


Wiederholung Lineare Regression



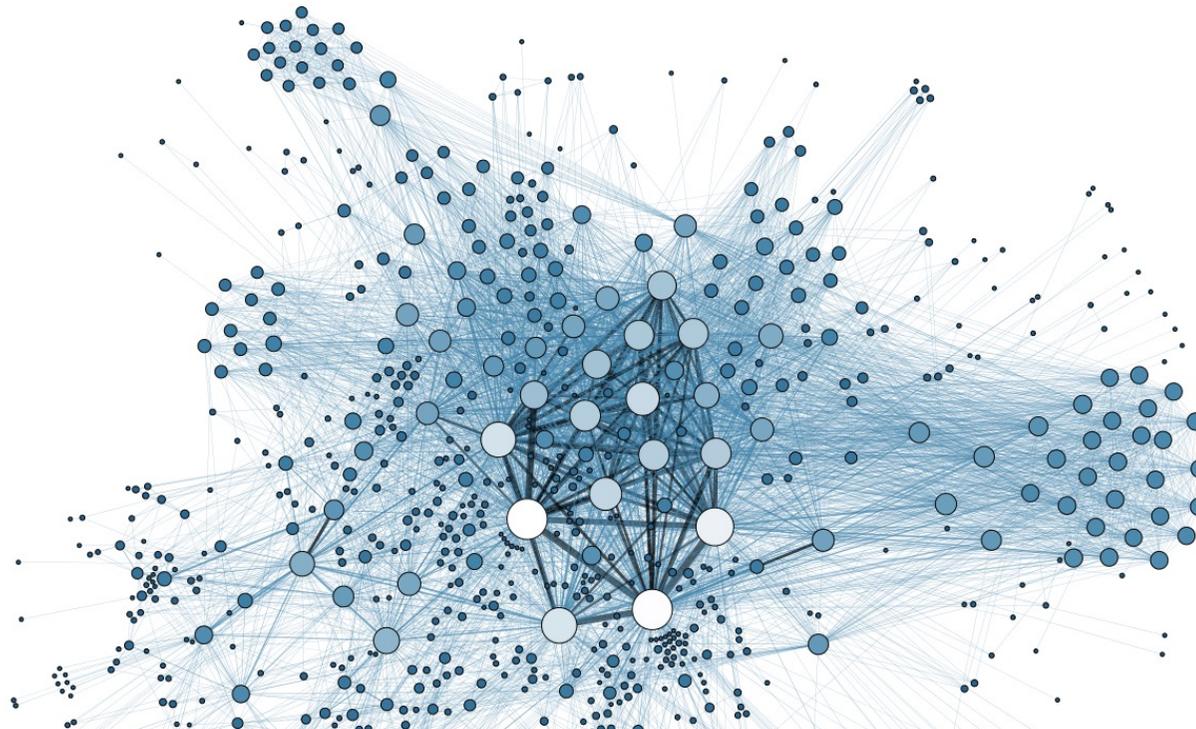
We are happy to share our materials openly:

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.

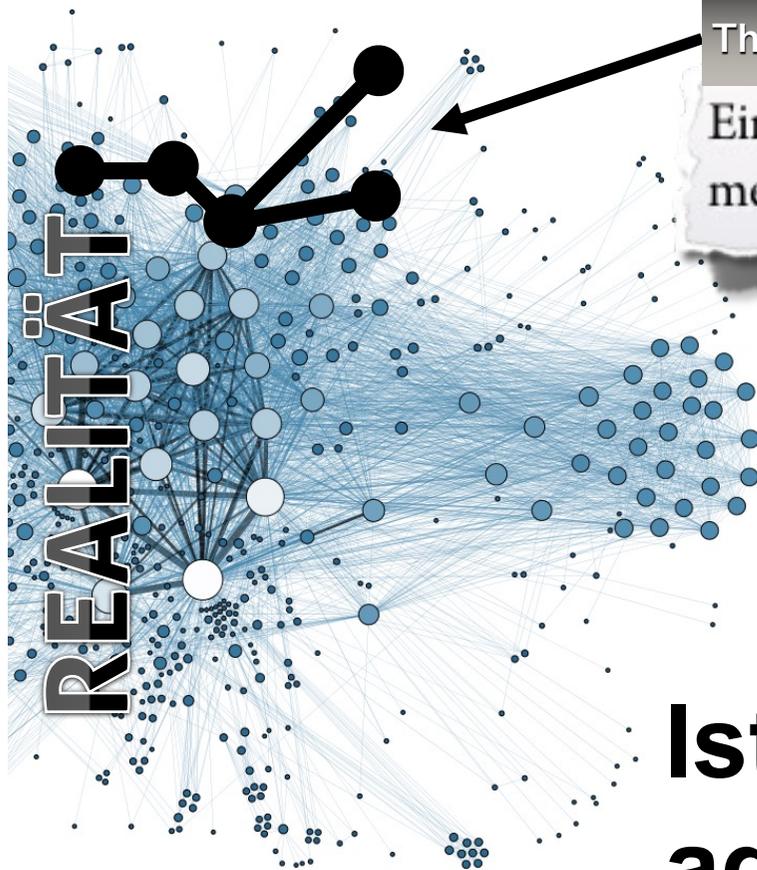
Warum Methodenlehre in der Psychologie?



Wie können wir zu Erkenntnissen über die Welt gelangen? u.a. durch Methodenlehre!



Wie können wir zu Erkenntnissen über die Welt gelangen?

