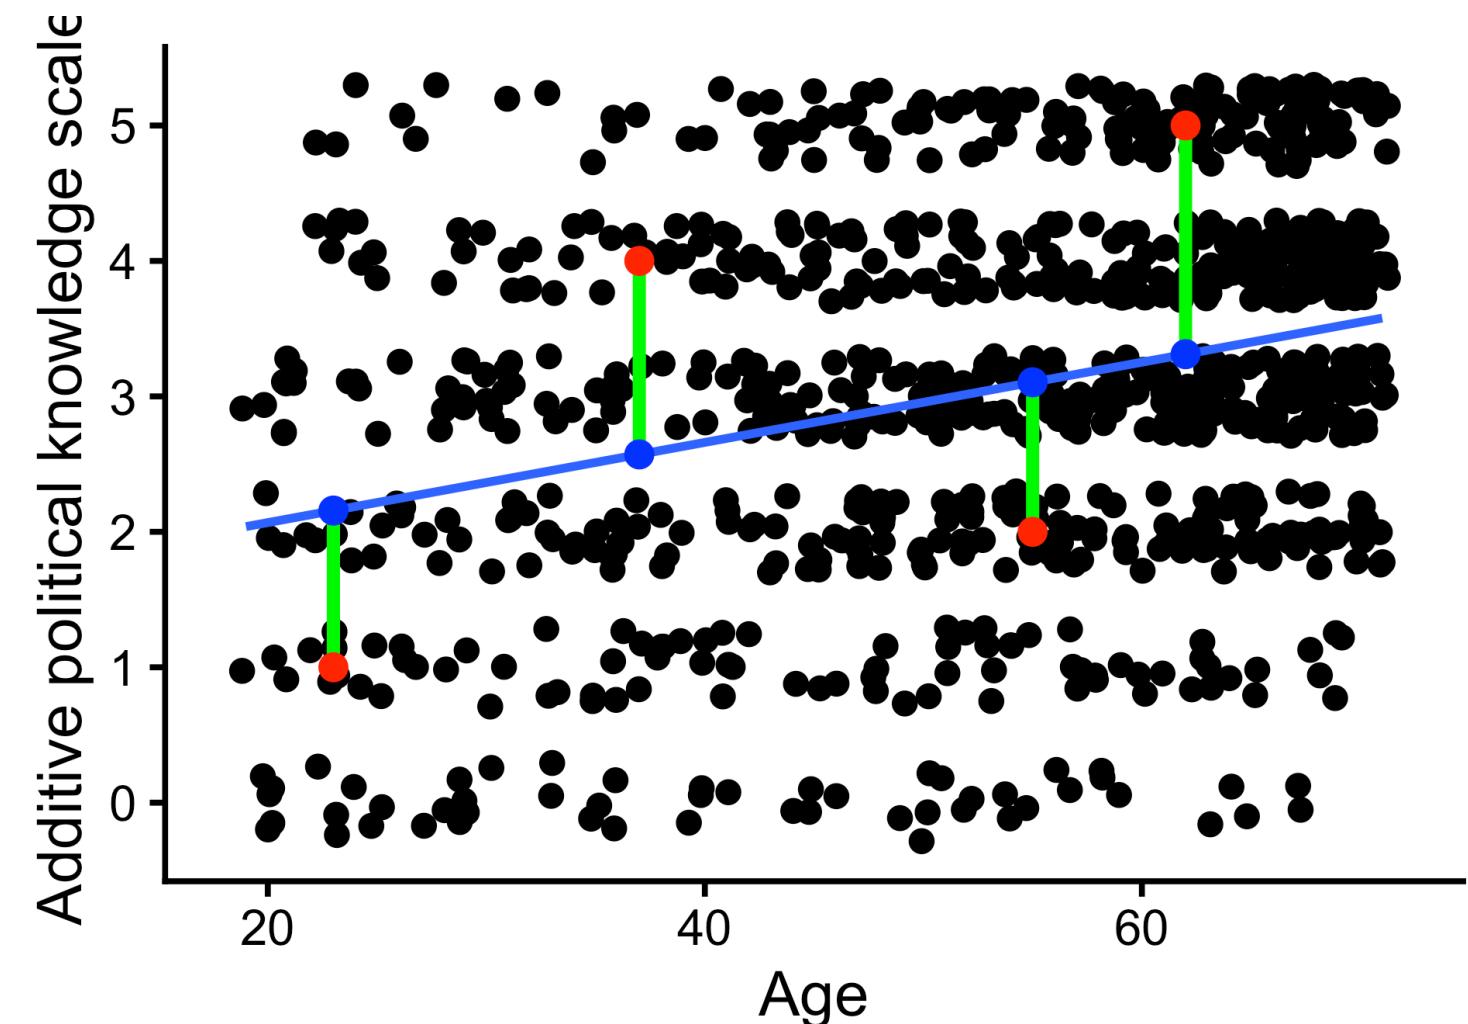


SCHÄTZUNG

Beispiel für vier Befragte:

Age	y	yhat	e	e2
23	1	2.16	-1.16	1.34
37	4	2.57	1.43	2.04
55	2	3.10	-1.10	1.22
62	5	3.31	1.69	2.85

- y: Beobachteter Wert
- \hat{y} : Vorhergesagter Wert
- e: Residuum, Vorhersagefehler
- Die Regressionsgerade minimiert die Fehlerquadratsumme.
- Mit OLS-Schätzung: $b_1 = \frac{\sum(x_i - \bar{x}) \times (y_i - \bar{y})}{\sum(x_i - \bar{x})^2}$ und $b_0 = \bar{y} - b_1 \times \bar{x}$ oder in Matrix-Notation $\beta = (X^T X)^{-1} X^T Y$



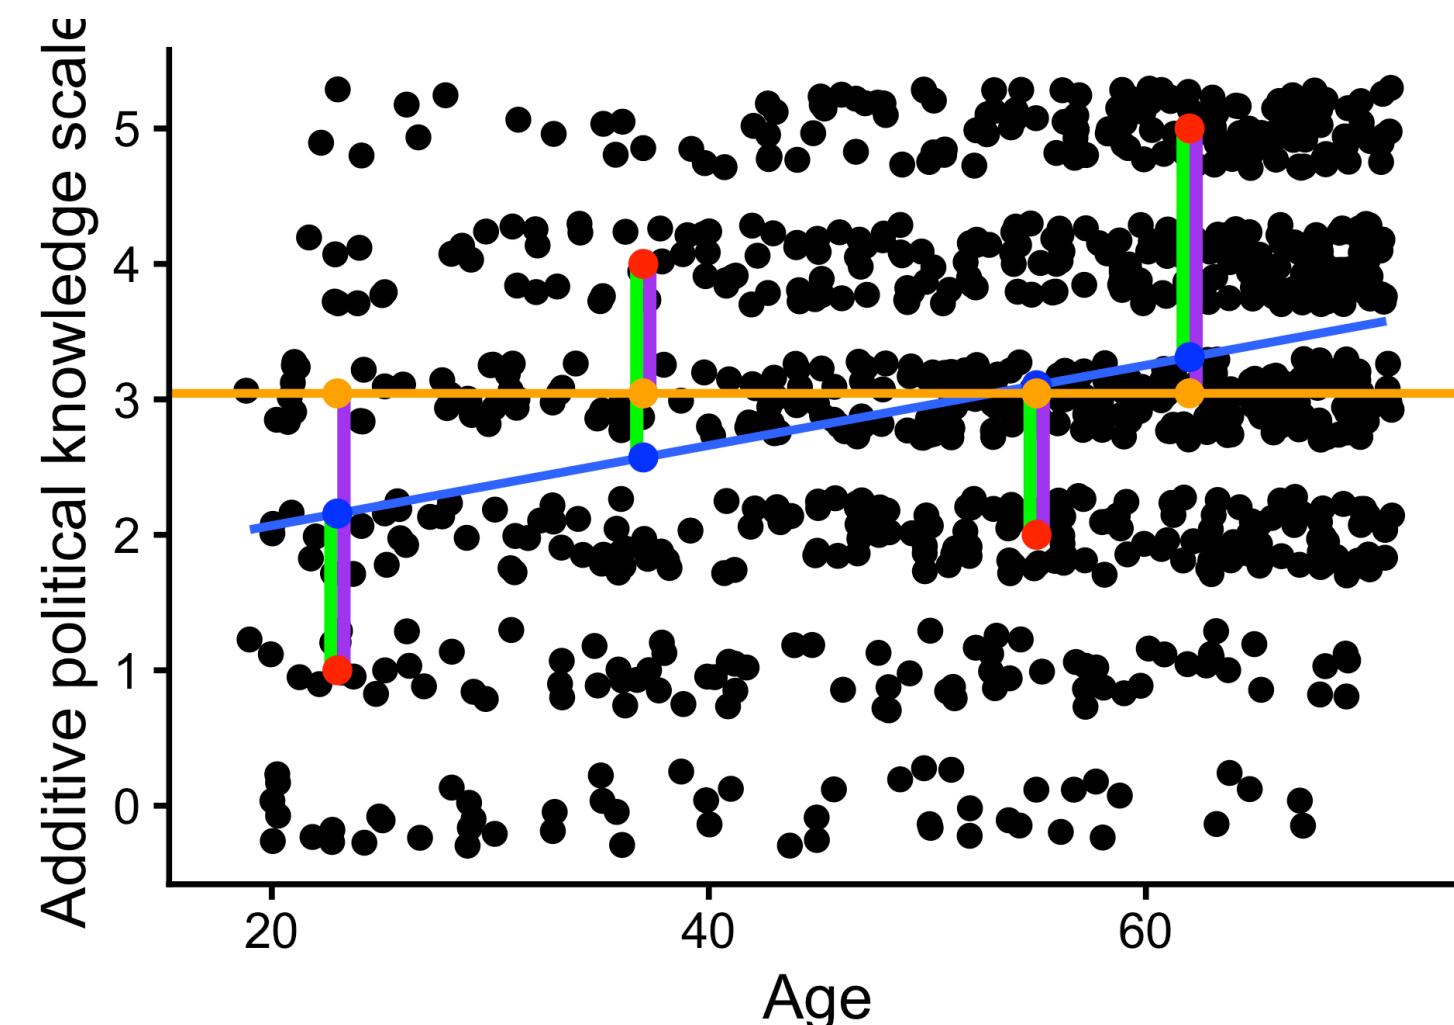
R²

Beispiel für vier Befragte:

Age	y	yhat	e	e2	e_M	e_M2
23	1	2.16	-1.16	1.34	-2.04	4.18
37	4	2.57	1.43	2.04	0.96	0.91
55	2	3.10	-1.10	1.22	-1.04	1.09
62	5	3.31	1.69	2.85	1.96	3.82

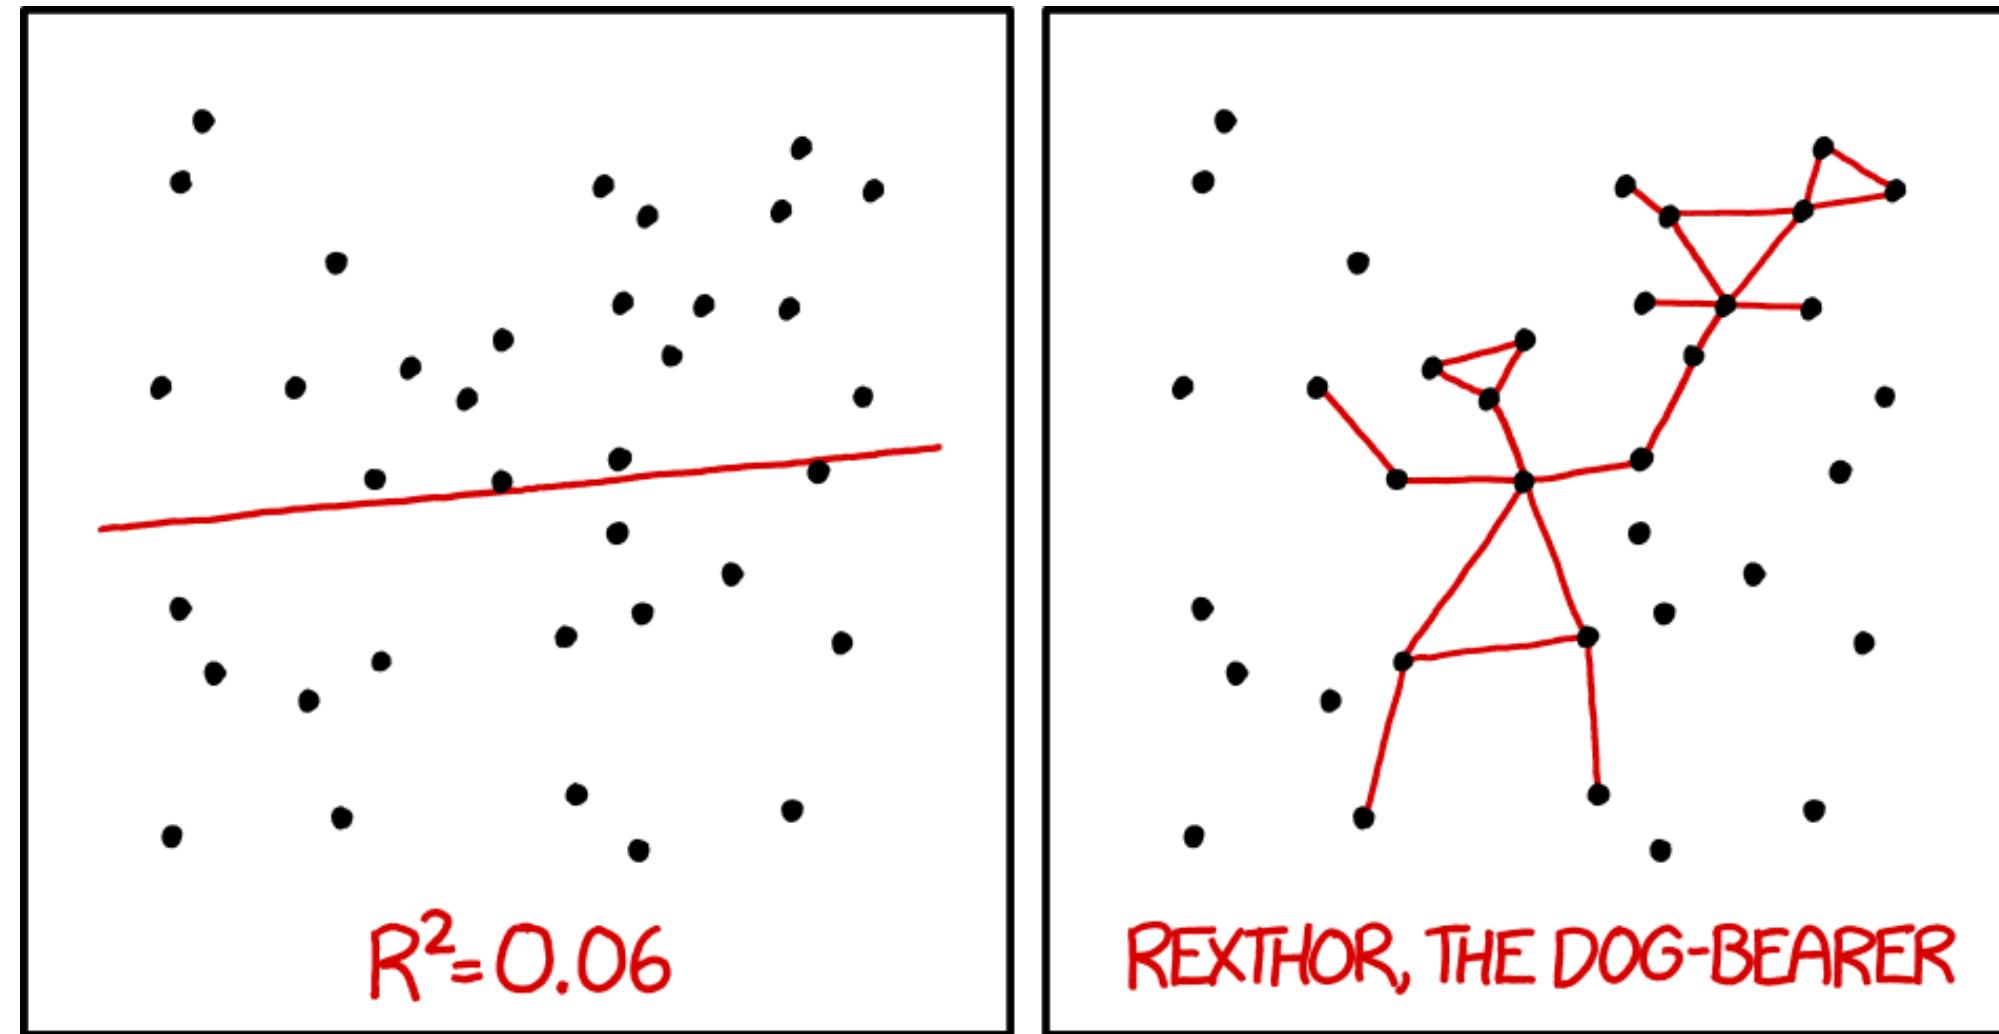
- y : Beobachteter Wert
- \hat{y} : Vorhergesagter Wert
- e : Residuum, Vorhersagefehler
- \bar{y} : Mittelwert
- e_m : Abweichung vom Mittelwert