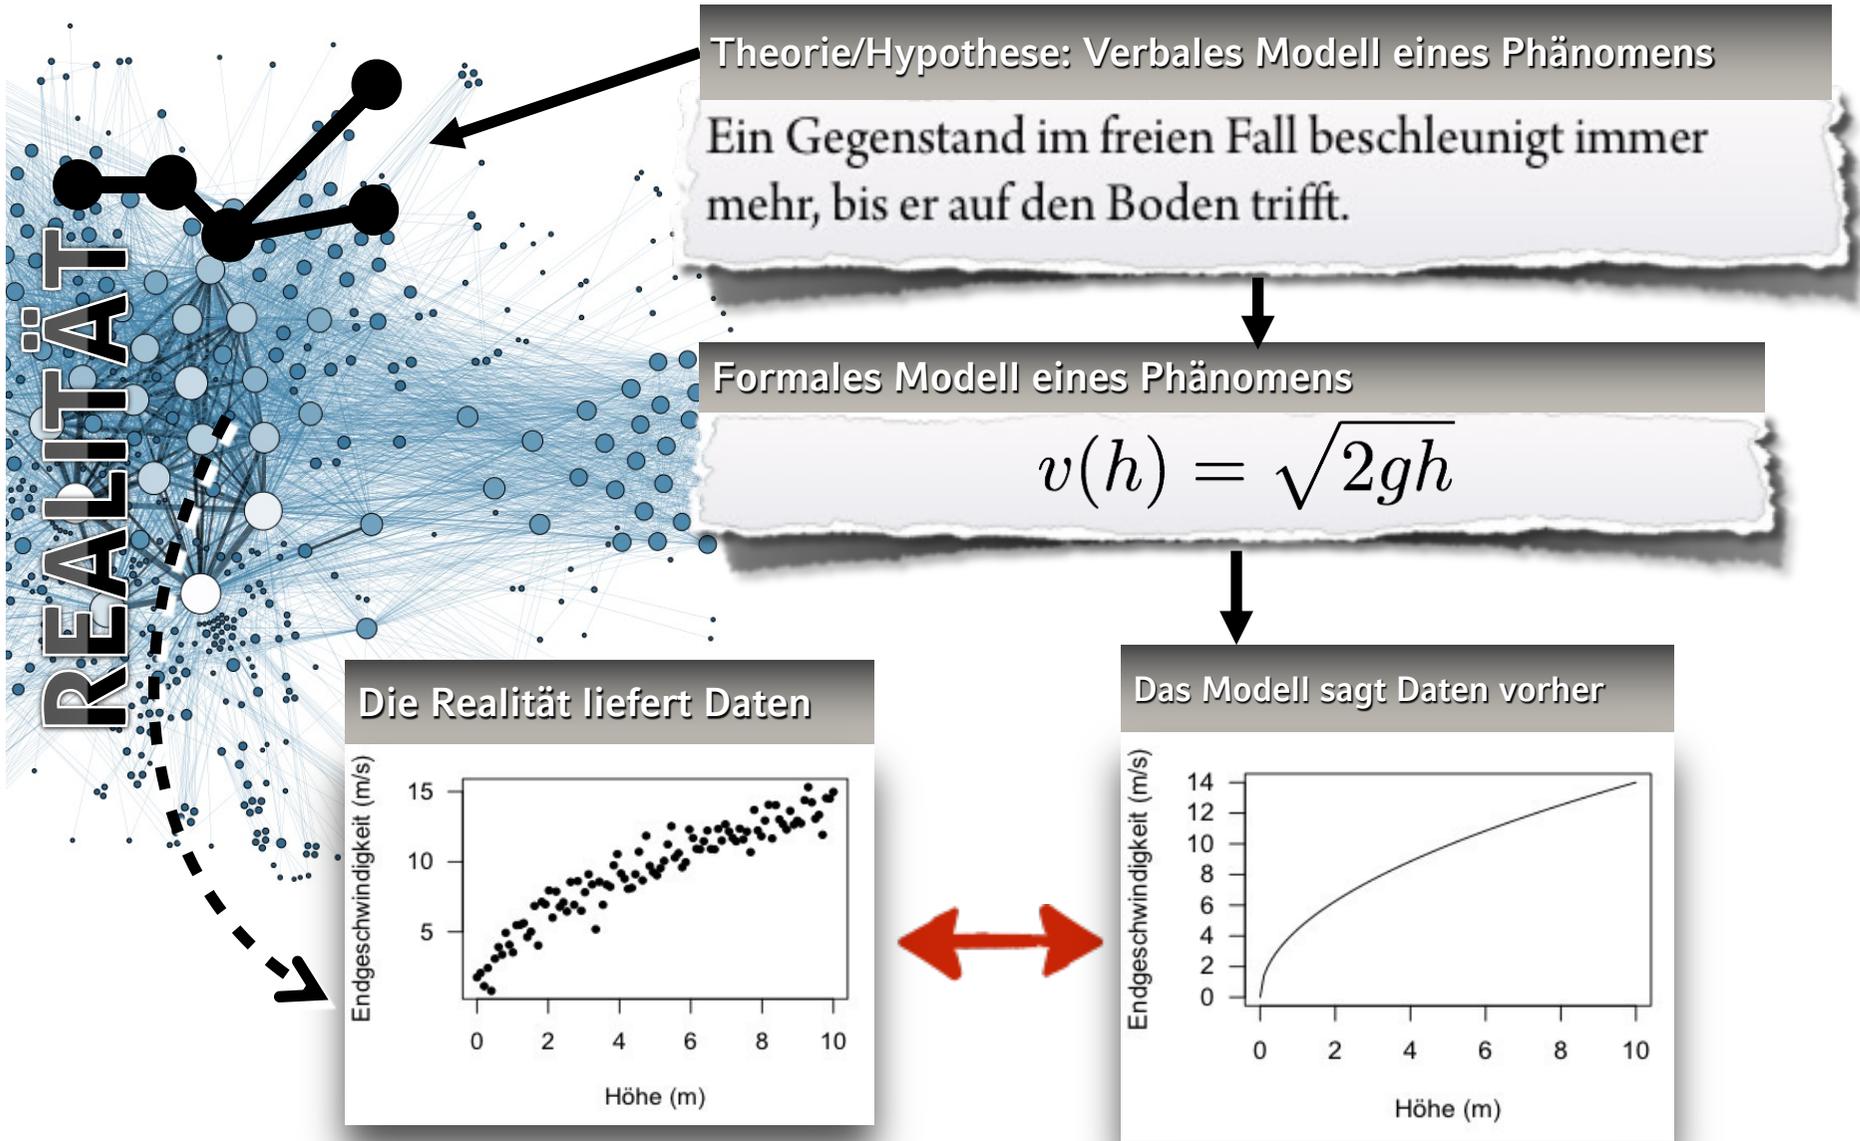


Theorie/Hypothese: Verbales Modell eines Phänomens

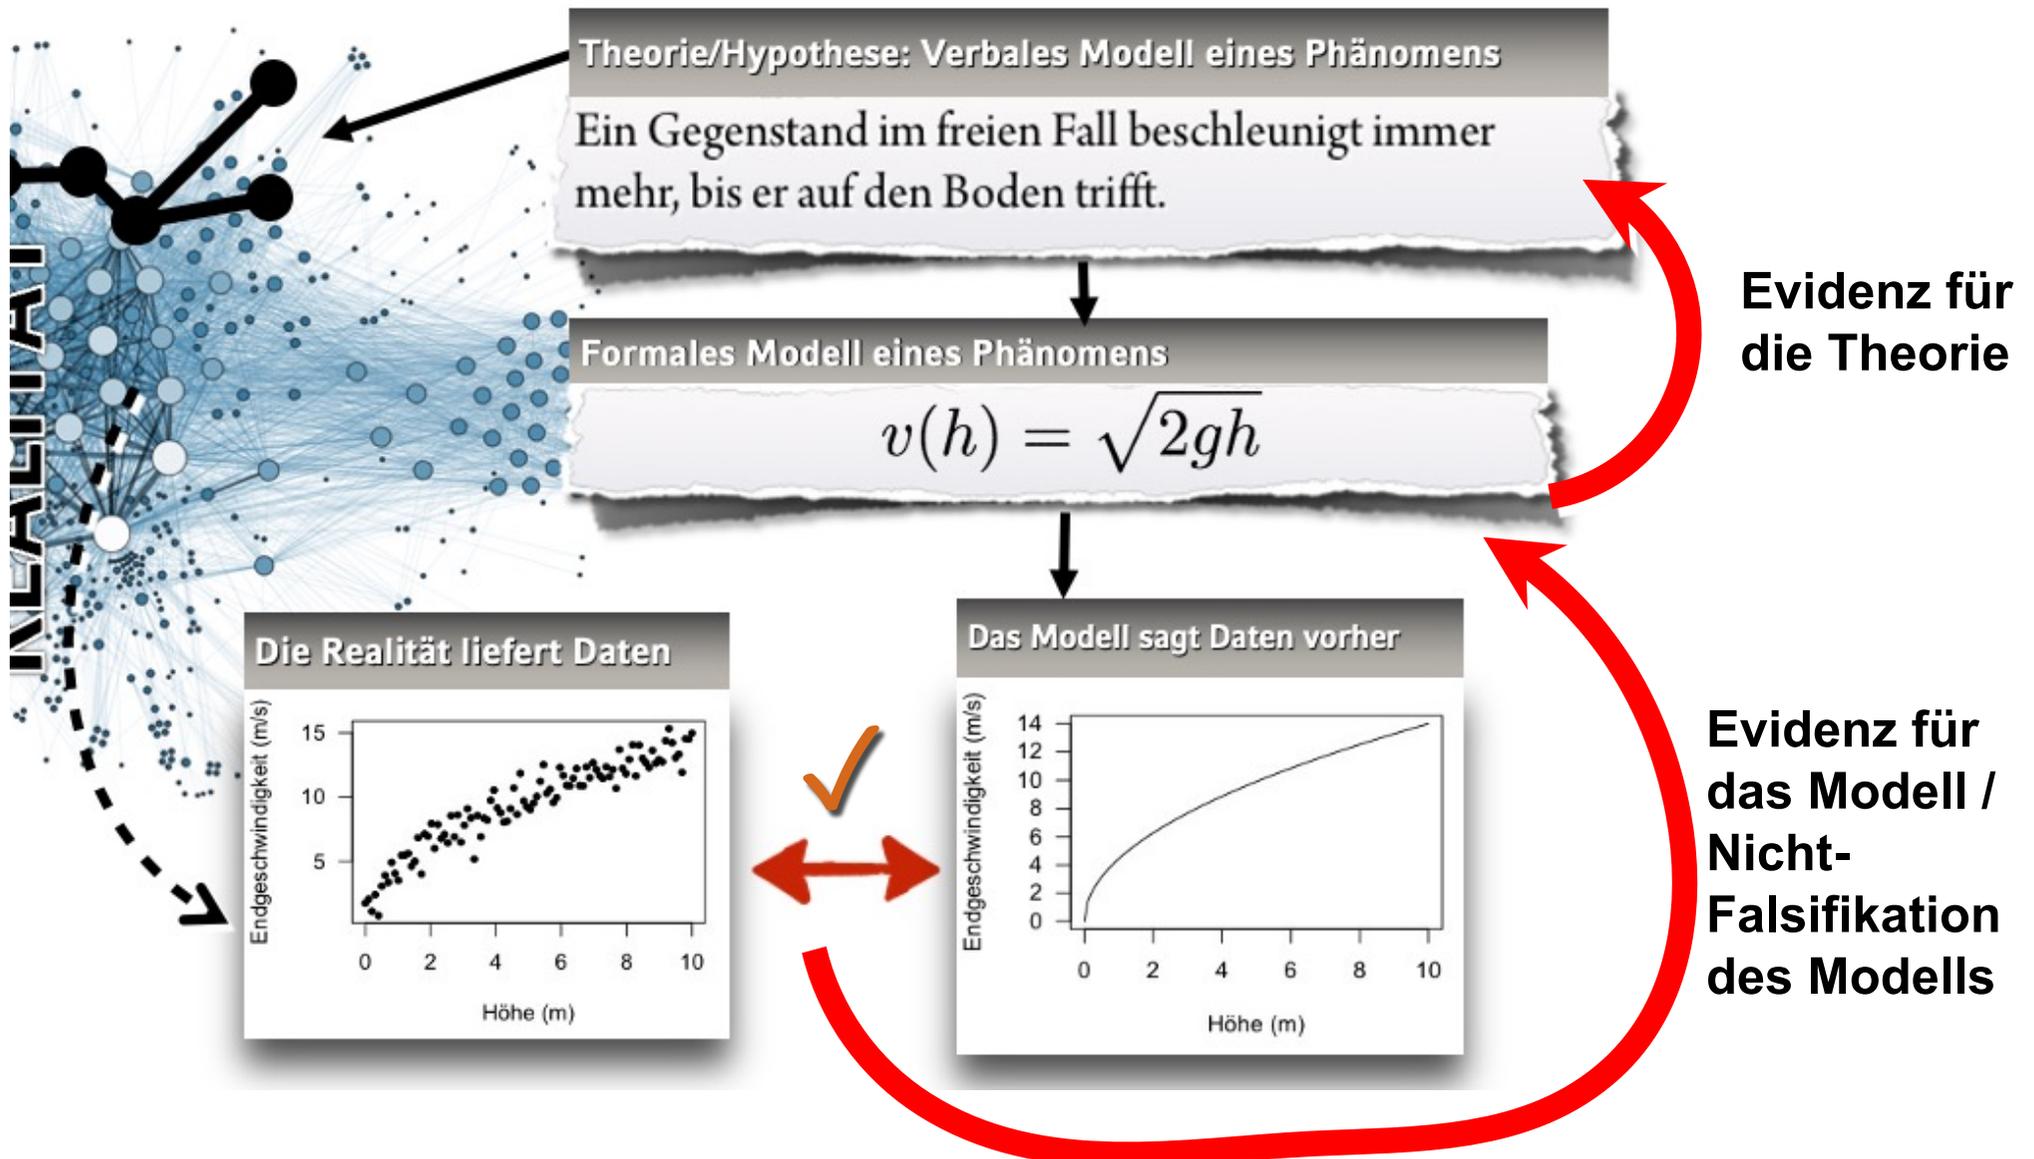
Ein Gegenstand im freien Fall beschleunigt immer
mehr, bis er auf den Boden trifft.

Ist meine Theorie eine adäquate Abbildung der Realität?

Wie können wir zu Erkenntnissen über die Welt gelangen?

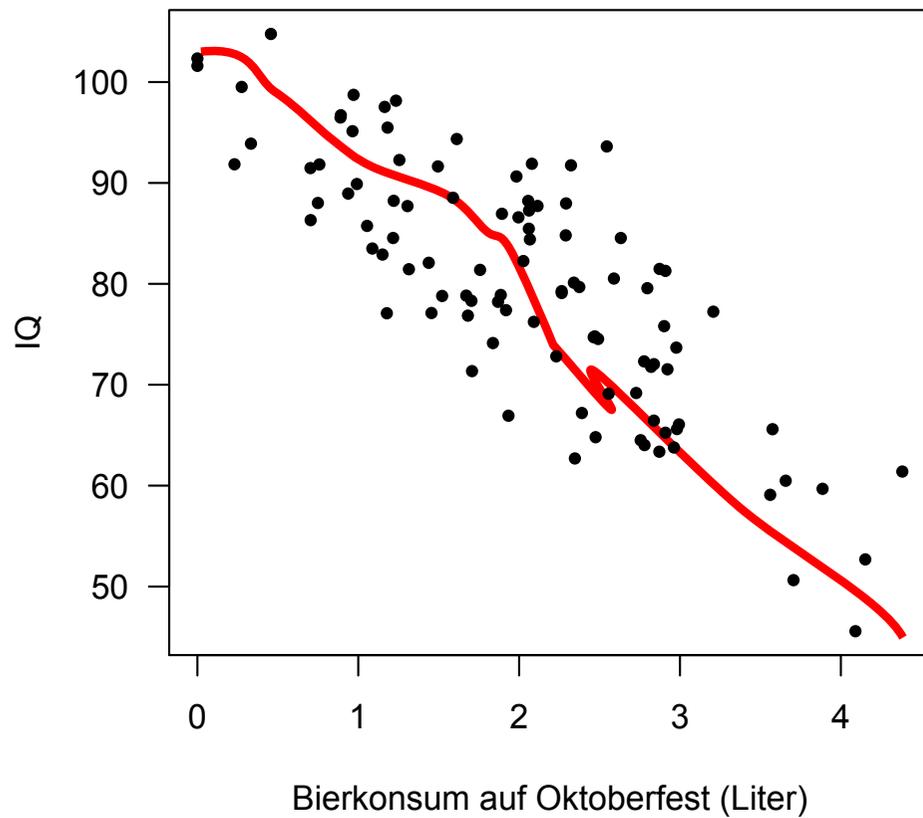


Wie können wir zu Erkenntnissen über die Welt gelangen?

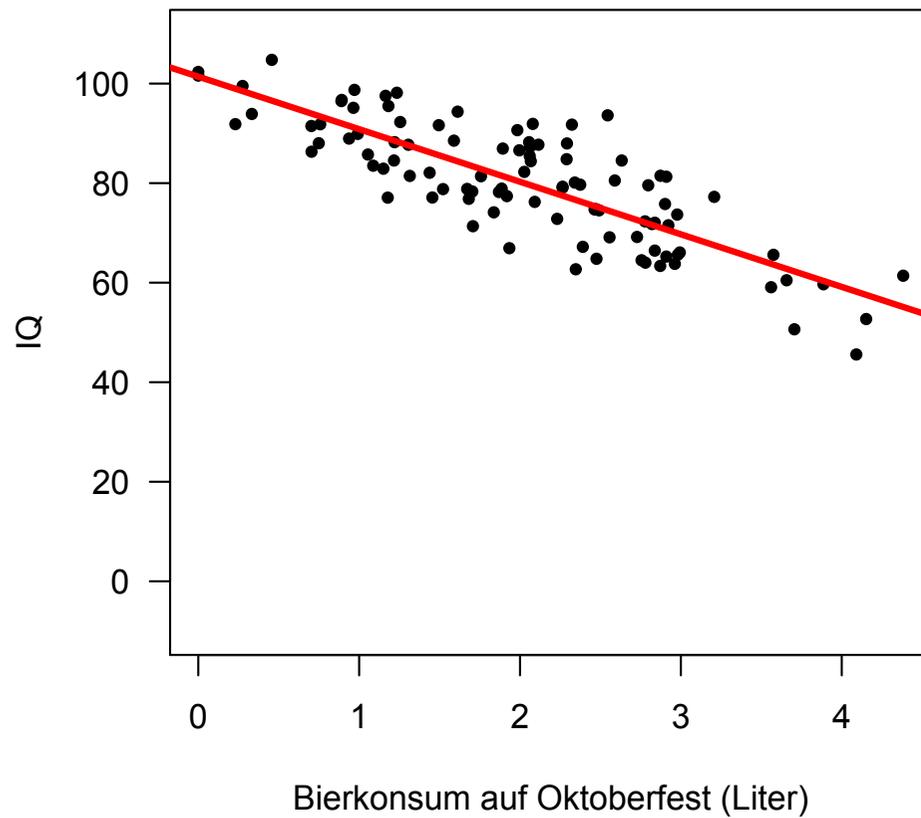


Zusammenfassung Lineare Regression

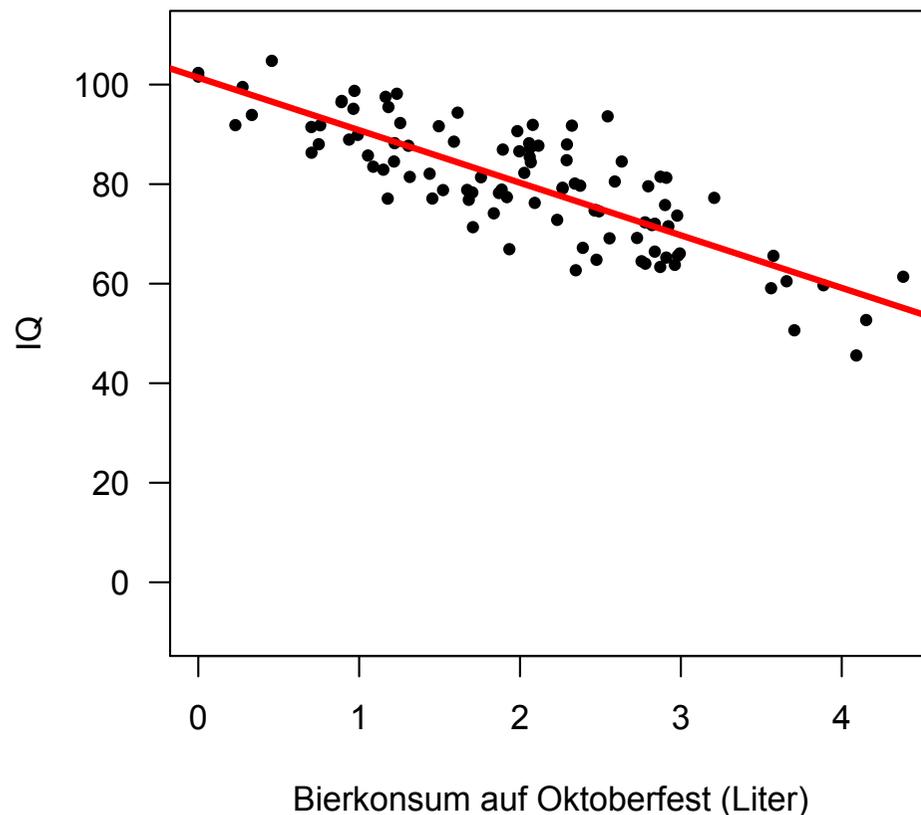
Eine wichtige Klasse von Modellen: Die linearen Modelle



Eine wichtige Klasse von Modellen: Die linearen Modelle



Eine wichtige Klasse von Modellen: Die linearen Modelle



Wie kann man eine Gerade
mathematisch beschreiben?