- $R^2 = .09$: Anteil der Varianz, die das Regressionsmodell erklärt; 0 (Modell erklärt keine Varianz) bis 1 (perfekter linearer Zusammenhang). Vergleich mit Mittelwert als einfachstem Modell von y .



$$R^2 = \frac{\sum(y_i - \bar{y})^2 - \sum(y_i - \hat{y})^2}{\sum(y_i - \bar{y})^2}$$

R^2

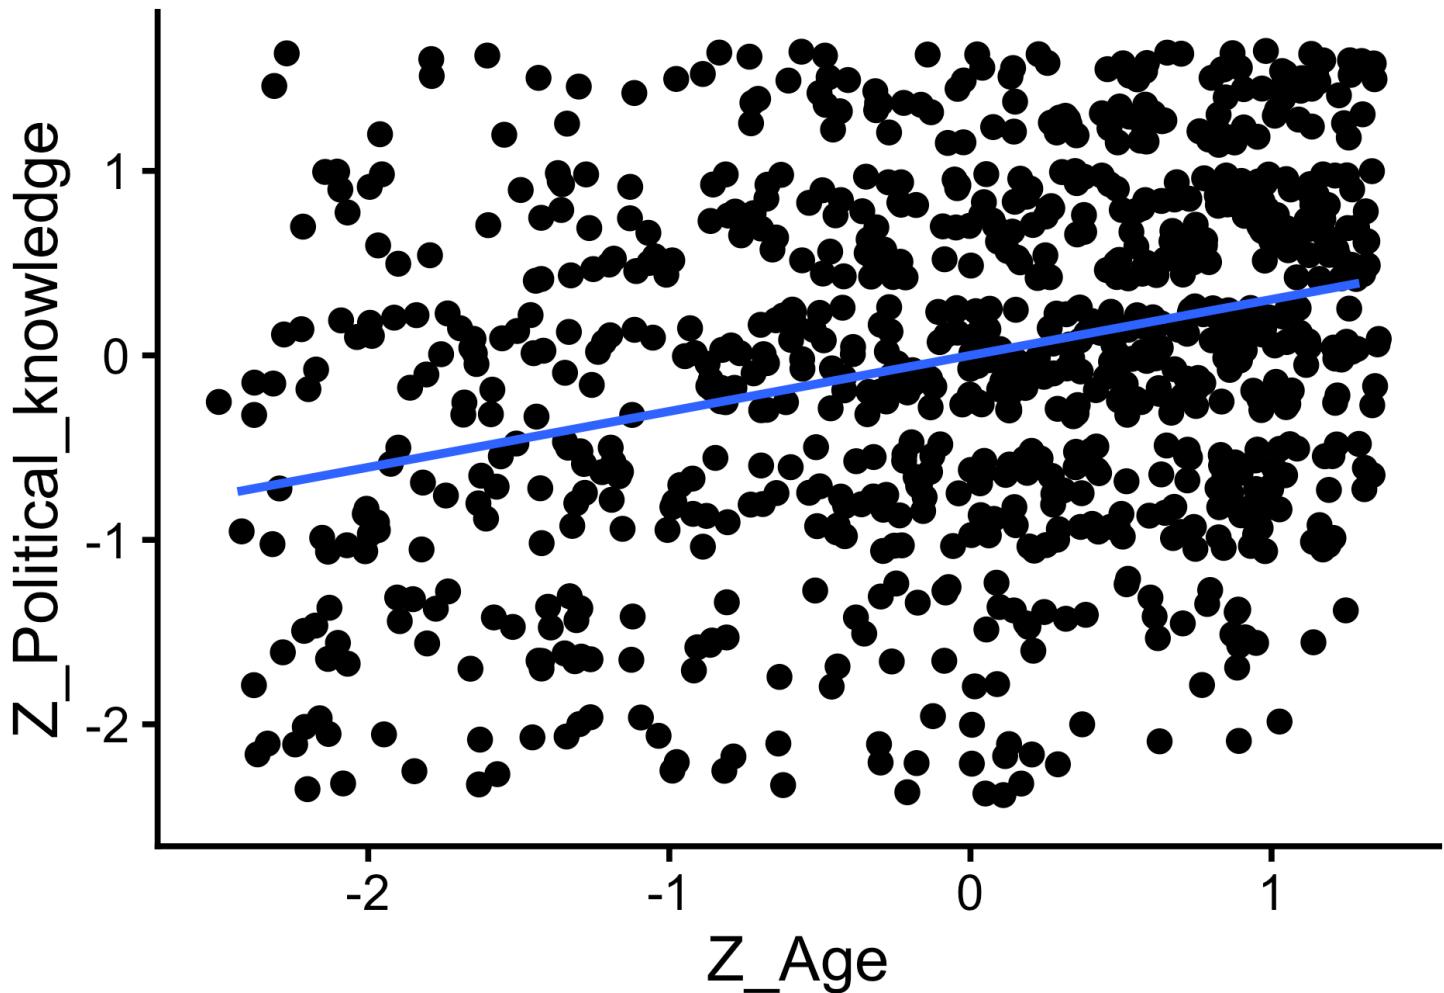


I DON'T TRUST LINEAR REGRESSIONS WHEN IT'S HARDER
TO GUESS THE DIRECTION OF THE CORRELATION FROM THE
SCATTER PLOT THAN TO FIND NEW CONSTELLATIONS ON IT.

xkcd

STANDARDISIERUNG UND (PEARSONS) r

- Standardisierter Regressionskoeffizient (unter SPSS-Nutzer:innen häufig β): $\beta_1 = b_1 \times \frac{SD_x}{SD_y}$
- Schätzung nach z-Standardisierung der Daten: $(x_i - M_x)/SD_x$ mit M_x Mittelwert von x und SD_x Standardabweichung von x
- $Z_{Political_knowledge} = 0.30 * Z_{Age};$
 $SD_{Age} = 14, SD_{Political_knowledge} = 1.4$
- Wenn das Alter um 1 SD steigt, dann steigt Political_knowledge um 0.30 SD.
- Korrelationskoeffizient Pearson r = standardisierter Regressionskoeffizient in bivariater linearer Regression; hier: $r = 0.30 = \beta_1$



STANDARDISIERUNG UND (PEARSONS) r

Vergleich in R

Regression

```
1 lm(scale(Political_knowledge) ~ scale(Age), data =
```

Call:

```
lm(formula = scale(Political_knowledge) ~ scale(Age),  
data = d)
```

Coefficients:

```
(Intercept)    scale(Age)  
 8.080e-17    3.034e-01
```

Korrelation

```
1 cor(d$Political_knowledge, d$Age)
```

```
[1] 0.3033832
```

INFERENCESTATISTIK ZUR REGRESSION

Parameter	Coefficient	95% CI	t(991)	p	Std. Coef.	Std. Coef.	Fit
						95% CI	
(Intercept)	1.48	(1.16, 1.79)	9.12	< .001	0.00	(-0.06, 0.06)	
Age	0.03	(0.02, 0.04)	10.02	< .001	0.30	(0.24, 0.36)	
R2							0.09

INFERENZSTATISTIK ZUR KORRELATION

$r = 0.30$, 95% CI [0.25, 0.36], $t(991) = 10.02$, $p < .001$

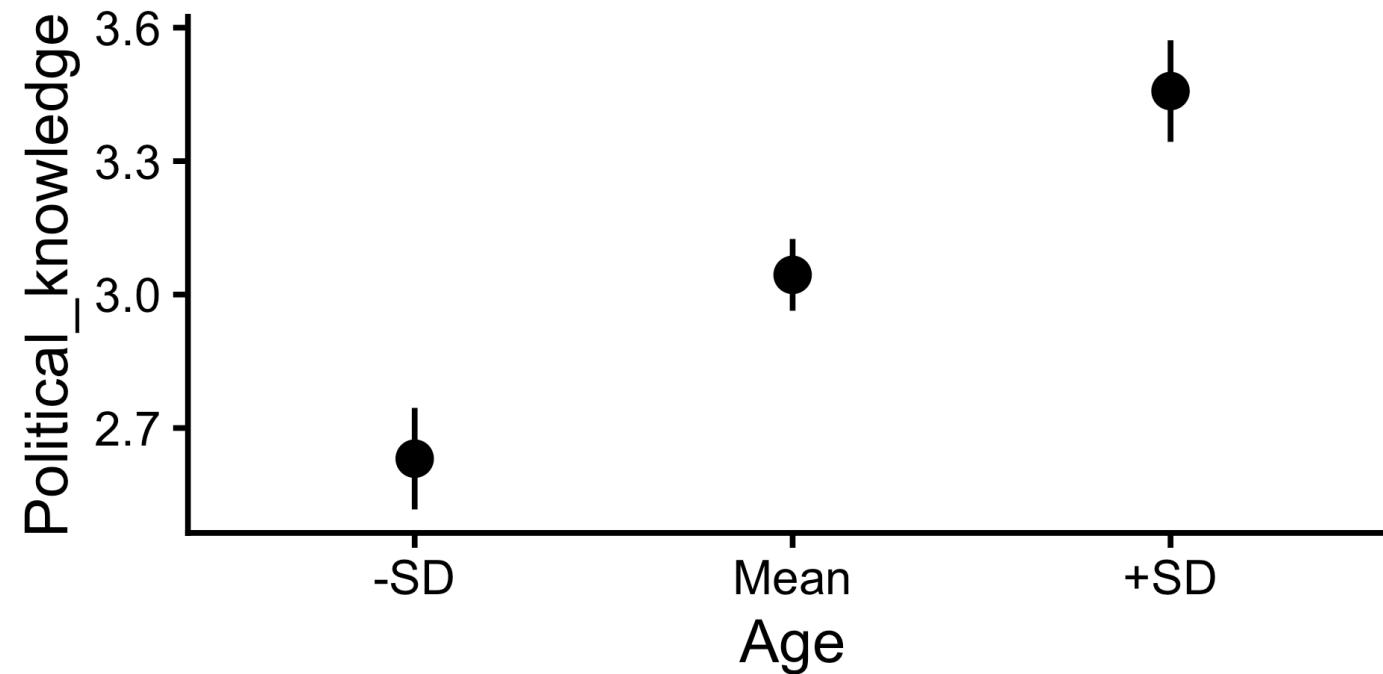
VORHERSAGEN: TABELLE

Age	Estimate	Std. Error	z	Pr(> z)	S	2.5 %	97.5 %
39.0	2.63	0.0583	45.1	<0.001	Inf	2.52	2.75
53.0	3.04	0.0412	73.9	<0.001	Inf	2.96	3.13
66.9	3.46	0.0583	59.3	<0.001	Inf	3.34	3.57

Type: response

- Mit der Regressionsgleichung lassen sich Vorhersagen der abhängigen Variable für beliebige Werte der Prädiktoren machen.
- Hier: Für Personen mit unterdurchschnittlichem ($M - SD$), durchschnittlichen (M) und überdurchschnittlichen ($M + SD$) Alter

VORHERSAGEN: PLOT



- Mit der Regressionsgleichung lassen sich Vorhersagen der abhängigen Variable für beliebige Werte der Prädiktoren machen.
- Hier: Für Personen mit unterdurchschnittlichem ($M - SD$), durchschnittlichen (M) und überdurchschnittlichen ($M + SD$) Alter

INTERPRETATION

	Nicht standardisiert	Standardisiert (Korrelation)
Vergleich (immer möglich)	<p>Wir vergleichen zwei Personen, die sich im Alter um ein Jahr unterscheiden. Die ältere Person beantwortet 0.03 Fragen mehr korrekt als die jüngere Person.</p>	<p>Wir vergleichen zwei Personen, die sich im Alter um eine SD unterscheiden. Die ältere Person liegt in der Verteilung der korrekt beantworteten Fragen um 0.3 SD über der jüngeren Person.</p>
Veränderung, Intervention (kausal; zusätzliche Annahmen)	<p>Wenn eine Person um ein Jahr älter wird, dann beantwortet sie 0.03 Fragen mehr korrekt.</p>	<p>Wenn eine Person sich in der Altersverteilung um eine SD nach oben bewegt, dann bewegt sie sich in der Verteilung der korrekt beantworteten Fragen um 0.3 SD nach oben.</p>

Fragen?