$$Y = a + bX$$

$$IQ = a + b * \text{Liter}$$

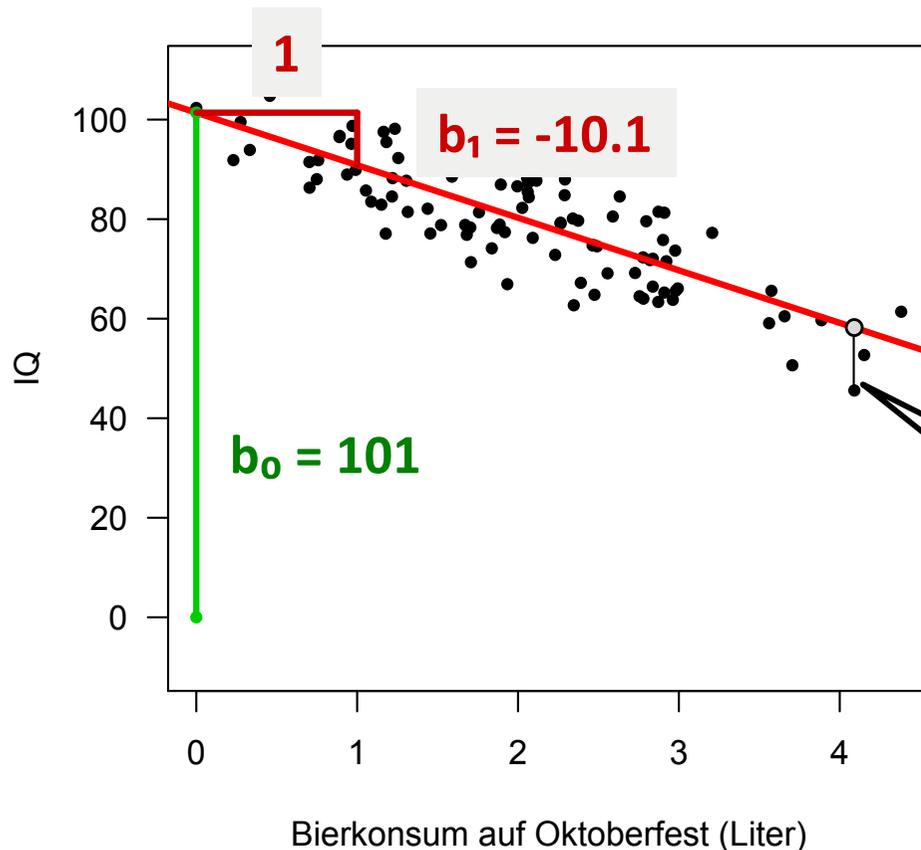
a =
Achsenabschnitt
(engl.: intercept)

b = Steigung
(engl.: slope)

Eine wichtige Klasse von Modellen: Die linearen Modelle

Modellparameter (Achsenabschnitt, bzw.
Intercept, eventuell als α bekannt)

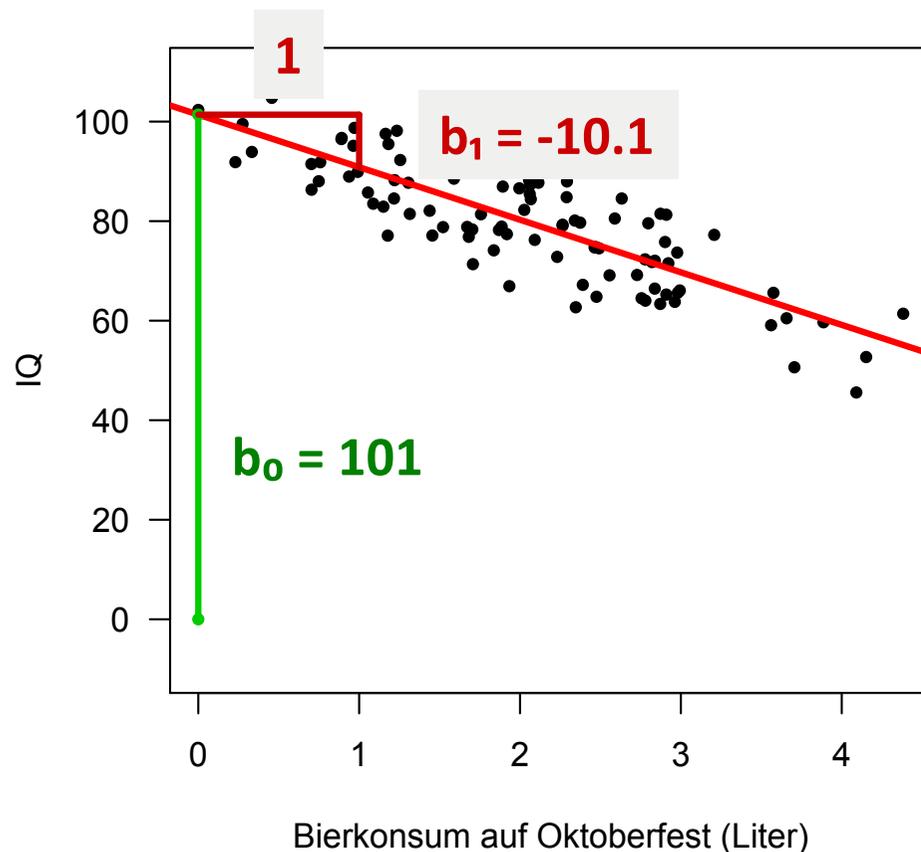
Modellparameter
(Steigungsparameter, Slope)



$$Y_i = \beta_0 + \beta_1 \cdot X_i + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma_\varepsilon^2)$$
$$E(Y_i | X_i = x_i) = \mu_i = \beta_0 + \beta_1 \cdot x_i$$
$$\hat{y}_i = b_0 + b_1 \cdot x_i$$

Vorhergesagter Wert (hier nun b_0
und b_1 , da die konkret
geschätzten Werte eingesetzt
werden)

Residuum: $e_i = y_i - \hat{y}_i$



Dach = vorhergesagter Wert

$$\widehat{IQ}_i = 101 - 10.1 * x_i$$

- Der Achsenabschnitt beschreibt den vorhergesagten Wert, wenn alle Prädiktorvariablen 0 sind
- Der Steigungsparameter gibt an, wie stark die Gerade steigt bzw. fällt. Die Steigung der Geraden ist an jeder Stelle konstant.
- Beispiel: wie stark sinkt der IQ **im Mittel**, wenn der Bierkonsum um eine Einheit zunimmt.
- Beispiel: Jemand der 2 Maß mehr trinkt, hat im Mittel einen IQ, der um 20.2 Einheiten geringer ist.

Wie findet man die optimal passende Gerade?

- Eine optimale Modellierung der Daten im Sinne der Regressionsanalyse besteht in der Minimierung der Fehlervariable ε : Über alle Datenpunkte betrachtet soll der Vorhersagefehler so klein wie möglich sein.
- Möglichkeit 1: Minimierung der **quadrierten Abweichung** von vorhergesagtem und tatsächlichen Wert (RSS = residual sum of squares):

$$\sum_{i=1}^n (y_i - \hat{y}_i)^2$$

- → ermöglicht analytische Berechnung der optimalen Modellparameter
- Aber: man könnte z.B. auch die **absolute Abweichung** optimieren. Oder die **maximale Abweichung** minimieren, ...

Wie findet man die optimal passende Gerade?

Iterativ durch Parameteroptimierung:

<https://shiny.psy.lmu.de/felix/lmfit/>

Fit-a-line!

ShinyApps: Experience Statistics About Links nicebread.de Contact

Coefficients

Intercept
-1.5 0.07 1.5

Slope
-1.5 0.59 1.5

Show optimal fit

Reset & new data Let 'optim' find the best fit!

Raw data + residuals

**Residual sum of squares
Smaller values = better fit**

Y X

RSS Step

Find-a-fit! shiny app. (c) by Felix Schönbrodt

Wir suchen die Werte für A und B, für die f(A,B) minimiert wird:

$$f(A, B) = \sum_{i=1}^n [Y_i - (A + BX_i)]^2$$

$$\sum_{i=1}^n \frac{1}{n} (-1)(2)(Y_i - A - BX_i) = 0$$

$$-2 \cdot \frac{1}{n} \sum_{i=1}^n (Y_i - A - BX_i) = 0$$

$$\frac{1}{n} \sum_{i=1}^n Y_i = \frac{1}{n} (nA + B \sum_{i=1}^n X_i)$$

$$\bar{Y} = A + B\bar{X}$$

$$A = \bar{Y} - B\bar{X}$$

$$\sum_{i=1}^n \frac{1}{n} (-X_i)(2)(Y_i - A - BX_i) = 0$$

$$B \sum_{i=1}^n X_i^2 = \sum_{i=1}^n X_i Y_i - \left((\bar{Y} - B\bar{X}) \sum_{i=1}^n X_i \right)$$

$$B \left(\sum_{i=1}^n X_i^2 - n \cdot \bar{X}^2 \right) = \sum_{i=1}^n X_i Y_i - n \cdot \bar{X} \cdot \bar{Y}$$

$$B = \frac{\sum_{i=1}^n X_i Y_i - n \cdot \bar{X} \cdot \bar{Y}}{\sum_{i=1}^n X_i^2 - n \cdot \bar{X}^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

Ausmultiplikation von $\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})$ **ergibt**
 $\sum_{i=1}^n X_i Y_i - n \cdot \bar{X} \cdot \bar{Y}$

Nebenrechnung:

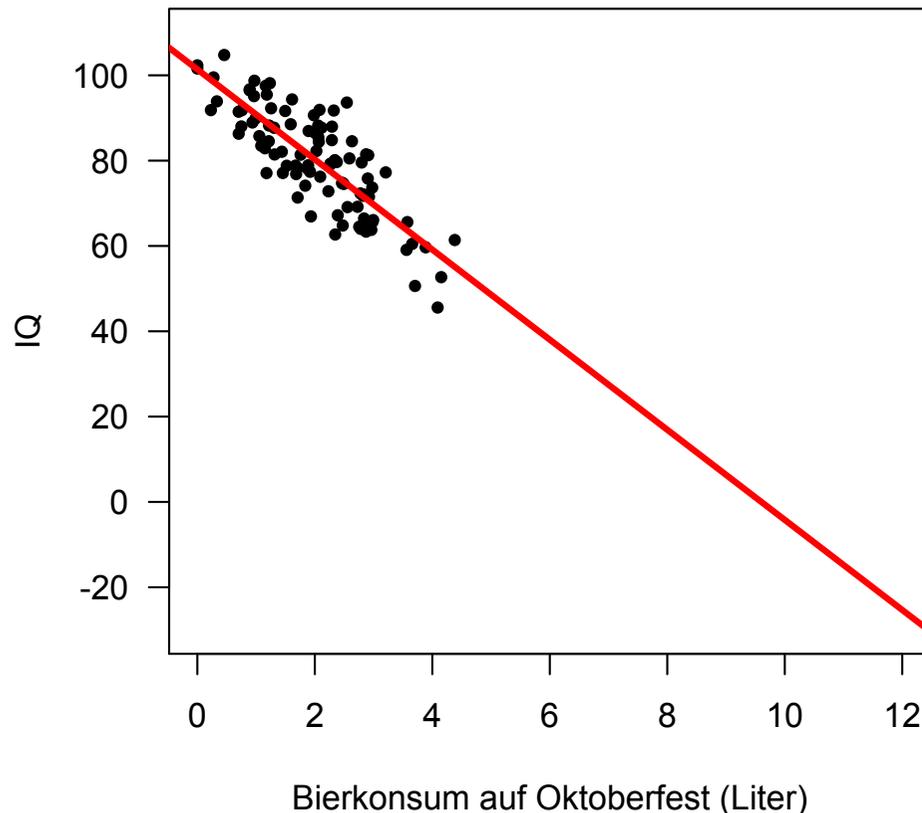
$$S^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n} \sum_{i=1}^n (X_i^2 - 2X_i \bar{X} + \bar{X}^2) =$$

$$S^2 = \frac{1}{n} \left(\sum_{i=1}^n X_i^2 - 2\bar{X} \sum_{i=1}^n X_i + \bar{X}^2 \sum_{i=1}^n 1 \right) =$$

$$nS^2 = \sum_{i=1}^n X_i^2 - 2n\bar{X}^2 + n\bar{X}^2 = \sum_{i=1}^n X_i^2 - n\bar{X}^2$$

Vorsicht bei Extrapolation!

Nach 12 Litern Bierkonsum ...



$$\begin{aligned}\widehat{IQ} &= 101 - 10.1 * x_i \\ &= 101 - 10.1 * 12 = -20.2\end{aligned}$$

- Extrapolation = Daten außerhalb des ursprünglichen Wertebereichs der Prädiktoren vorhersagen
- Extrapolation funktioniert nur unter typischerweise sehr unrealistischen Zusatzannahmen.
- Daher: Im Normalfall keine Extrapolation machen.

1. Die Zufallsvariablen hängen linear zusammen
2. Alle ε_i sind unabhängig voneinander
→ Diese Annahme wird z.B. in hierarchischen Datenstrukturen verletzt!
3. Die ε_i folgen einer Normalverteilung mit Erwartungswert Null und konstanter Varianz (Homoskedastizität):

$$\varepsilon_i \sim N(0, \sigma_\varepsilon^2)$$

→ Achtung: das Modell nimmt an, dass **die Fehlervariablen** normalverteilt sind – nicht die Prädiktoren, und auch nicht die abhängige Variable!

→ diese Annahme ist für die Schätzung der Modellparameter meist irrelevant (Gelman & Hill, 2007); eine Verletzung ist auch für die Schätzung der Standardfehler meist unkritisch.

Kategoriale Prädiktoren: Dummy vs. Effektkodierung

- Bei kategorialen Variablen wird die Ausprägung numerisch kodiert
- Verschiedene Kodierungsschemata am Beispiel „Münchner*in“:
- Dummy-Kodierung:
 - z.B.: keine Münchner*in = 0, Münchner*in = 1
 - Die Gruppe mit der Kodierung 0 ist die Referenzgruppe
- Effektkodierung:
 - z.B.: keine Münchner*in = -1, Münchner*in = 1
 - Bei zwei Gruppen: immer symmetrisch um Null herum definieren
- Die Zahlen sind arbiträr – man könnte auch keine Münchner*in = 0 und Münchner*in = 3 machen. Die Modelle sind mathematisch alle äquivalent, die Interpretation der Koeffizienten aber unterschiedlich!

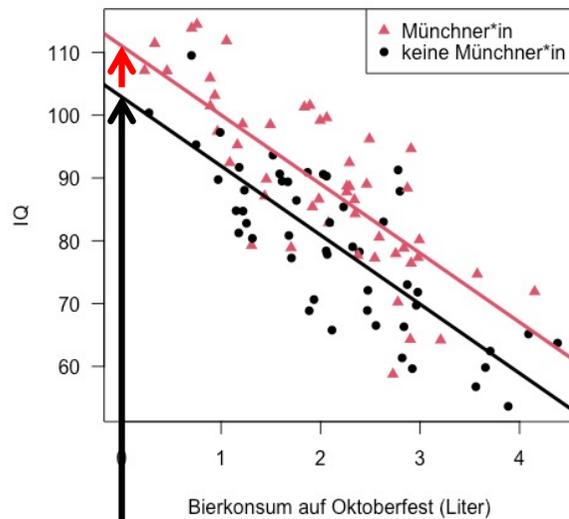
$$IQ_i = \beta_0 + \beta_1 \cdot Bier_i + \beta_2 \cdot Muc_i + \varepsilon_i$$

Dummykodierung !muc=0, muc=1

β_0	β_1	β_2
Coefficients:		
(Intercept)	bier	muc_dummy1
102.919	-11.002	8.123

Slope beider Gruppen

Unterschied in den
Intercepts



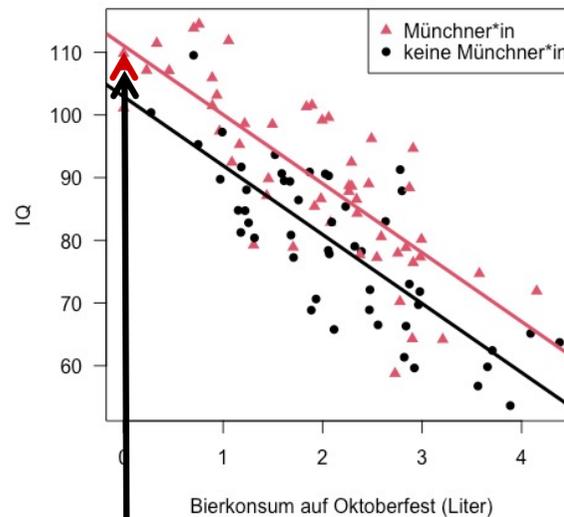
Intercept =
Intercept der Referenzgruppe

Effektkodierung !muc=-1, muc=1

β_0	β_1	β_2
Coefficients:		
(Intercept)	bier	muc_effect
106.980	-11.002	4.062

Slope beider Gruppen

Abweichung beider
Gruppen (+/-) vom
grand intercept

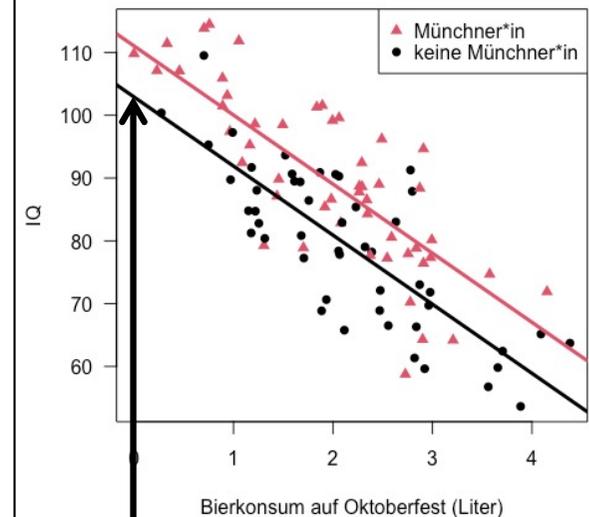


Intercept =
gemitteltes Intercept über beide Gruppen
(ohne Gewichtung nach Fallzahl beider Gruppen)

Seltsame Dummykodierung !muc=0, muc=3

β_0	β_1	β_2
Coefficients:		
(Intercept)	bier	muc_dummy2
102.919	-11.002	2.708

Wenn die dummy-kodierte Variable
eine Einheit hoch geht, geht das
Intercept 2.7 Einheiten hoch. Nur
steht bei muc immer 3, also ist das
Intercept $3 \cdot 2.7 = 8.1$ höher!