Regression und Mittelwertvergleich

REGRESSION UND MITTELWERTVERGLEICH

- Wir können Mittelwertvergleiche innerhalb der linearen Regression durchführen.
- In bivariater Analyse äquivalent zum T-Test. Interessanter in multipler Regression (Mittelwertvergleiche unter Berücksichtigung weiterer Variablen)

BINÄRE PRÄDIKTOREN (ALLGEMEIN)

- Gruppierungsvariable X wird in eine *Dummy*-Variable recodiert (0 = Merkmal nicht vorhanden; Referenzgruppe, 1 = Merkmal vorhanden)
- Regressionsgerade: $Y = b_0 + b_1 \times X + \varepsilon$
- Wenn $X = 0$: $Y = b_0 + \varepsilon$
- b_0 ist Mittelwert der Referenzgruppe
- b_1 ist Differenz zwischen Referenzgruppe und Gruppe mit Merkmal

BINÄRE PRÄDIKTOREN (BEISPIEL)

- Gender wird in eine *Dummy*-Variable female recodiert
(0 = not female [hier: male], 1 = female)
- Regressionsgerade: $Y = b_0 + b_1 \times \text{female} + \varepsilon$
- Wenn $\text{female} = 0$: $Y = b_0 + \varepsilon$
- b_0 ist Mittelwert der Männer
- b_1 ist Differenz zwischen Männern und Frauen

Regression

Parameter	Coefficient	95% CI	t(991)	p	Fit
(Intercept)	3.44	(3.33, 3.55)	60.48	< .001	
Gender (female)	-0.84	(-1.00, -0.67)	-10.14	< .001	
R2					0.09

T-Test

Parameter	Group	Mean_Group1	Mean_Group2	Difference	95% CI	t(987.31)	p	Cohen's d
Political_knowledge	Gender	3.44	2.61	0.84	(0.67, 1.00)	10.15	< .001	0.64

Fragen?

Annahmen und ihre Überprüfung

ANNAHMEN UND IHRE ÜBERPRÜFUNG

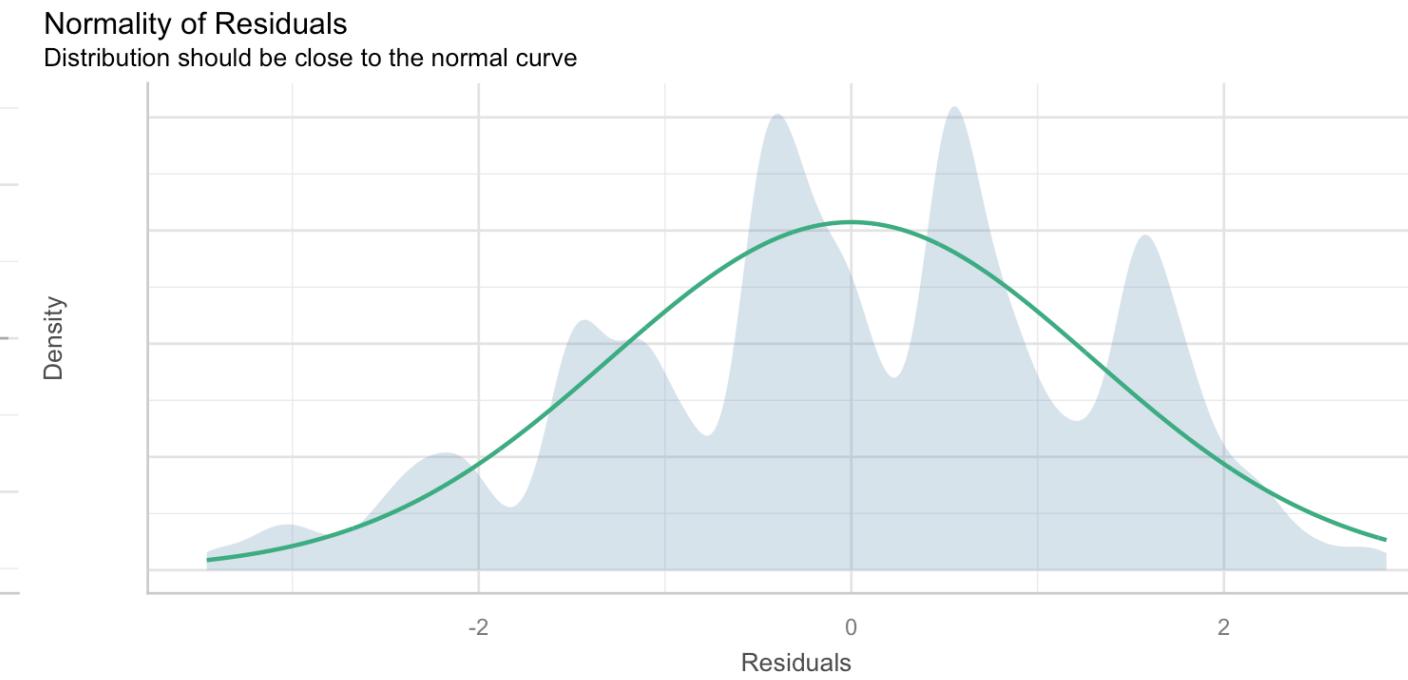
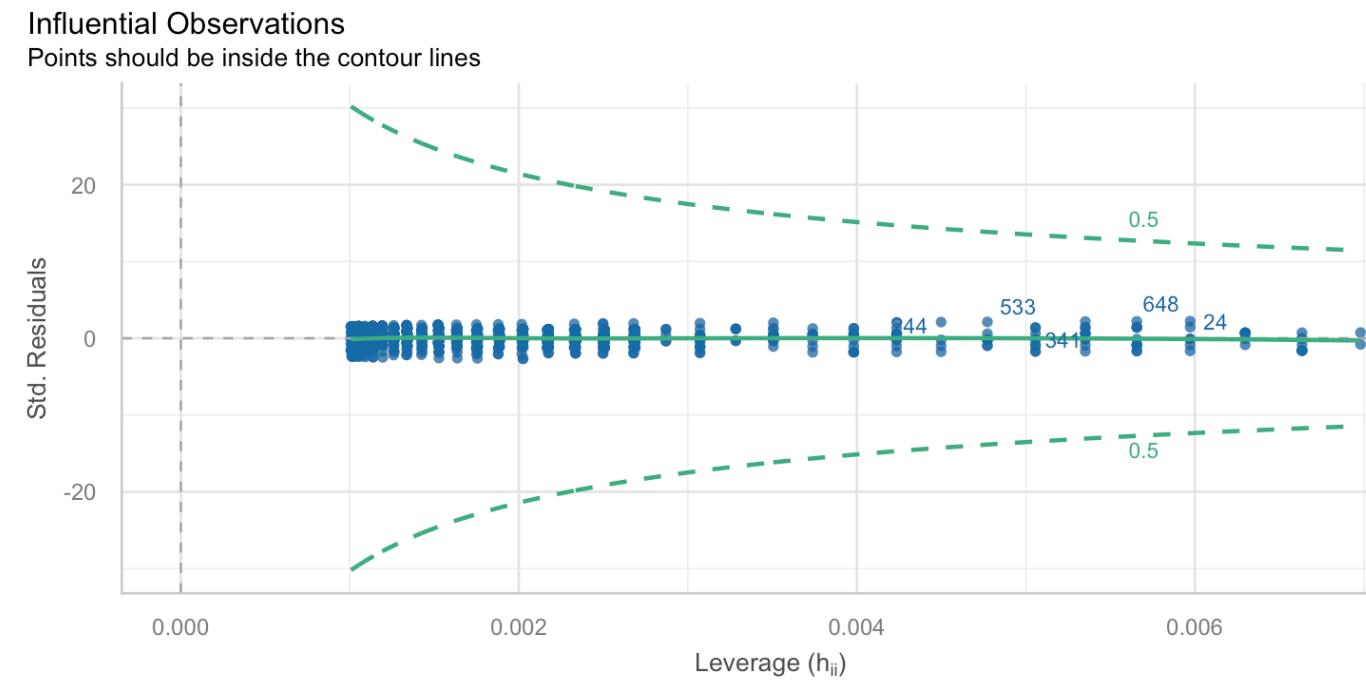
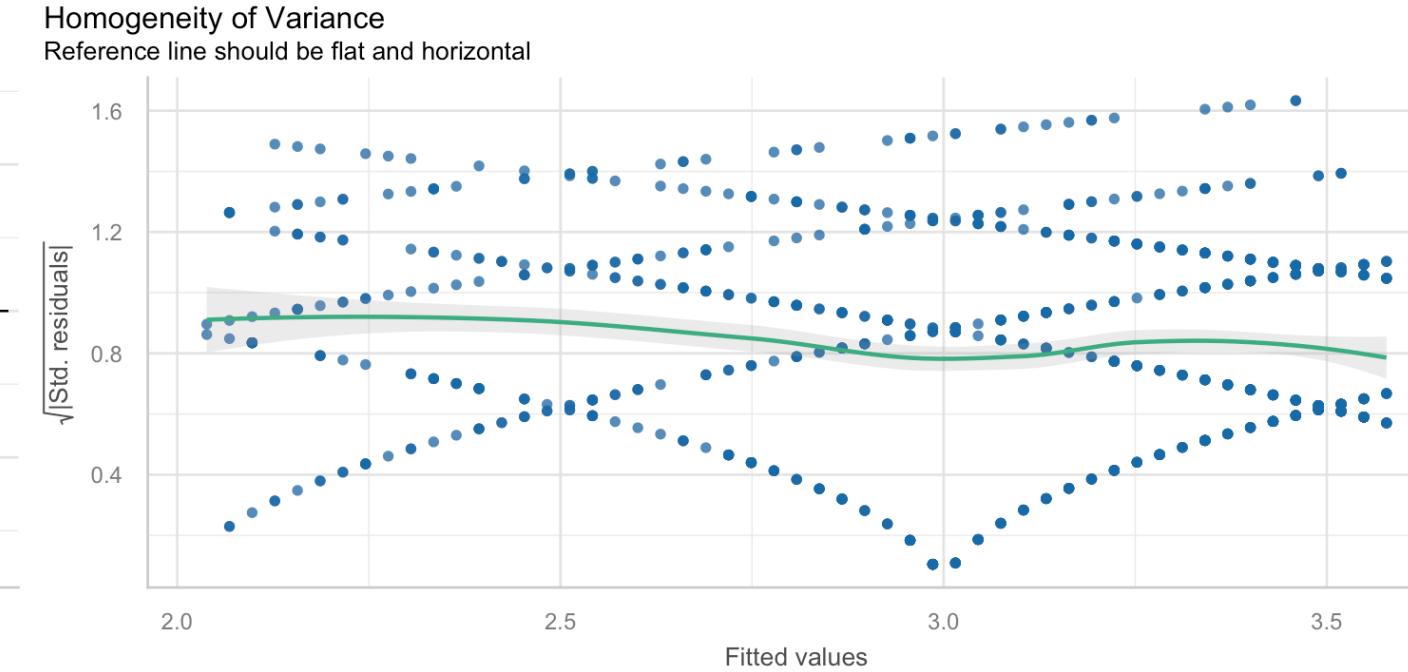
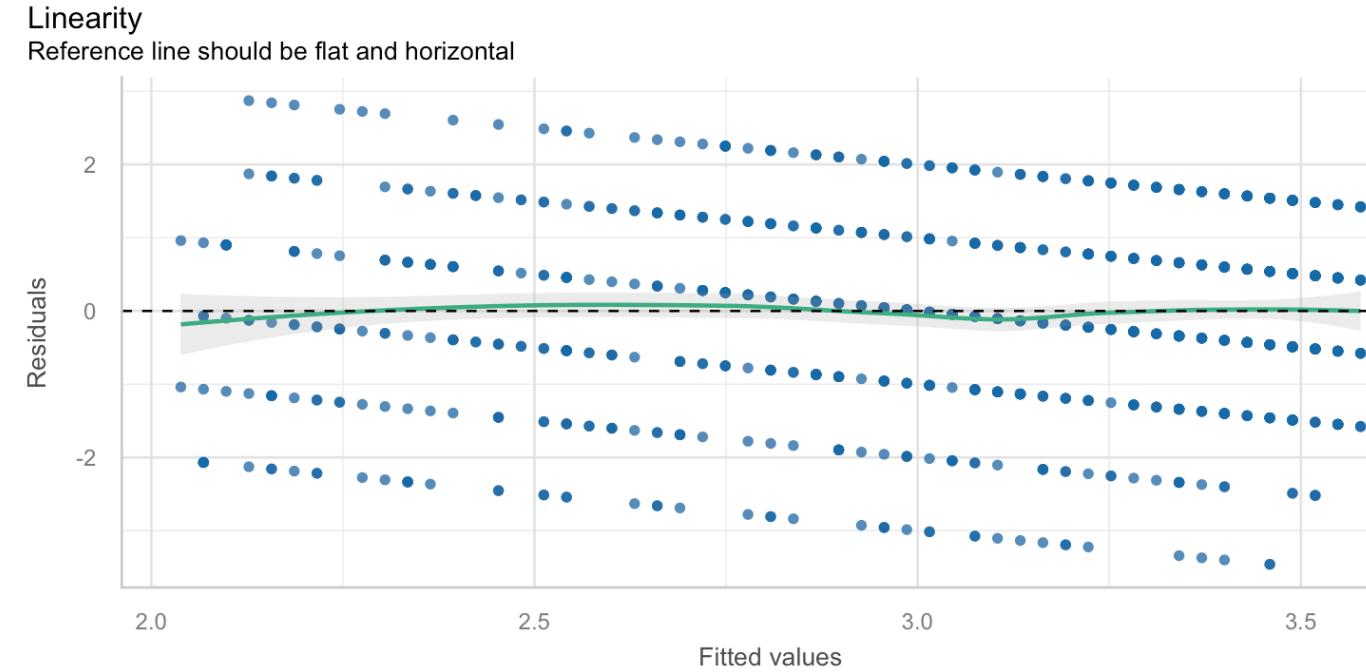
Statistische Annahmen

- Linearität und Additivität der Zusammenhänge
- Normalverteilung und Homoskedastizität der Residuen
- Unabhängigkeit der Residuen
- keine einflussreichen Ausreißer
- (keine Multikollinearität) [→ Multiple Regression]

Kausalannahmen

- korrekt spezifiziertes Modell; keine fehlenden oder überflüssigen Variablen
- Besprechen wir in eigener Einheit

ANNAHMEN UND IHRE ÜBERPRÜFUNG



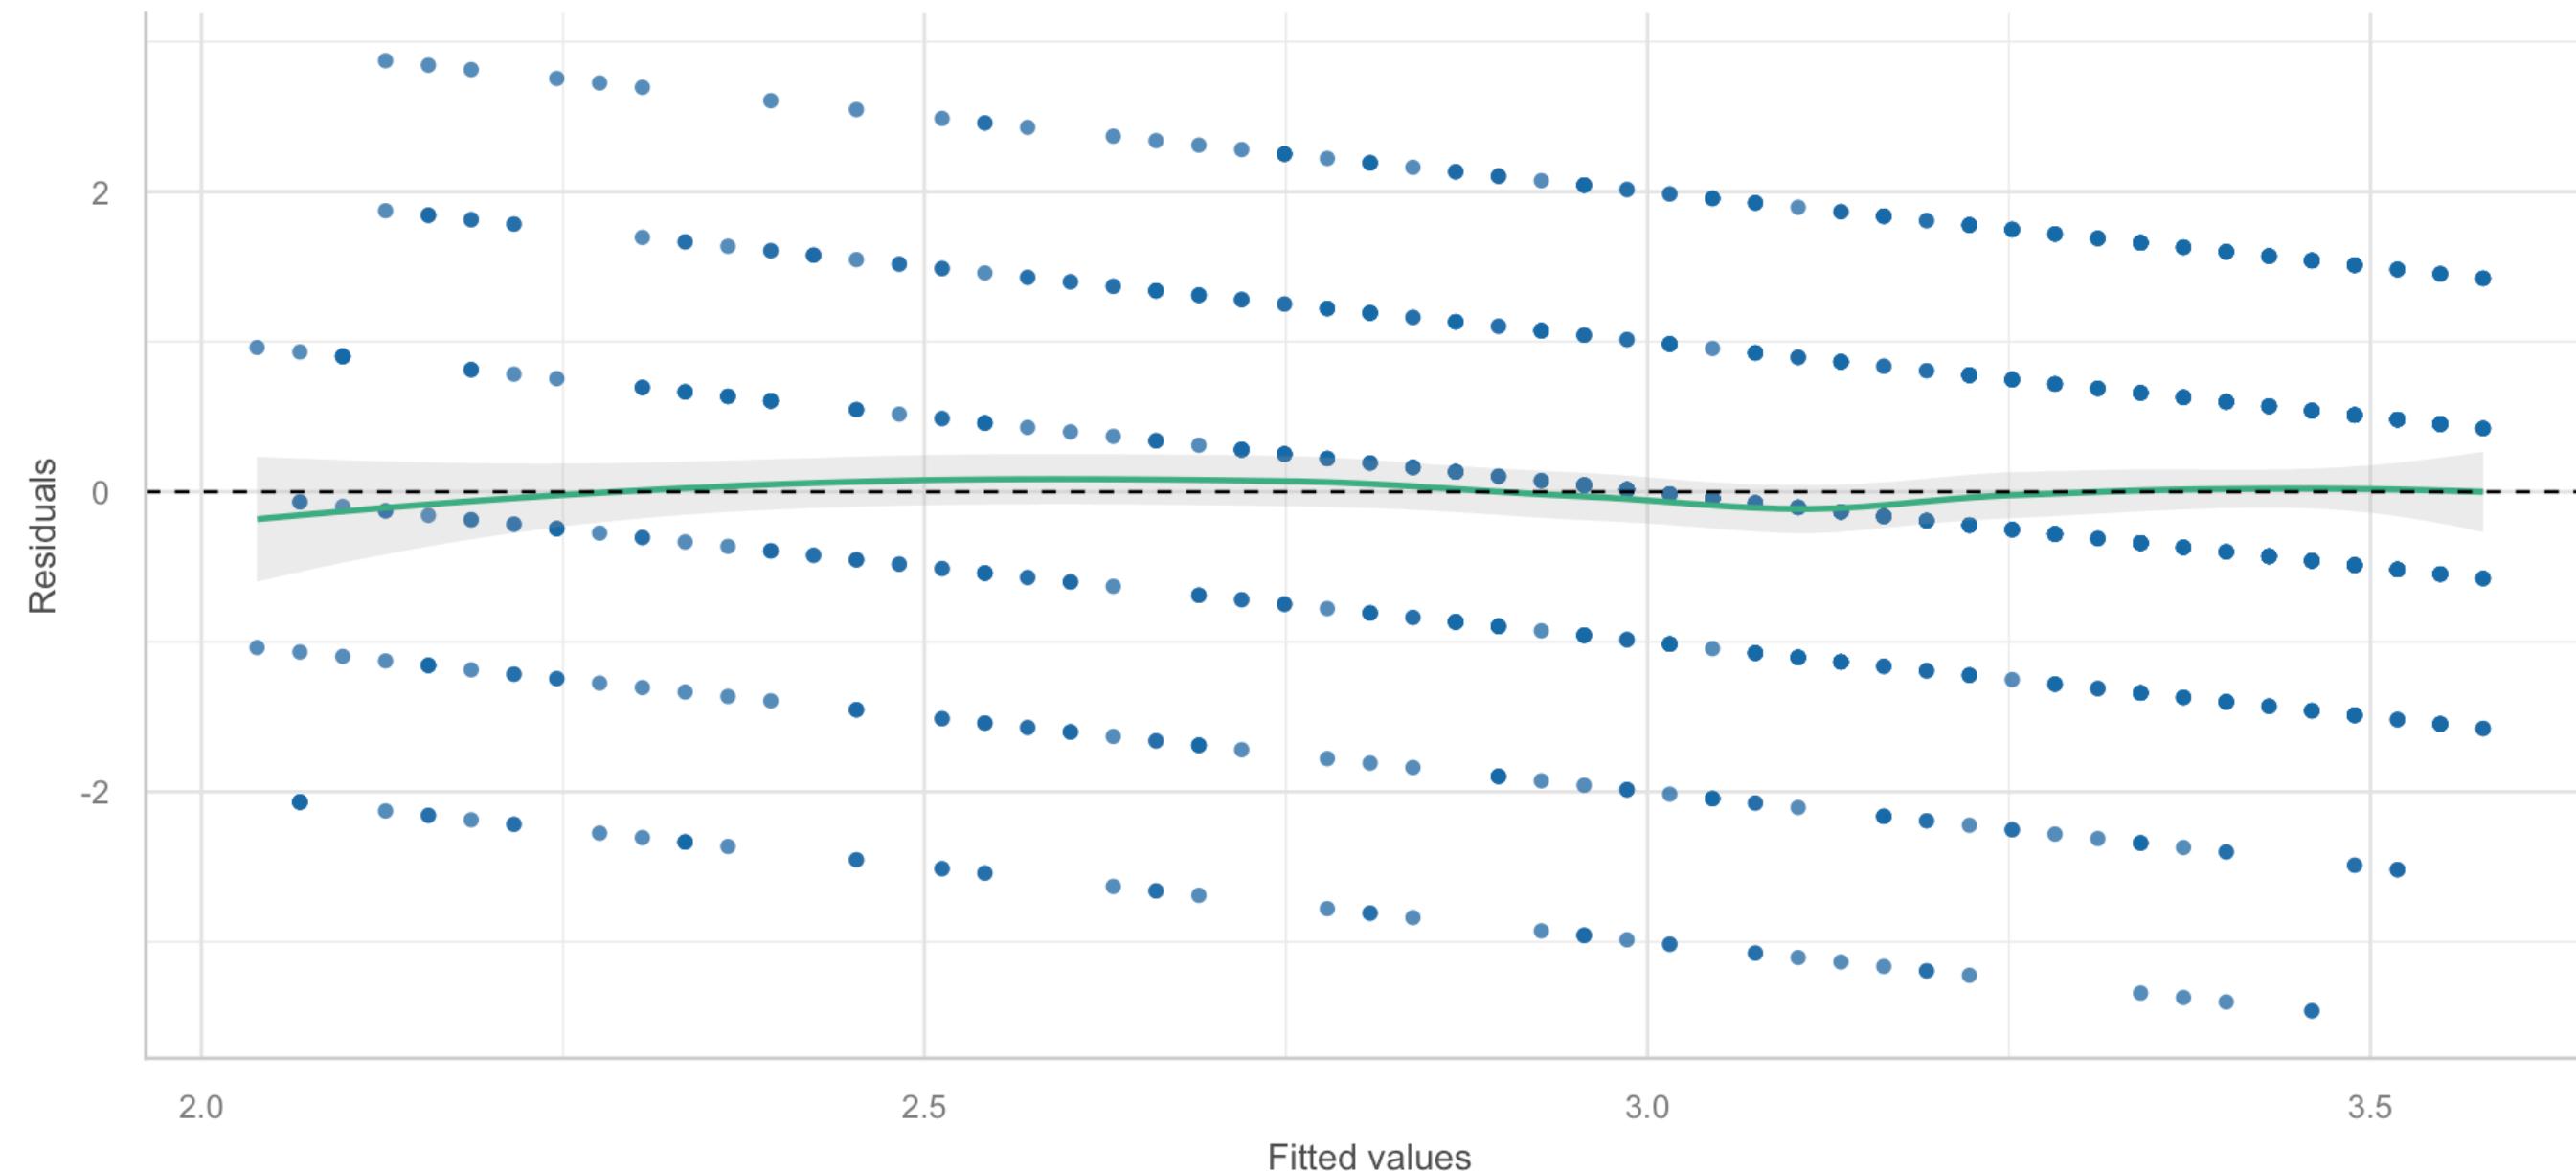
LINEARITÄT & ADDITIVITÄT

- **Annahme:** der Zusammenhang zwischen X und Y ist linear und unabhängig von Z
- **Diagnose:** Inspektion des Scatterplots bzw. des Fitted/Residual-Plots
- **Verletzung:** nichtlineare Zusammenhänge (quadratisch, exponentiell, etc.)
- **Konsequenz der Verletzung:** verzerrte Regressionskoeffizienten
- **Lösung:** Transformation von X oder Y, nichtlineares Regressionsmodell, Moderationsanalyse mit Z