Intercept =
Intercept der Referenzgruppe

$$IQ_i = \beta_0 + \beta_1 \cdot Bier_i + \beta_2 \cdot Muc_i + \varepsilon_i$$

Dummykodierung
!muc=0, muc=1

Coefficients:
(Intercept) bier muc_dummy1
102.919 -11.002 8.123

Eine Münchner*in
trinkt 3.4 Liter Bier.

Wie hoch ist ihr IQ?

$bier = 3.4$
 $muc_dummy1 = 1$

$$\widehat{IQ}_i = 102.9 - 11.00 \cdot 3.4 + 8.12 \cdot 1 \\ = 73.6$$

Effektkodierung
!muc=-1, muc=1

Coefficients:
(Intercept) bier muc_effect
106.980 -11.002 4.062

Eine Münchner*in
trinkt 3.4 Liter Bier.

Wie hoch ist ihr IQ?

$bier = 3.4$
 $muc_effect = 1$

$$\widehat{IQ}_i = 106.98 - 11.00 \cdot 3.4 + 4.06 \cdot 1 \\ = 73.6$$

Seltene Dummykodierung
!muc=0, muc=3

Coefficients:
(Intercept) bier muc_dummy2
102.919 -11.002 2.708

Eine Münchner*in
trinkt 3.4 Liter Bier.

Wie hoch ist ihr IQ?

$bier = 3.4$
 $muc_dummy2 = 3$

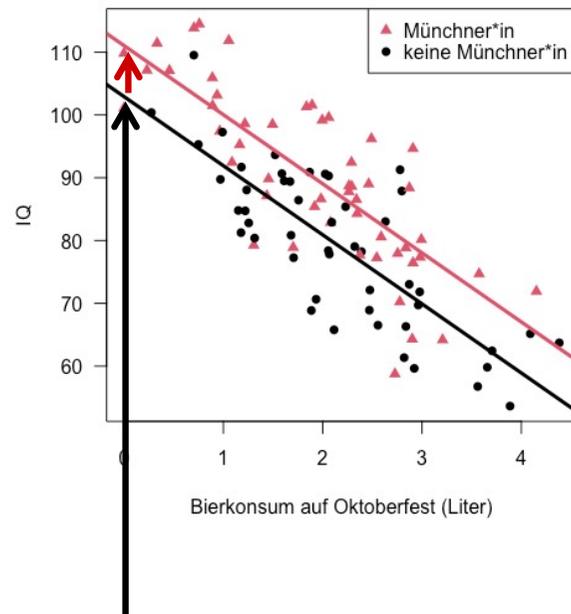
$$\widehat{IQ}_i = 102.9 - 11.00 \cdot 3.4 + 2.71 \cdot 3 \\ = 73.6$$

Wechsel der Referenzgruppe

Dummykodierung
!muc=0, muc=1

Coefficients:

(Intercept)	bier	muc_dummy1
102.919	-11.002	8.123

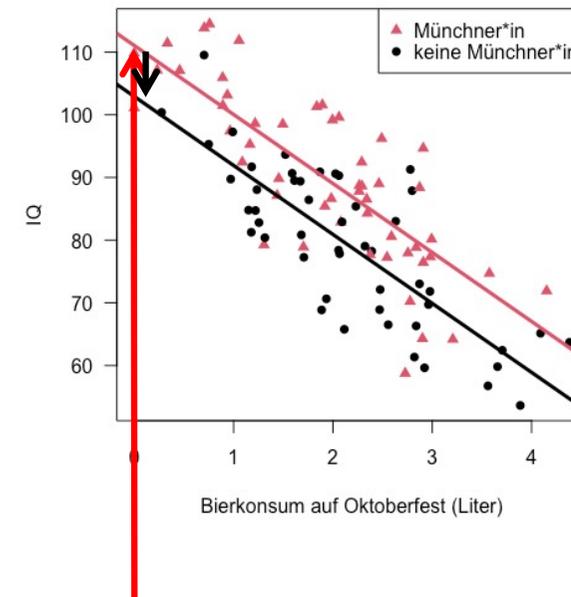


Intercept =
Intercept der Referenzgruppe (!Muc)

Dummykodierung
!muc=1, muc=0

Coefficients:

(Intercept)	bier	muc_dummy1_rev
111.042	-11.002	-8.123



Intercept =
Intercept der Referenzgruppe (Muc)

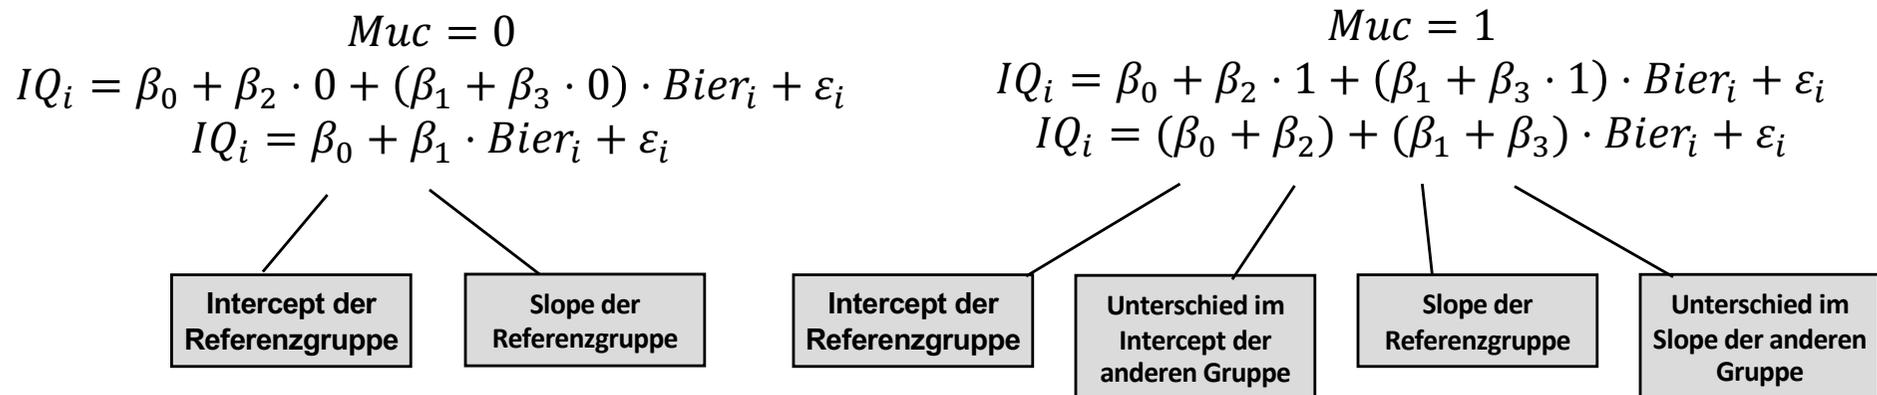
- Dummy-Kodierung:
 - z.B.: keine Münchner*in = 0, Münchner*in = 1
 - Die Gruppe mit der Kodierung 0 ist die Referenzgruppe
 - Intercept = Achsenabschnitt der Referenzgruppe
 - Das Regressionsgewicht für μ_C ist der Unterschied im Intercept der anderen Gruppe im Vgl. zur Referenzgruppe
- Effektkodierung:
 - z.B.: keine Münchner*in = -1, Münchner*in = 1
 - Intercept = grand intercept, über beide Gruppen hinweg (ungewichtet falls ungleiche Gruppengrößen – d.h., der Mittelwert der beiden Gruppenmittelwerte, egal wie groß die Gruppen sind)
 - Das Regressionsgewicht für μ_C ist der Unterschied beider Gruppen (+ oder -) im Vergleich zum grand intercept.

Dichotome Variable: Interaktion mit slope (a.k.a. „Moderierte Regression“)

$$IQ_i = \beta_0 + \beta_1 Bier_i + \beta_2 Muc_i + \beta_3 Bier_i \cdot Muc_i + \varepsilon_i$$

$$IQ_i = \beta_0 + \beta_2 Muc_i + (\beta_1 + \beta_3 Muc_i) \cdot Bier_i + \varepsilon_i$$

Dummy-Kodierung: !muc = 0, muc = 1



$$IQ_i = \beta_0 + \beta_1 Bier_i + \beta_2 Muc_i + \beta_3 Bier_i \cdot Muc_i + \varepsilon_i$$

$$IQ_i = \beta_0 + \beta_2 Muc_i + (\beta_1 + \beta_3 Muc_i) \cdot Bier_i + \varepsilon_i$$

Dummy-Kodierung: !muc = 0, muc = 1

Coefficients:

(Intercept)
102.364

bier
-15.744

muc_dummy1
9.124

bier:muc_dummy1
-10.491

Intercept !Muc

Slope !Muc

Unterschied
Intercept Muc
zu !Muc

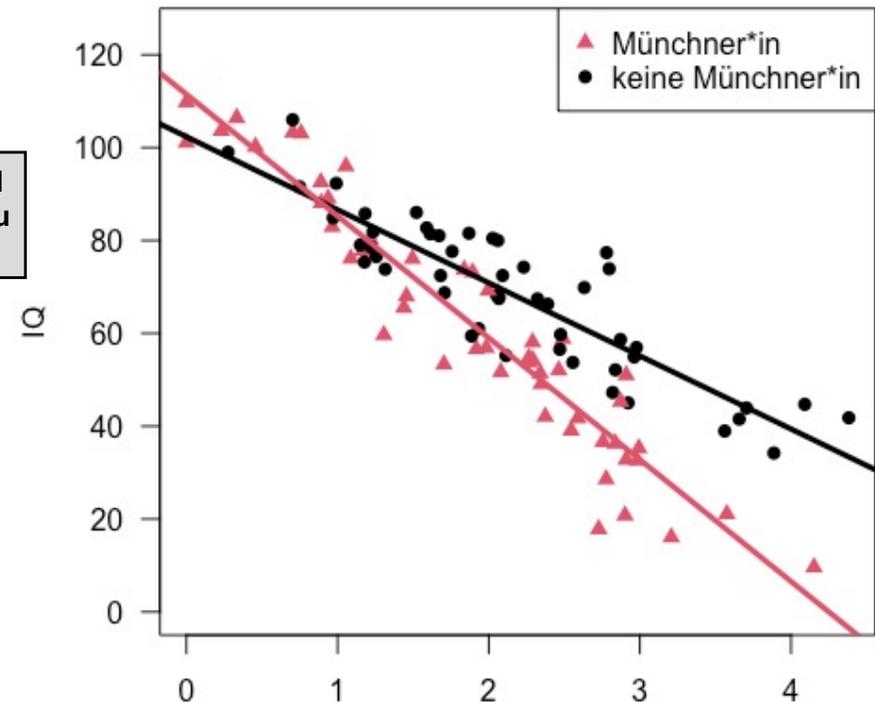
Unterschied
slope Muc zu
!Muc

$Muc = 0$

$$\widehat{IQ}_i = 102.4 - 15.7 \cdot Bier_i$$

$Muc = 1$

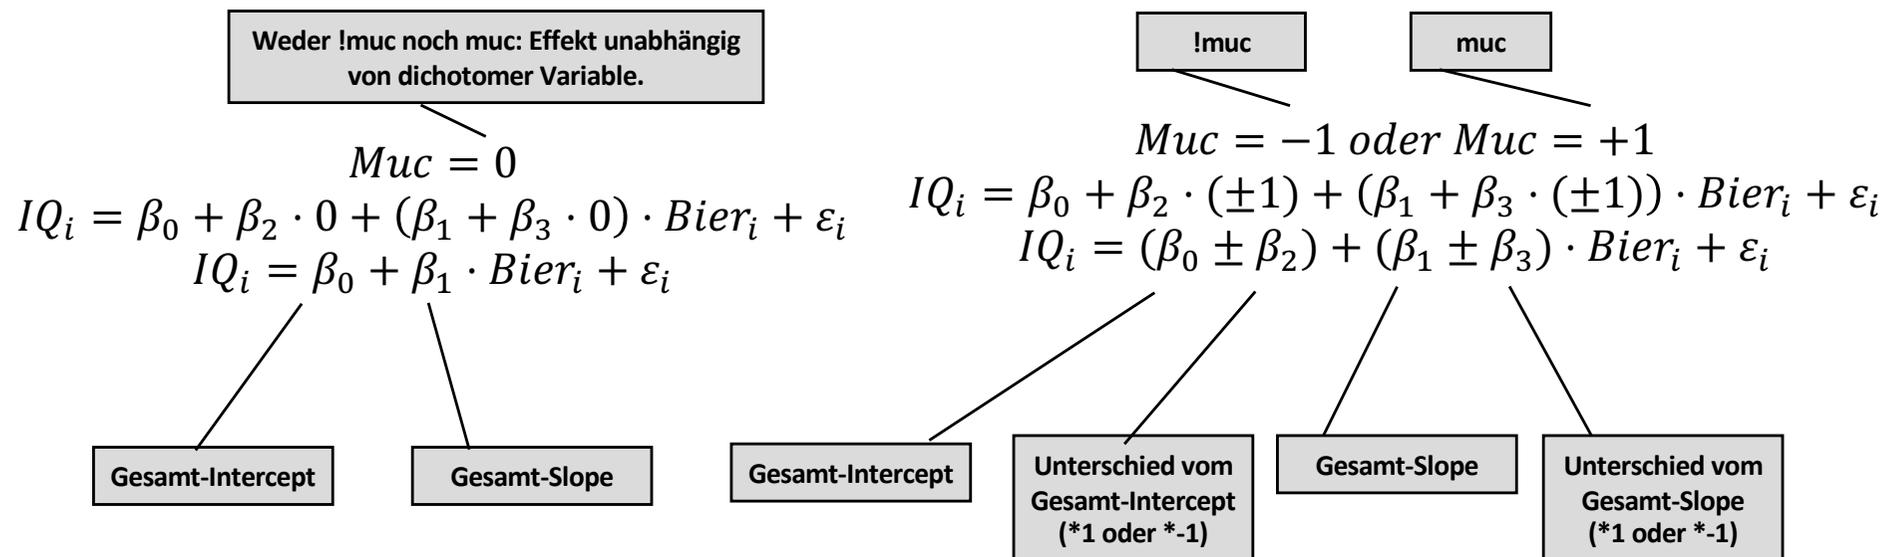
$$\widehat{IQ}_i = (102.4 + 9.1) + (-15.7 - 10.5) \cdot Bier_i$$



$$IQ_i = \beta_0 + \beta_1 Bier_i + \beta_2 Muc_i + \beta_3 Bier_i \cdot Muc_i + \varepsilon_i$$

$$IQ_i = \beta_0 + \beta_2 Muc_i + (\beta_1 + \beta_3 Muc_i) \cdot Bier_i + \varepsilon_i$$

Effektkodierung: !muc = -1, muc = 1



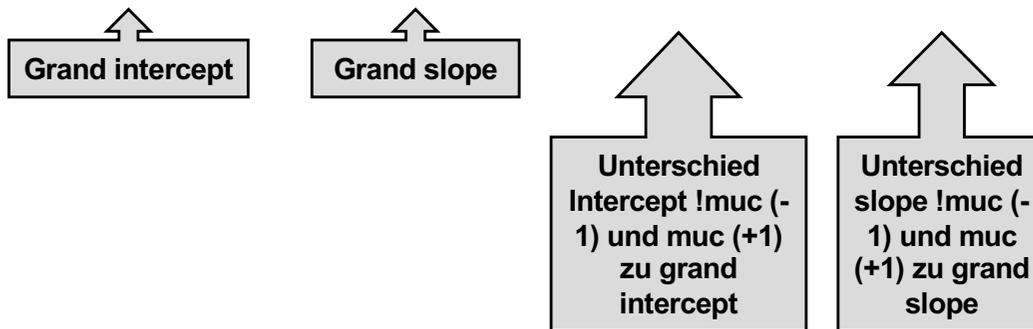
$$IQ_i = \beta_0 + \beta_1 Bier_i + \beta_2 Muc_i + \beta_3 Bier_i \cdot Muc_i + \varepsilon_i$$

$$IQ_i = \beta_0 + \beta_2 Muc_i + (\beta_1 + \beta_3 Muc_i) \cdot Bier_i + \varepsilon_i$$

- Effektkodierung: !muc= -1, muc = 1

Coefficients:

(Intercept)	bier	muc_effect	bier:muc_effect
106.926	-20.989	4.562	-5.246

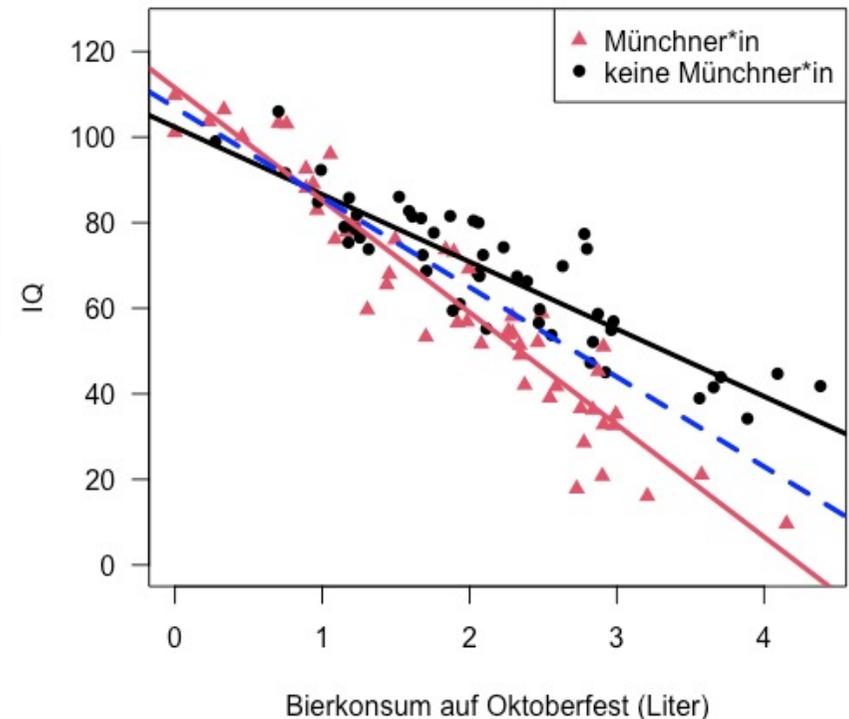


$Muc = 0$

$$\widehat{IQ}_i = 106.9 - 21.0 \cdot Bier_i$$

$Muc = \pm 1$

$$\widehat{IQ}_i = (106.9 \pm 4.6) + (-21.0 \pm (-5.2)) \cdot Bier_i$$



Dummykodierung
!muc=0, muc=1

Effektkodierung
!muc=-1, muc=1

Call:
lm(formula = IQ ~ bier * muc_dummy1)