LINEARITÄT

\$NCV

Linearity
Reference line should be flat and horizontal



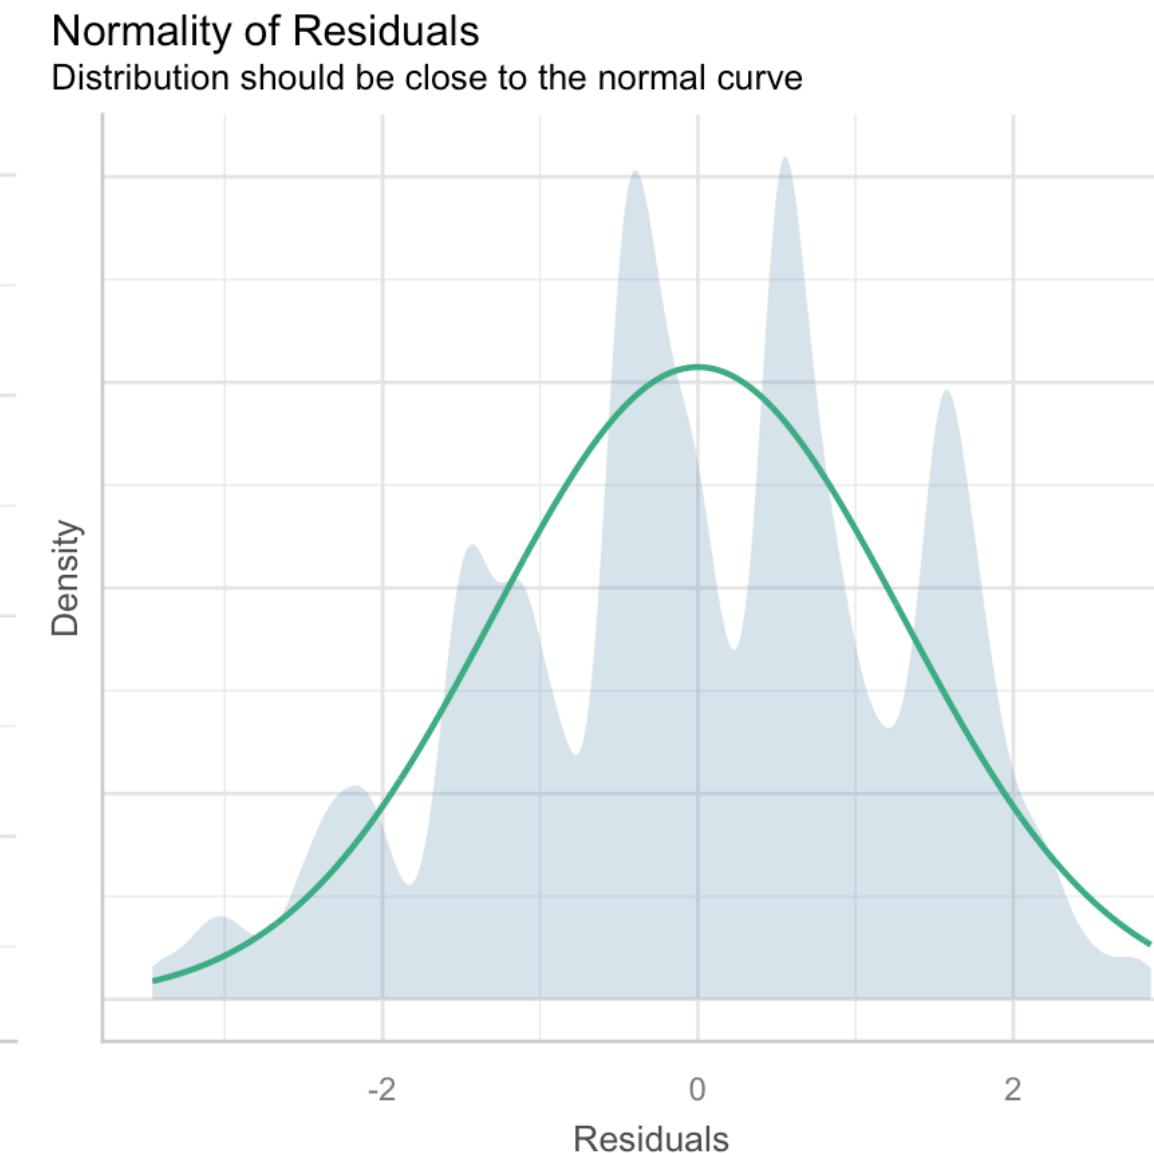
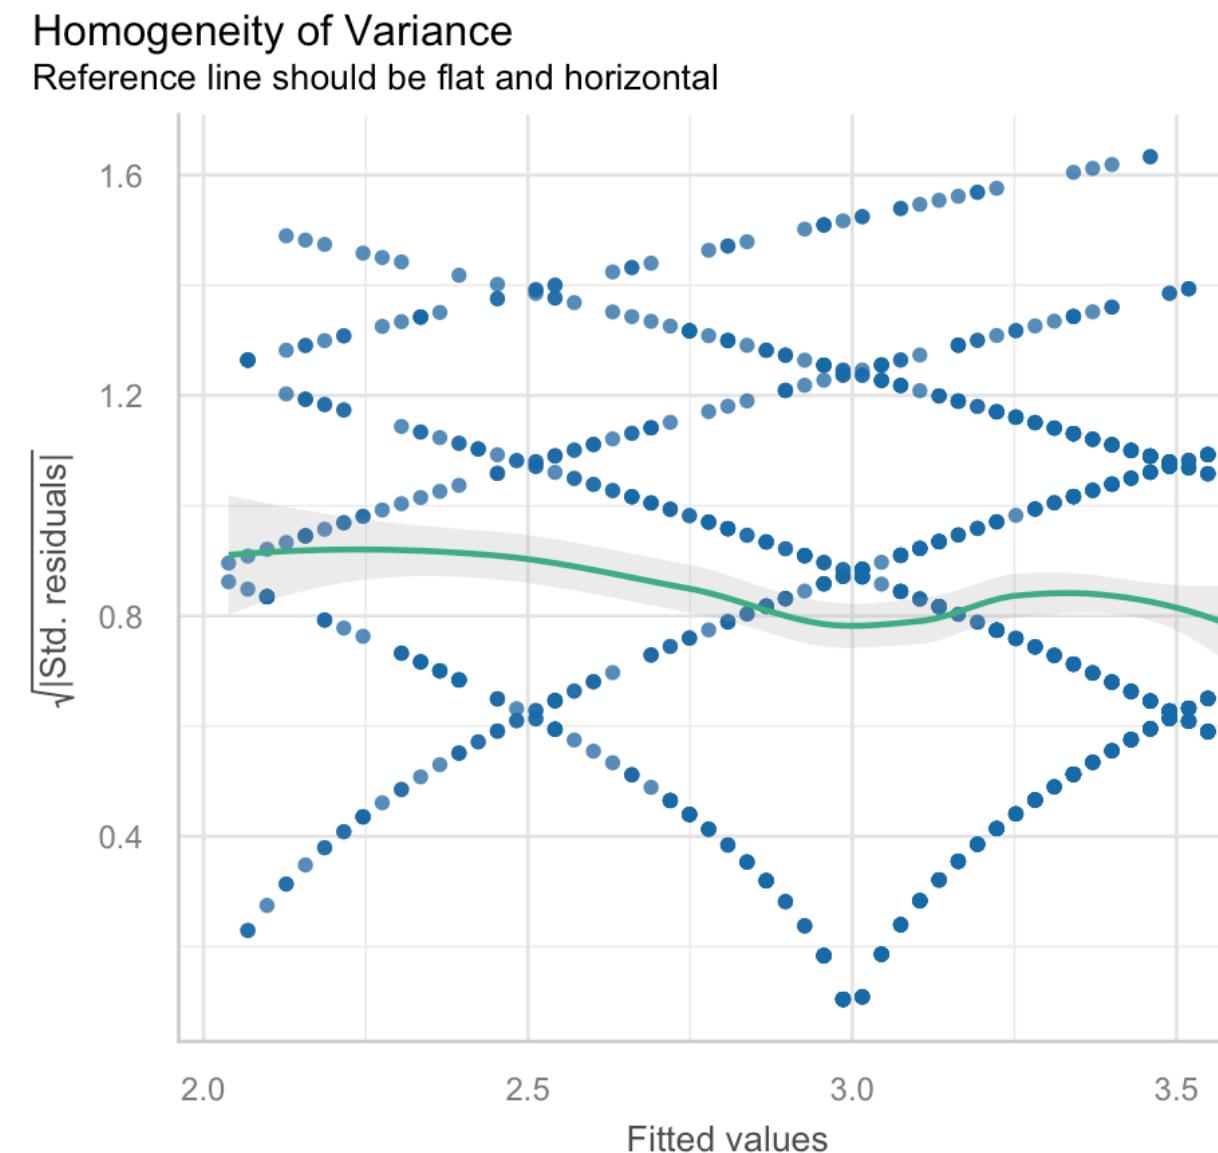
NORMALVERTEILUNG DER RESIDUEN

- **Annahme:** Residuen sind normalverteilt
- **Diagnose:** Plot der Verteilung der Residuen
- **Verletzung:** Residuen sind nicht normalverteilt
- **Konsequenz der Verletzung:** falsche Standardfehler, ineffiziente Schätzung
- **Lösung:** alternative Standardfehler, Datentransformationen, alternatives Modell

HOMOSKEDASTIZITÄT DER RESIDUEN

- **Annahme:** Residualvarianz ist für alle Werte von X gleich
- **Diagnose:** Fitted/Residual-Plots
- **Verletzung:** Residuen streuen in Abhängigkeit von X
- **Konsequenz der Verletzung:** falsche Standardfehler, ineffiziente Schätzung
- **Lösung:** alternative Standardfehler, Datentransformationen, alternatives Modell

NORMALVERTEILUNG UND HOMOSKEDASTIZITÄT DER RESIDUEN

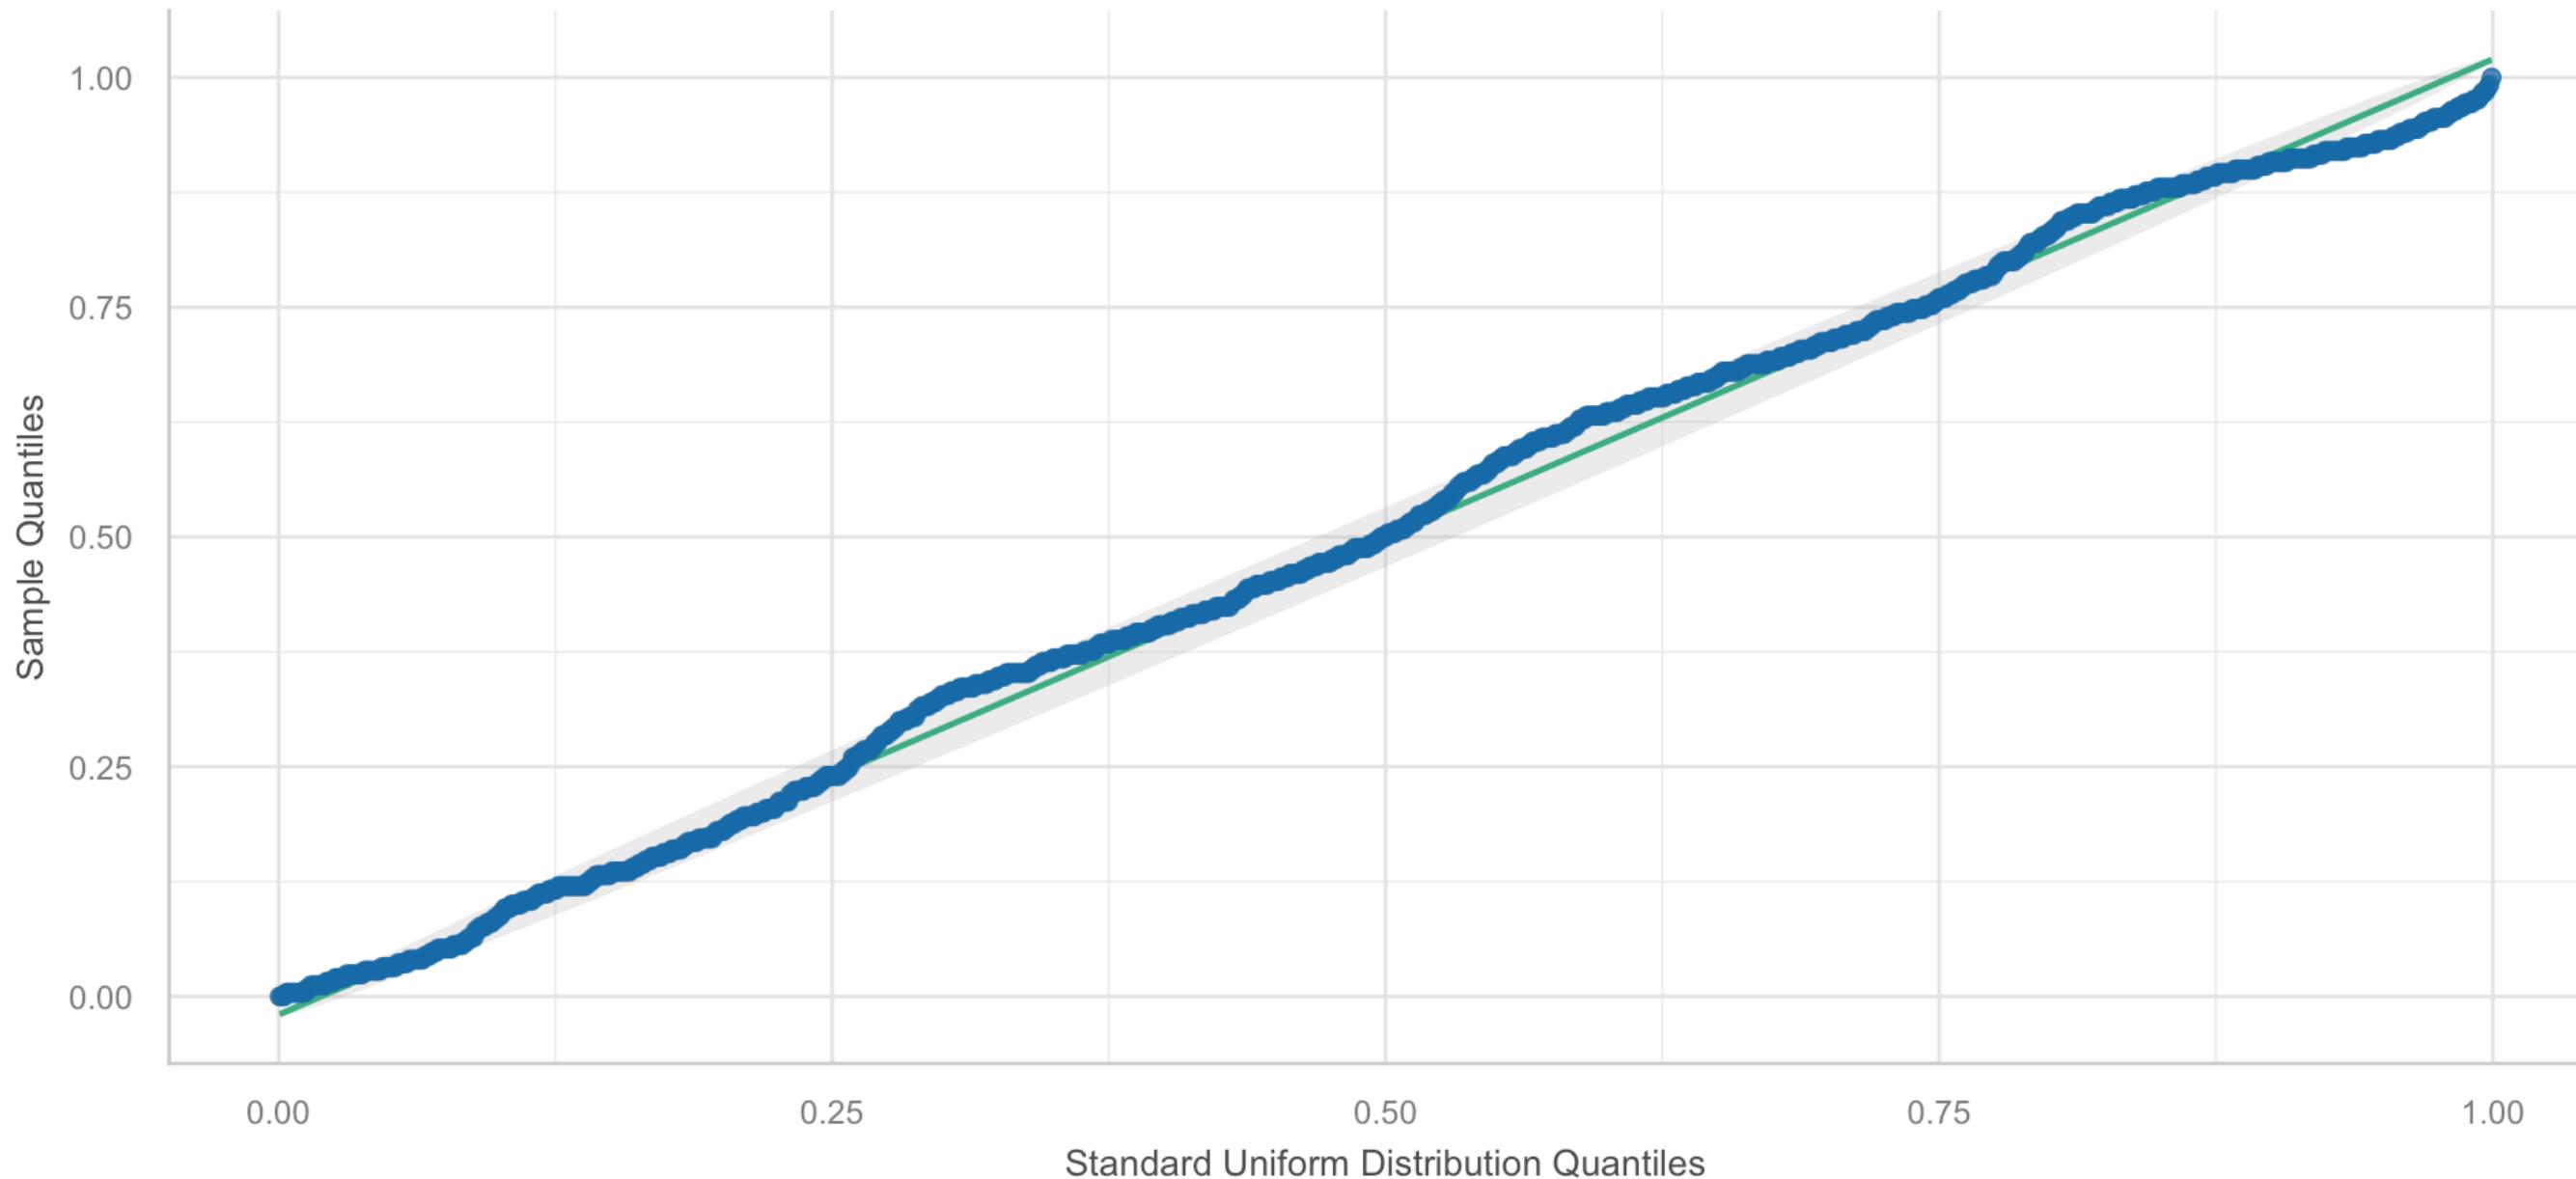


UNABHÄNGIGKEIT DER RESIDUEN

- **Annahme:** Residuen korrelieren weder miteinander noch mit den Prädiktoren
- **Diagnose:** Nachdenken über datengenerierenden Prozess, Tests auf Zusammenhänge in Residuen
- **Verletzung:** Residuen (und oft Variablen) sind geclustert (zeitlich, Stichprobe)
- **Konsequenz der Verletzung:** falsche Standardfehler, ineffiziente Schätzung
- **Lösung:** Mehrebenen-Modell, Modell mit Autokorrelationen, alternative Standardfehler

UNABHÄNGIGKEIT DER RESIDUEN

Distribution of Quantile Residuals
Dots should fall along the line

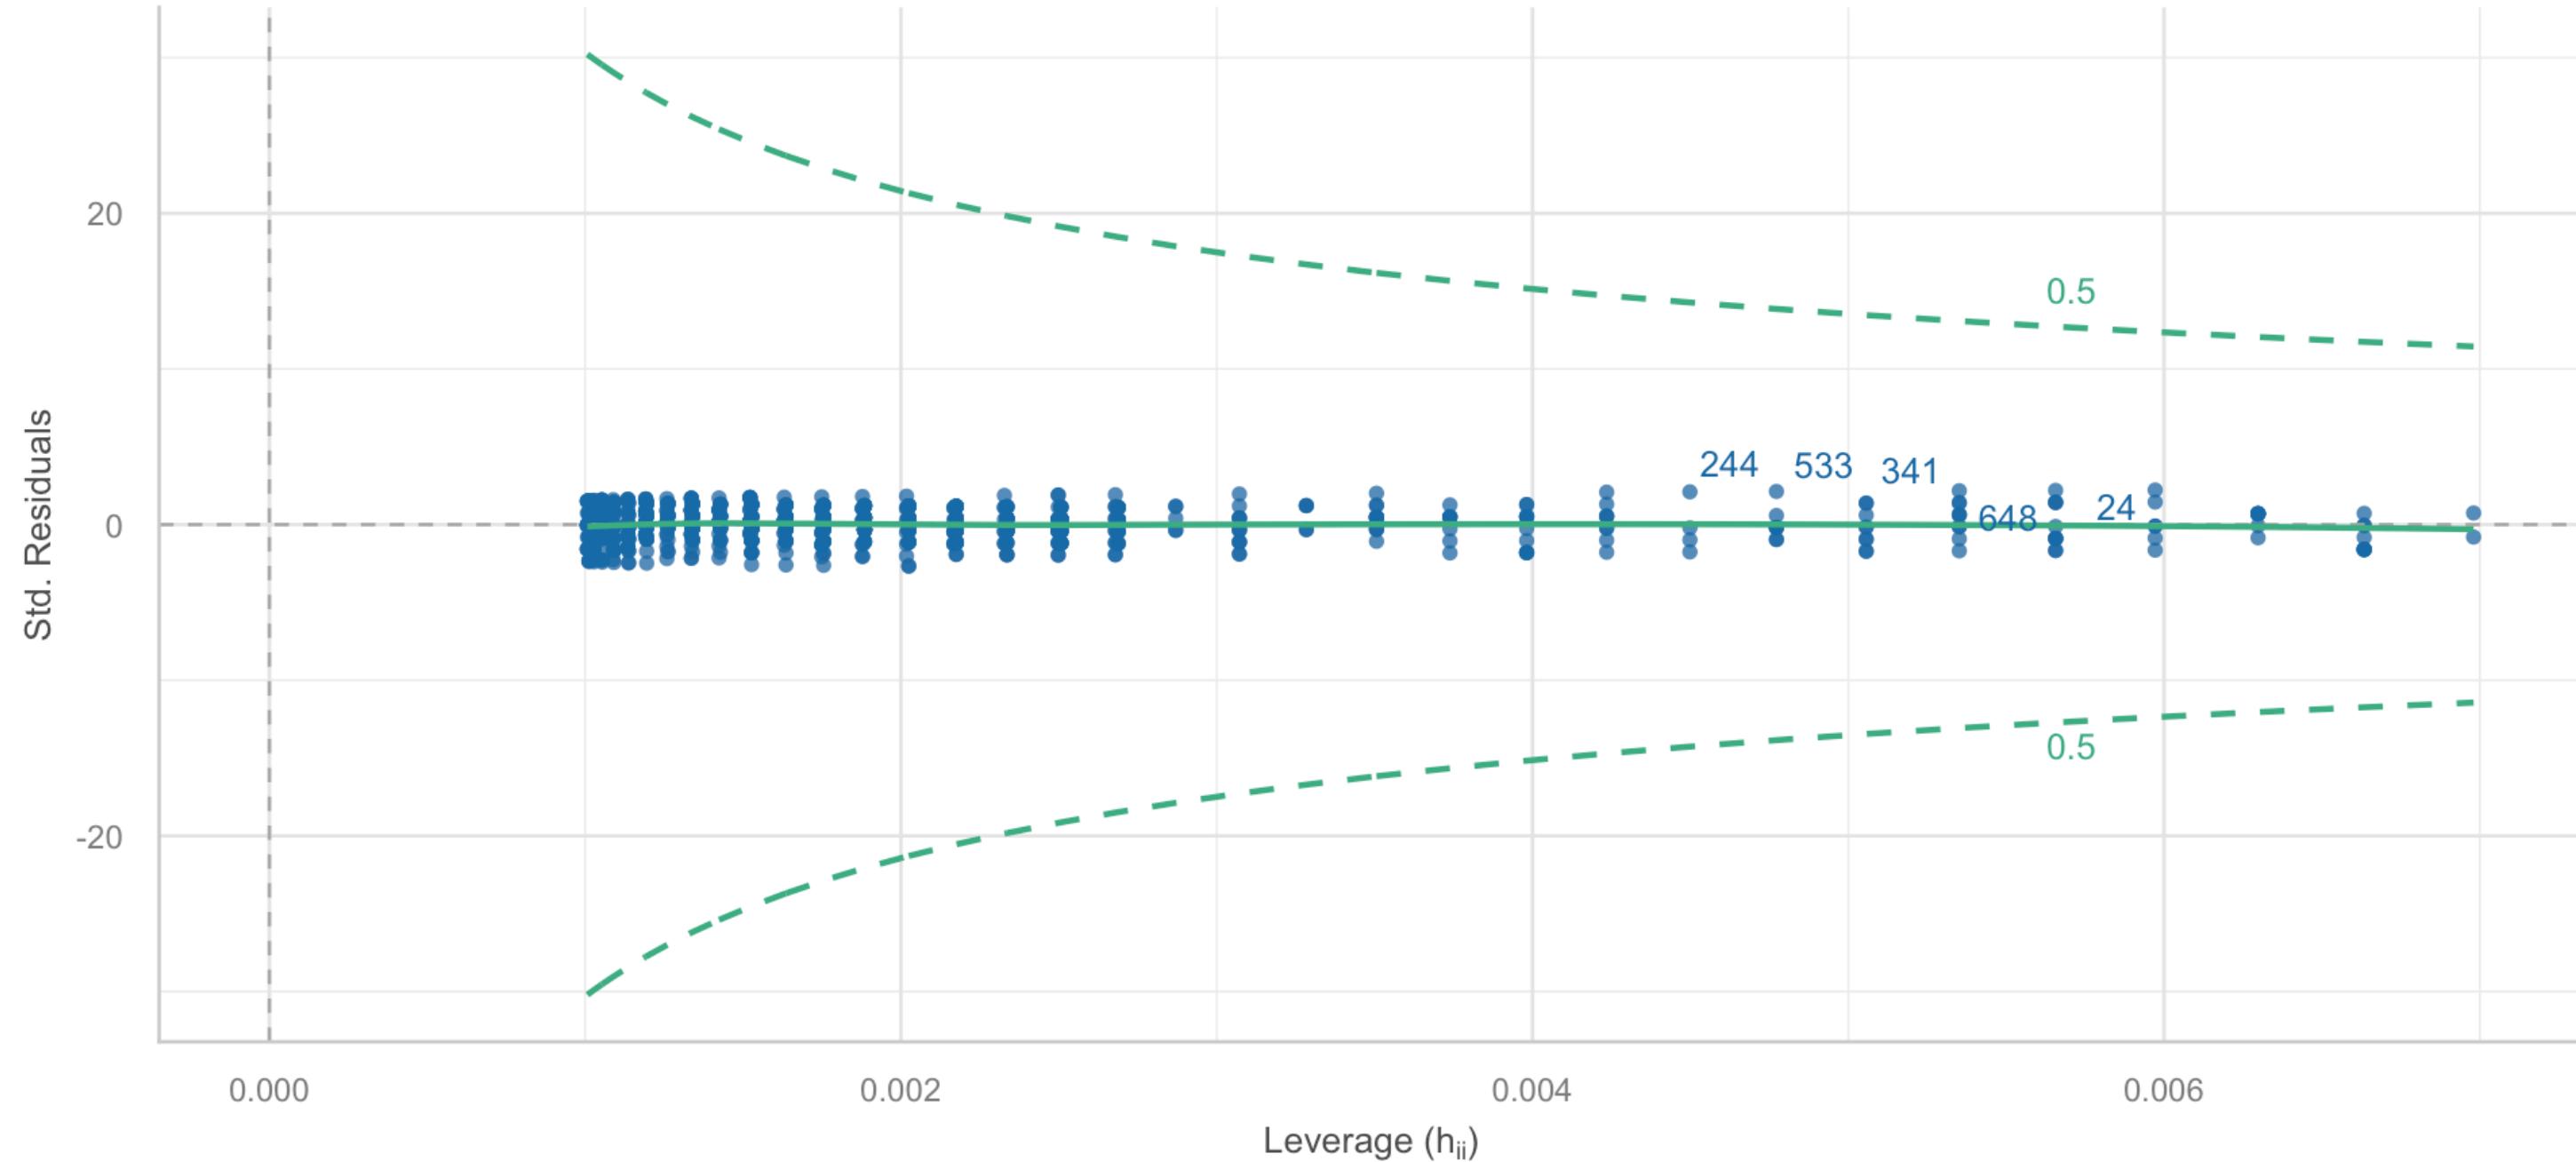


KEINE EINFLUSSREICHEN AUSREISSER

- **Annahme:** alle Fälle tragen gleich zur Schätzung bei
- **Diagnose:** Scatterplot, Leverage-Plot
- **Verletzung:** einzelne Fälle beeinflussen die Höhe der Regressionsgeraden
- **Konsequenz der Verletzung:** verzerrte Regressionskoeffizienten
- **Lösung:** Ausschluss von Ausreißern (mit klar definierten Regeln!)

KEINE EINFLUSSREICHEN AUSREISSER

Influential Observations
Points should be inside the contour lines



VERLETZUNG DER STATISTISCHEN MODELLANNAHMEN - UND NUN?

- Keine Panik! Einige Modellannahmen sind praktisch immer verletzt (z.B. Normalverteilung der Residuen)
- Viele Annahmen beziehen sich auf die Residuen, nicht auf X oder Y
- Wichtig ist, einschätzen zu können, welche Konsequenzen eine Verletzung der Modellannahme haben kann
 - verzerrte Schätzer (zu hoch, zu niedrig)
 - falsche Standardfehler (α - und β -Fehler)
- Vorsichtig formulieren, Robustheit der Ergebnisse prüfen
- Bei stärkeren Verletzungen Korrekturen möglich (robuste Schätzer, robuste Standardfehler; nicht in dieser Vorlesung)
- Problematischer sind Verletzungen der kausalen Annahmen (\rightarrow eigene Sitzung)

Fragen?

Transformation von Variablen im Regressionsmodell

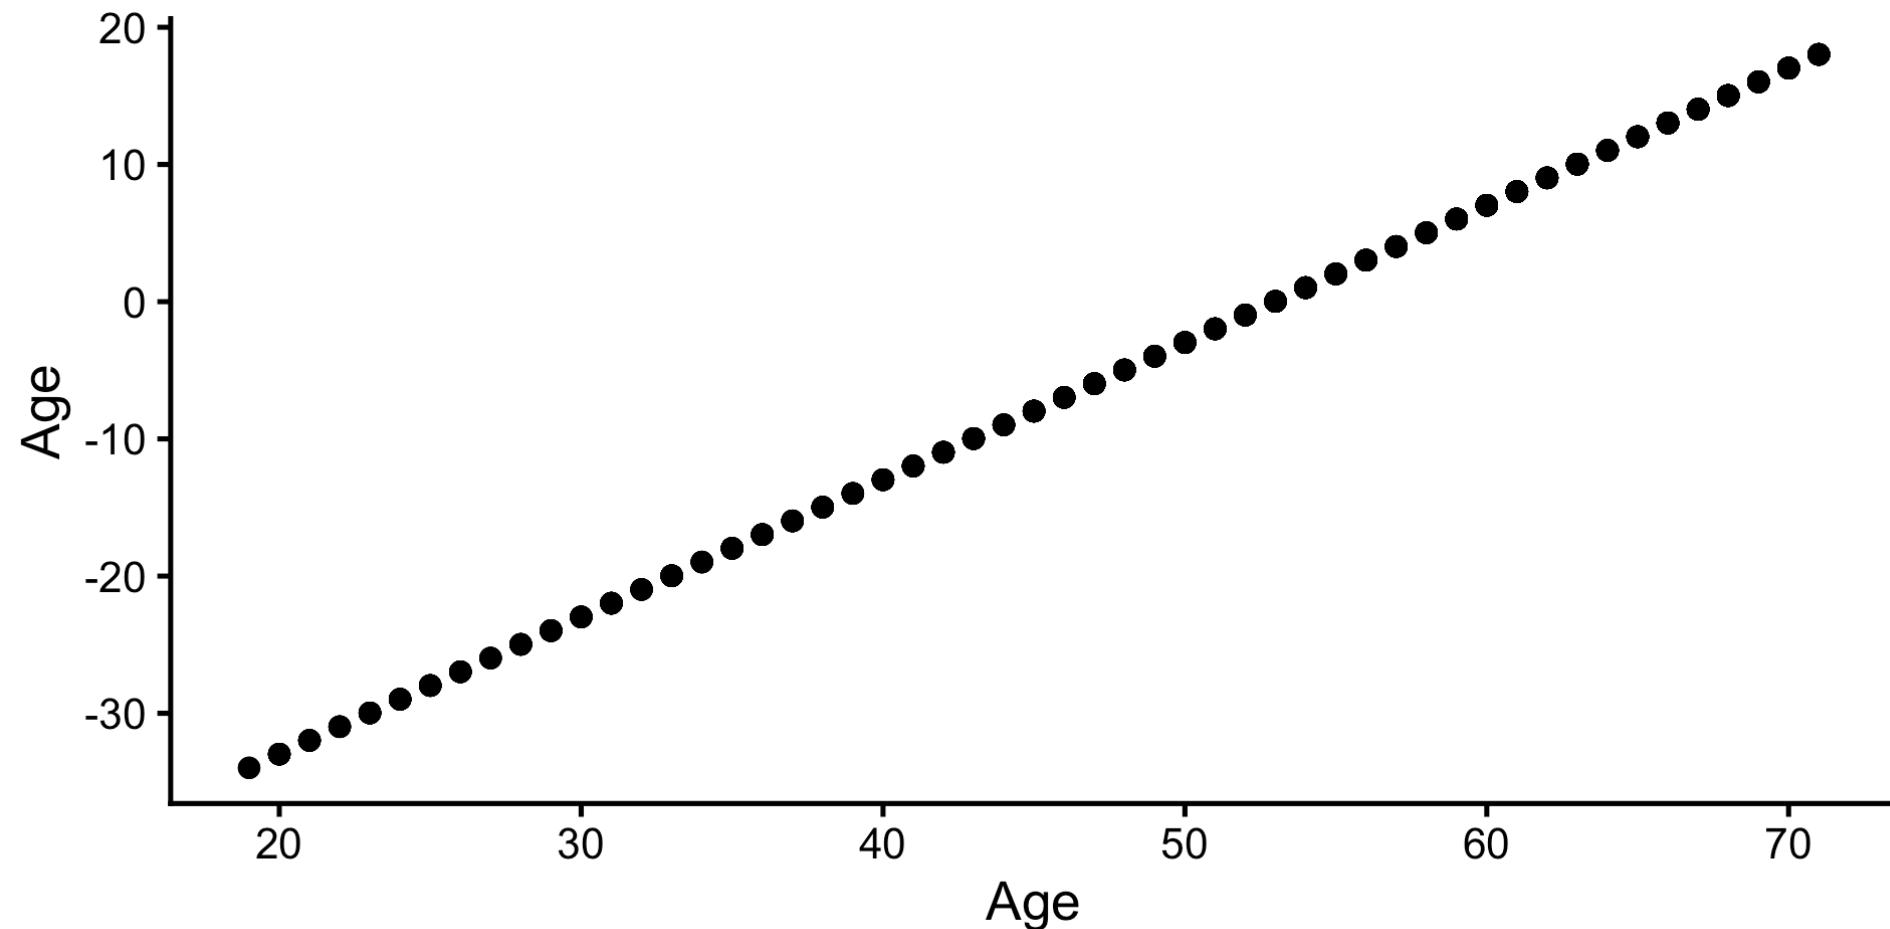
TRANSFORMATION VON VARIABLEN IM REGRESSIONSMODELL

- Addieren & Subtrahieren einer Konstante: Ändert die Bedeutung der Konstante (Intercept) (Wert, wenn alle Prädiktoren gleich 0 sind)
- Multiplizieren & Dividieren mit einer Konstante: Ändert die Skala der Regressionskoeffizienten
- Nicht-lineare Transformationen eines Prädiktors (z.B. Quadrieren, Logarithmus): Ändert die funktionale Form der Beziehung
- (Multiplikation mehrerer Prädiktoren: Moderation & Interaktion) [→ eigene Einheit]

ADDIEREN & SUBTRAHIEREN EINER KONSTANTE

- Zentrieren von quasi-metrischen *Prädiktoren* um ihren Mittelwert

```
1 d <- d |>  
2 mutate(Age_c = Age - mean(Age))
```



ADDIEREN & SUBTRAHIEREN EINER KONSTANTE

Original

Parameter	Coefficient	95% CI	t(991)	p	Fit
(Intercept)	1.48	(1.16, 1.79)	9.12	<.001	
Age	0.03	(0.02, 0.04)	10.02	<.001	
R2					0.09

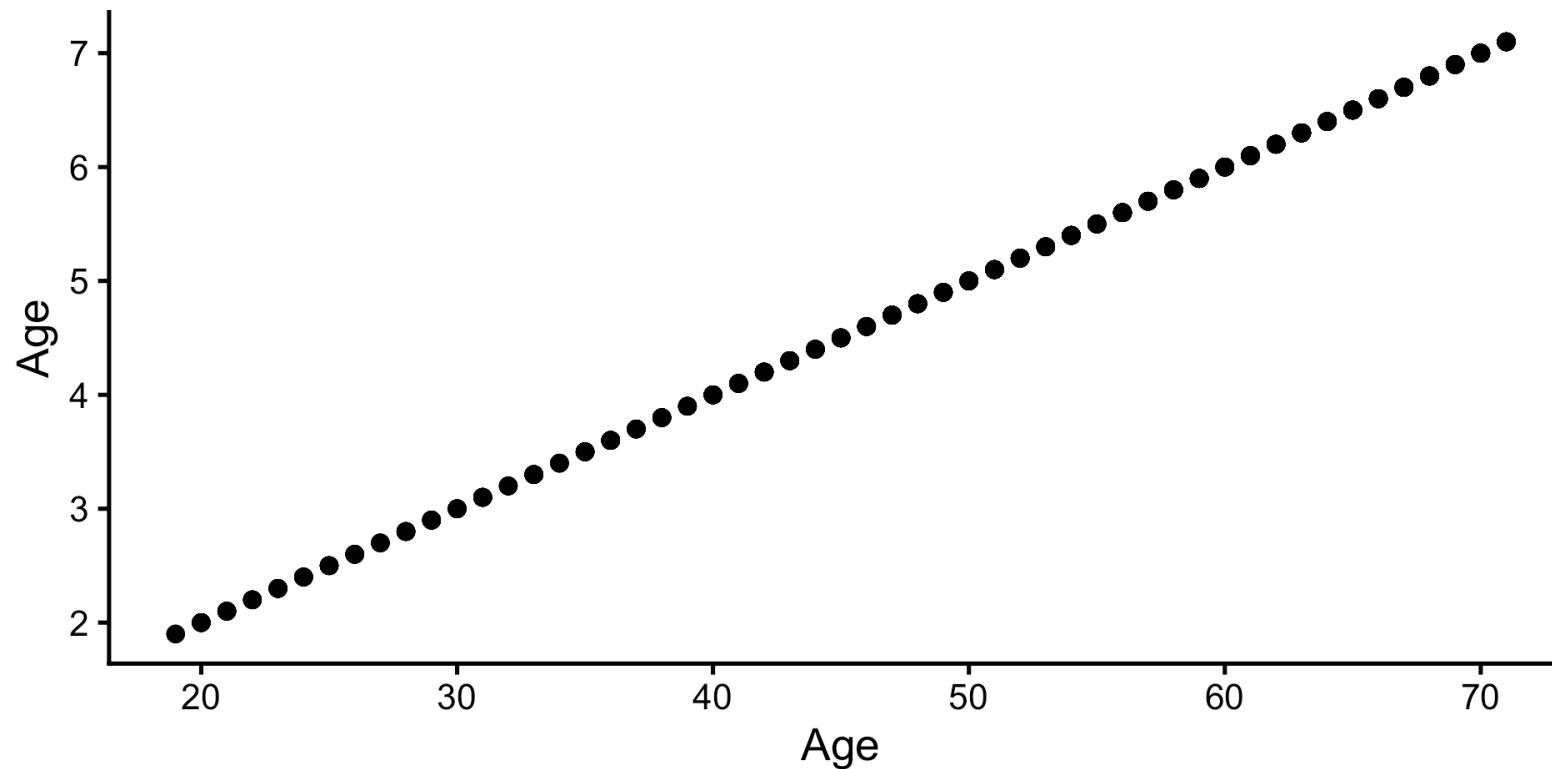
Zentriert

Parameter	Coefficient	95% CI	t(991)	p	Fit
(Intercept)	3.04	(2.96, 3.13)	73.88	<.001	
Age c	0.03	(0.02, 0.04)	10.02	<.001	
R2					0.09

MULTIPLIZIEREN & DIVIDIEREN MIT EINER KONST.

- Skala verändern:
- Teilen des Alters durch 10 → Vergleich zu bzw. Veränderung um 10 Jahren

```
1 d <- d |>  
2   mutate(Age_10 = Age / 10)
```



MULTIPLIZIEREN & DIVIDIEREN MIT EINER KONST.

Original

Parameter	Coefficient	95% CI	t(991)	p	Fit
(Intercept)	1.48	(1.16, 1.79)	9.12	<.001	
Age	0.03	(0.02, 0.04)	10.02	<.001	
R2			0.09		

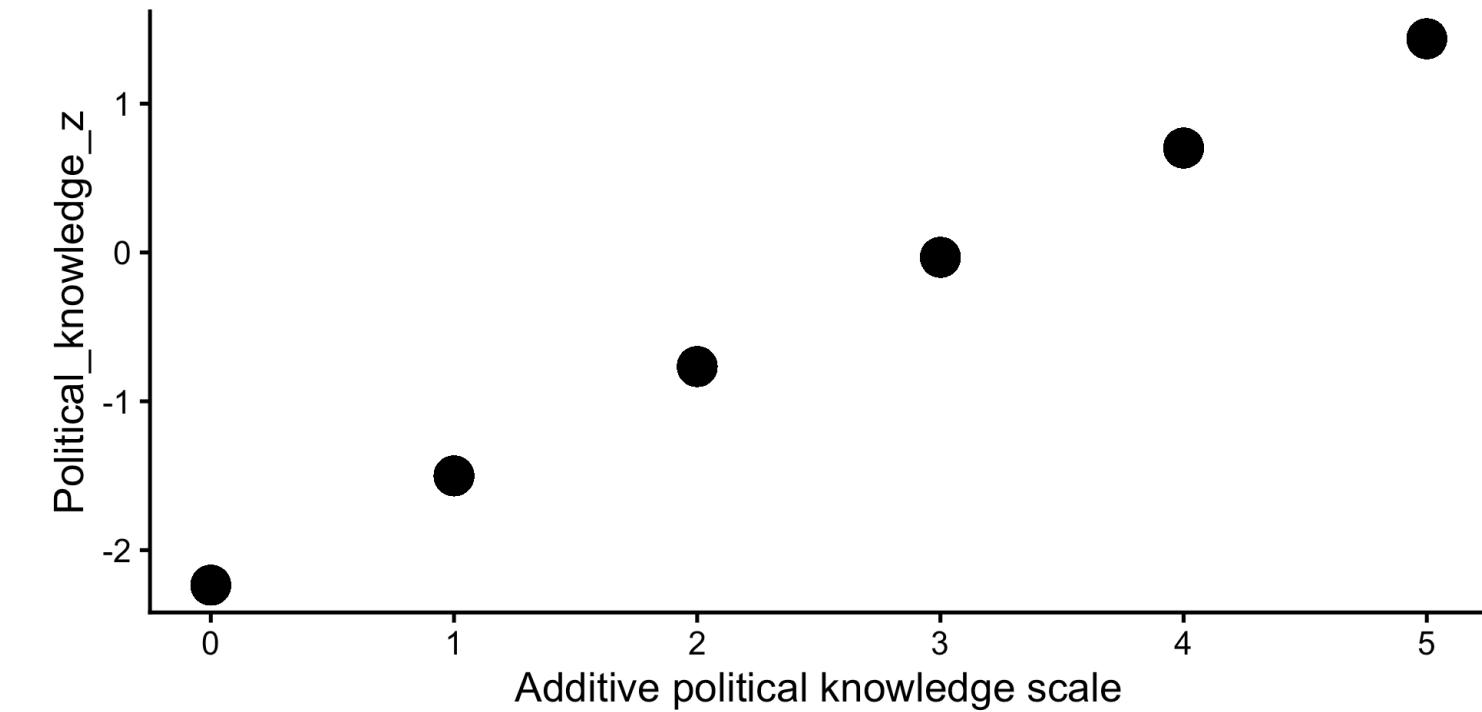
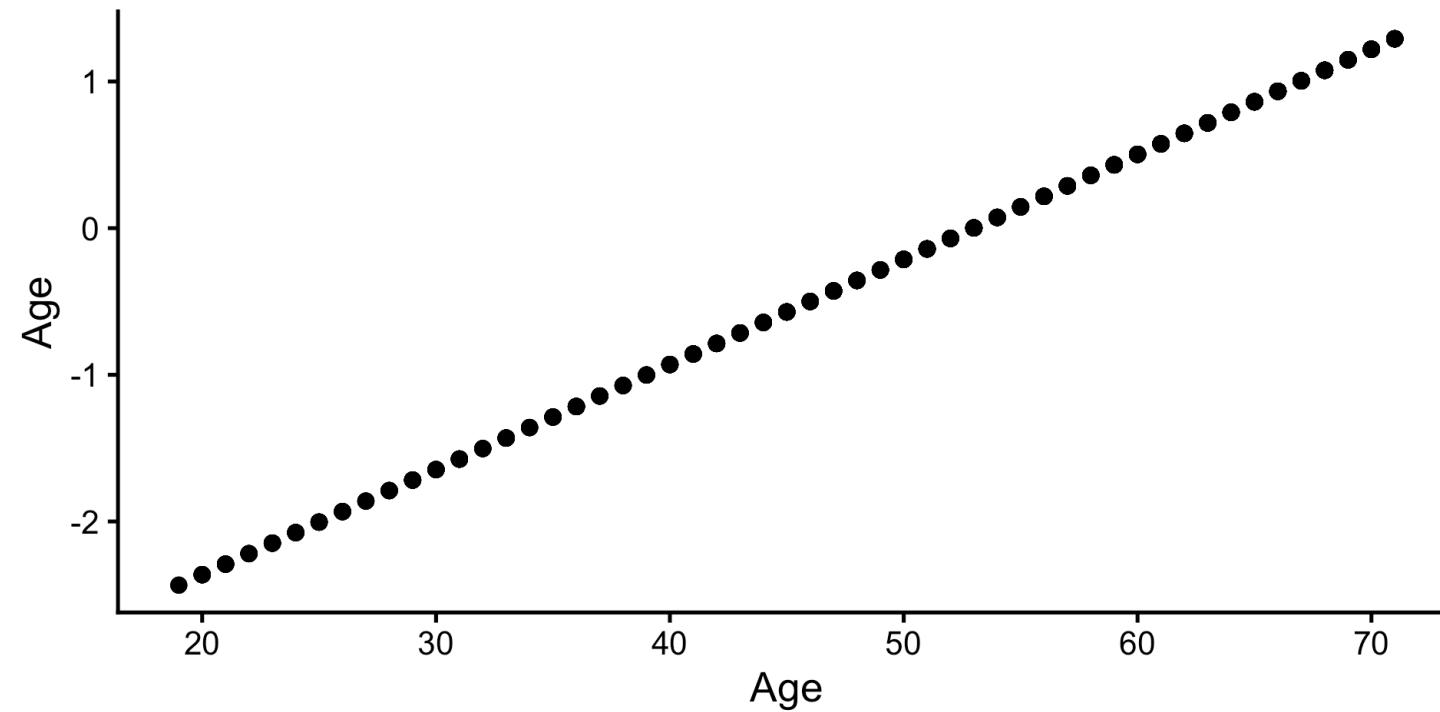
Transformiert

Parameter	Coefficient	95% CI	t(991)	p	Fit
(Intercept)	1.48	(1.16, 1.79)	9.12	<.001	
Age 10	0.30	(0.24, 0.35)	10.02	<.001	
R2			0.09		

MULTIPLIZIEREN & DIVIDIEREN MIT EINER KONST.

- Z-Standardisieren: Zentrieren *aller quasi-metrischer Variablen* um Mittelwert und Teilen durch eine Standardabweichung → Standardisierte Koeffizienten

```
1 d <- d |>
2   mutate(
3     Age_z = (Age - mean(Age)) / sd(Age),
4     Political_knowledge_z = scale(Political_knowledge, center = TRUE, scale = TRUE)
5   )
```



MULTIPLIZIEREN & DIVIDIEREN MIT EINER KONST.

Original

Parameter	Coefficient	95% CI	t(991)	p	Fit
(Intercept)	1.48	(1.16, 1.79)	9.12	<.001	
Age	0.03	(0.02, 0.04)	10.02	<.001	
R2					0.09

Z-Standardisiert

Parameter	Coefficient	95% CI	t(991)	p	Fit
(Intercept)	0.00	(-0.06, 0.06)	0.00	>.999	
Age z	0.30	(0.24, 0.36)	10.02	<.001	
R2					0.09

MULTIPLIZIEREN & DIVIDIEREN MIT EINER KONST.

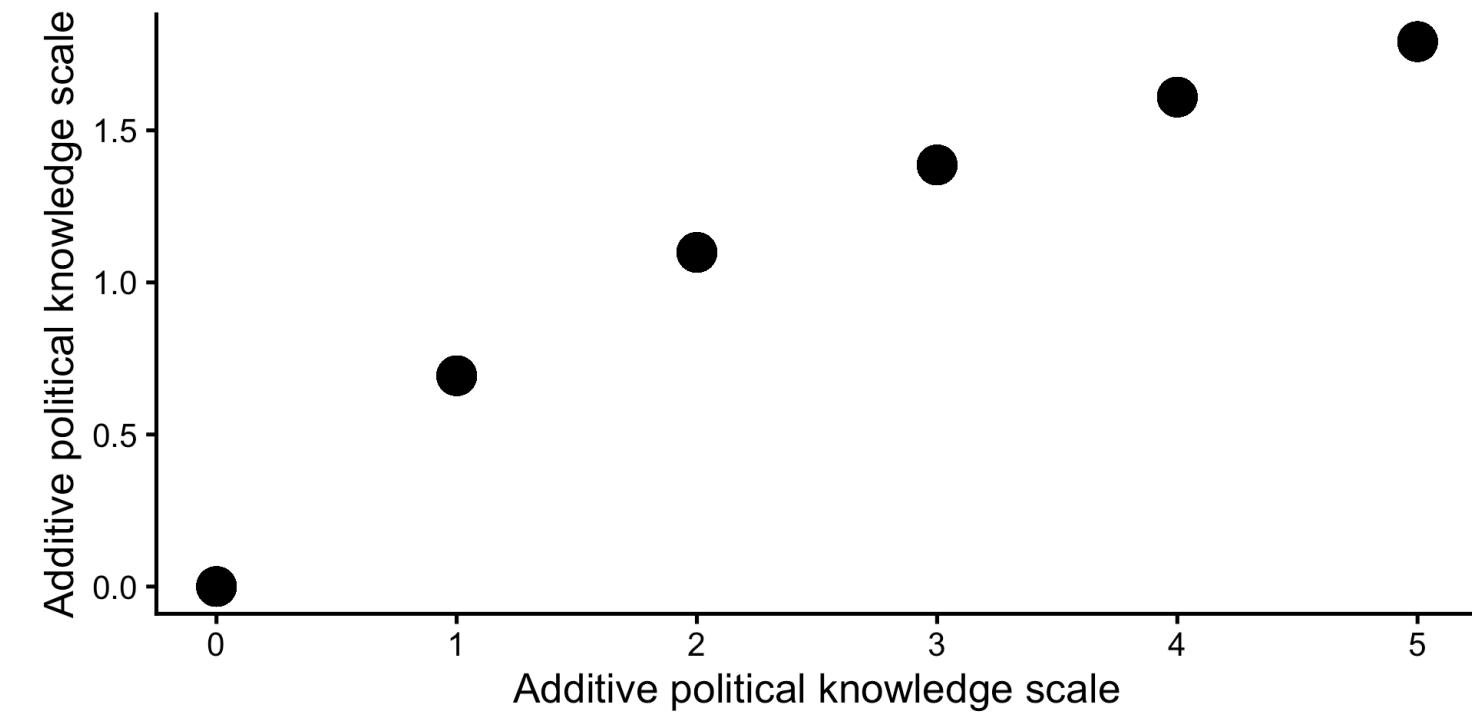
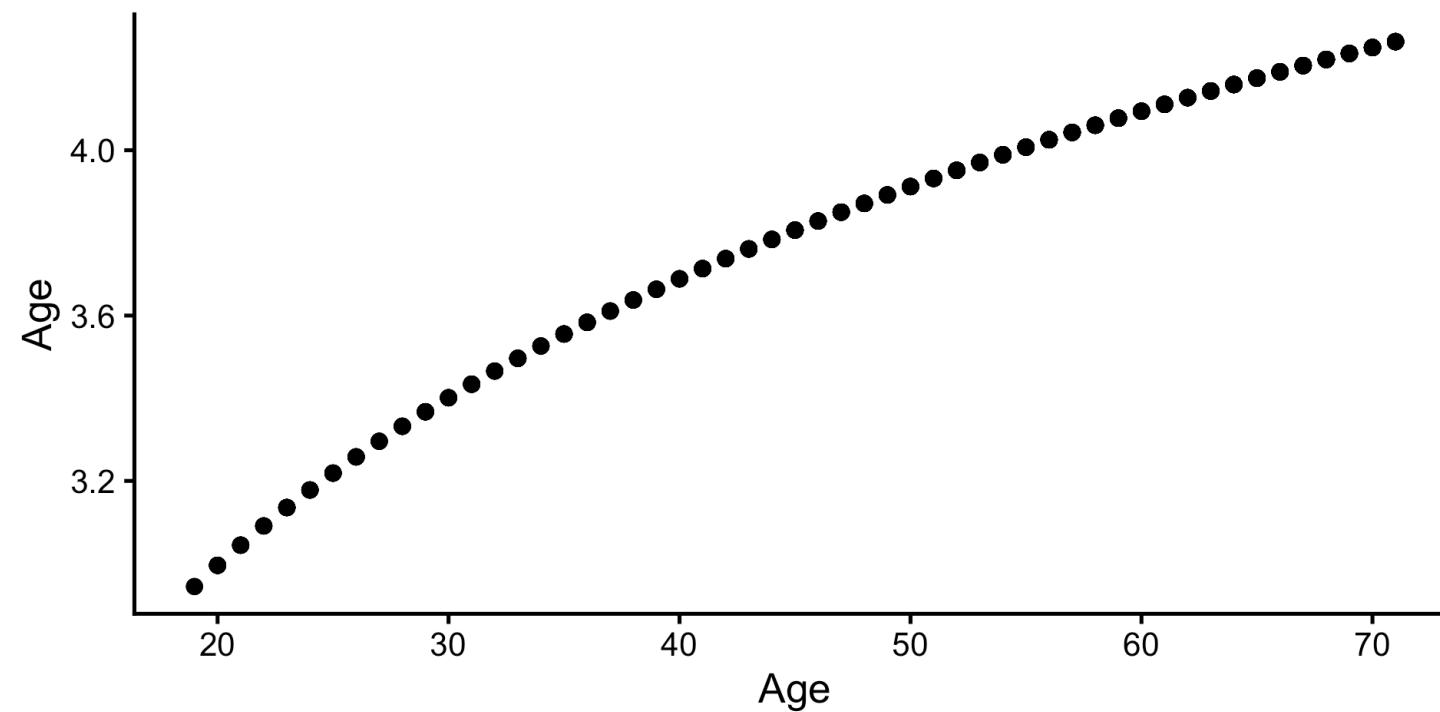
Parameter	Coefficient	95% CI	t(991)	p	Std. Coef.	Std. Coef. 95% CI	Fit
(Intercept)	1.48	(1.16, 1.79)	9.12	< .001	0.00	(-0.06, 0.06)	
Age	0.03	(0.02, 0.04)	10.02	< .001	0.30	(0.24, 0.36)	
R2							0.09

- Die Funktion `report_table()` schätzt das Modell im Hintergrund mit standardisierten quasi-metrischen Variablen neu, um die standardisierten Koeffizienten zu erhalten.

NICHT-LINEARE TRANSFORMATIONEN

- z.B. Logarithmierung: Vergleich bzw. Veränderung in %

```
1 d <- d |>
2 mutate(
3   Age_log = log(Age),
4   Political_knowledge_log = log1p(Political_knowledge)
5 )
```



NICHT-LINEARE TRANSFORMATIONEN

Original

Parameter	Coefficient	95% CI	t(991)	p	Fit
(Intercept)	1.48	(1.16, 1.79)	9.12	<.001	
Age	0.03	(0.02, 0.04)	10.02	<.001	
R2					0.09

Log-transformierte Variablen

Parameter	Coefficient	95% CI	t(991)	p	Fit
(Intercept)	-0.38	(-0.70, -0.06)	-2.31	0.021	
Age log	0.43	(0.35, 0.51)	10.41	<.001	
R2					0.1

- log-log: Eine um 1% ältere Person beantwortet 0.43% mehr Fragen korrekt als eine um 1% jüngere Person (Oder ganz genau: liegt auf der Variable “Richtig beantwortete Fragen + 1” um 0.31% höher).
- Daumenregel für 100%: Eine doppelt so alte Person beantwortet ca. 43% mehr Fragen korrekt.
- Genauer gerechnet: Eine doppelt so alte Person beantwortet ca. $2^{0.43} - 1 = 35\%$ mehr Fragen korrekt.

Fragen?

Zusammenfassung

ZUSAMMENFASSUNG

- Mit der linearen Regression und ihren Varianten können wir sehr viele Fragen beantworten.
- Grundgedanke immer: Wir legen Linien durch die Daten; die Steigung der Linien quantifiziert den Zusammenhang.
- Abschnitt *Grundlagen der Regression* ist Voraussetzung für mindestens 2/3 der folgenden Inhalte.
- Abschnitte *Annahmen und ihre Überprüfung* und *Transformation von Variablen* sind nützlich, aber nicht essentiell.

Übungsaufgaben

Fragen?

Nächste Einheit

Multiple lineare Regression

Danke – bis zur nächsten Sitzung.

Marko Bachl

marko.bachl@fu-berlin.de

LITERATUR

- Van Erkel, P. F. A. (2020). „*Replication data for “Why don’t we learn from social media?”*“ (Version V2) [Dataset]. Harvard Dataverse. <https://doi.org/10.7910/DVN/D0COF1>
- Van Erkel, P. F. A., & Van Aelst, P. (2021). Why don’t we learn from social media? Studying effects of and mechanisms behind social media news use on general surveillance political knowledge. *Political Communication*, 38(4), 407–425. <https://doi.org/ghk94s>