Residuals:				
Min	1Q	Median	3Q	Max
-22.0866	-5.3774	-0.0536	5.2388	18.7691

Coefficients:				
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	102.364	2.914	35.123	< 2e-16 ***
bier	-15.744	1.247	-12.624	< 2e-16 ***
muc_dummy1	9.124	3.863	2.362	0.0202 *
bier:muc_dummy1	-10.491	1.720	-6.099	2.23e-08 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 8.06 on 96 degrees of freedom
Multiple R-squared: 0.8748, Adjusted R-squared: 0.8708
F-statistic: 223.5 on 3 and 96 DF, p-value: < 2.2e-16

Call:
lm(formula = IQ ~ bier * muc_effect)

Residuals:				
Min	1Q	Median	3Q	Max
-22.0866	-5.3774	-0.0536	5.2388	18.7691

Coefficients:				
	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	106.926	1.931	55.365	< 2e-16 ***
bier	-20.989	0.860	-24.405	< 2e-16 ***
muc_effect	4.562	1.931	2.362	0.0202 *
bier:muc_effect	-5.246	0.860	-6.099	2.23e-08 ***

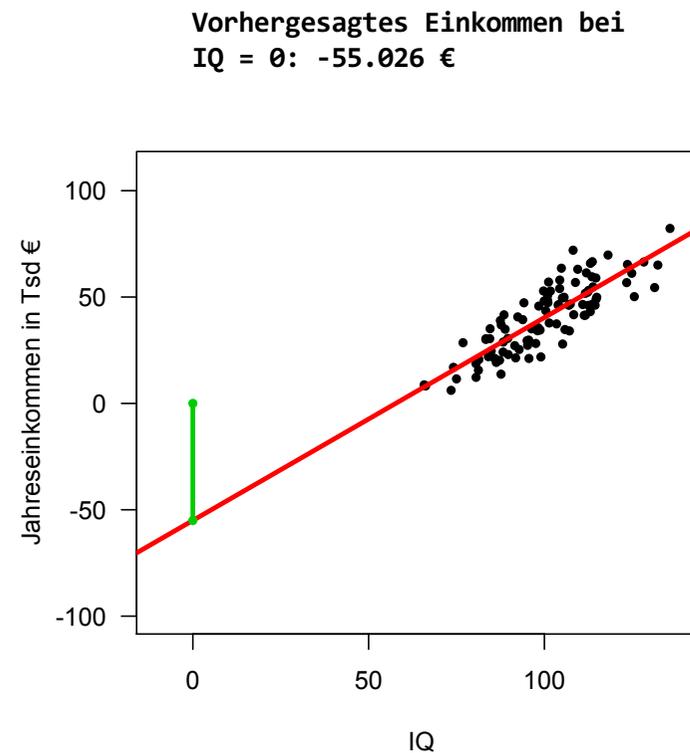
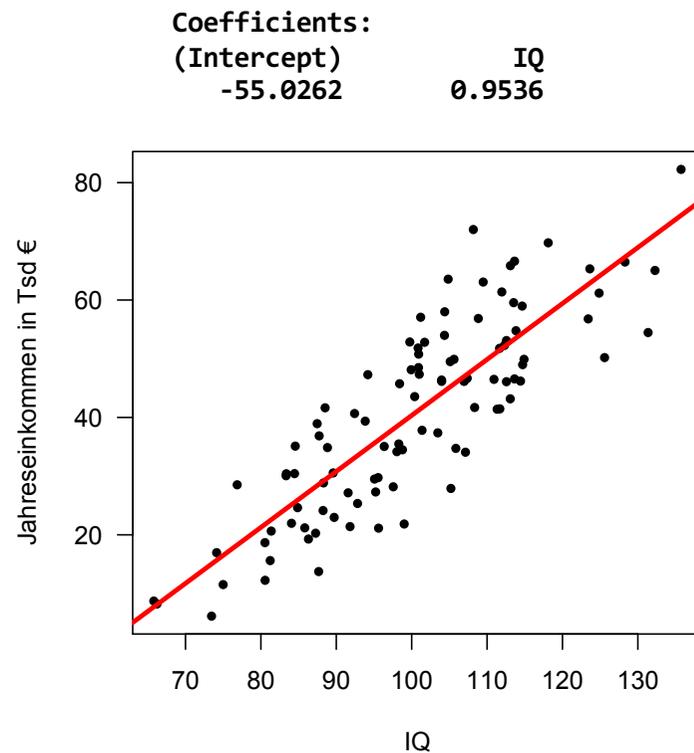
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 8.06 on 96 degrees of freedom
Multiple R-squared: 0.8748, Adjusted R-squared: 0.8708
F-statistic: 223.5 on 3 and 96 DF, p-value: < 2.2e-16

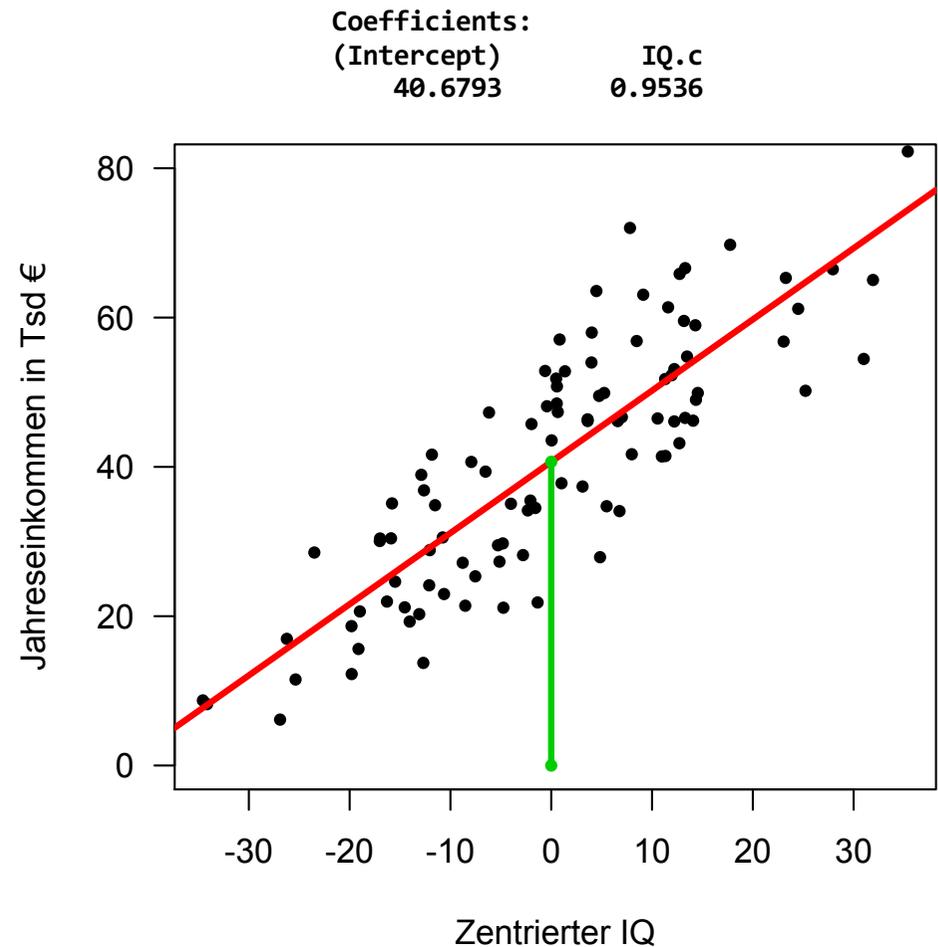
Unterschiedliche Koeffizienten, aber identisches R²,
F-Statistik, Residuen!

Zentrierung von Prädiktorvariablen

- Der Achsenabschnitt beschreibt den vorhergesagten Wert, wenn alle Prädiktorvariablen 0 sind
- Ist die 0 ein sinnvoller Wert bei einem Prädiktor?



- Faustregel: Zentriere Prädiktorvariablen immer so, dass die Null einen sinnvollen Wert beschreibt. Möglichkeiten:
 - Auf Stichprobenmittelwert zentrieren (am häufigsten). Dann beschreibt das Intercept den vorhergesagten Wert einer durchschnittlichen Person
 - Auf Populationsmittelwert zentrieren (aus Normdaten)
 - Auf das Minimum der Stichprobe zentrieren
 - Bei Zeitreihen: Auf ersten Messzeitpunkt zentrieren
 - Bei Likert-Skalen: Auf den semantischen Mittelpunkt zentrieren:
 - 3 = trifft gar nicht zu;
 - 0 = unentschieden;
 - +3 = trifft voll zu



Unterschiedliche Zentrierungen (bzw. lineare Transformationen im Allgemeinen) von Prädiktoren führen zu mathematisch äquivalenten Modellen!

→ Unterschiedliche Koeffizienten, aber identisches R^2 , F-Statistik, Residuen!

Dummykodierung
!muc=0, muc=1

ACHTUNG: Diese Kombination macht wenig Sinn – nur aus didaktischen Gründen gewählt!

Bier zentriert auf Gesamtmittelwert

Effektkodierung
!muc=-1, muc=1

ACHTUNG: Diese Kombination macht wenig Sinn – nur aus didaktischen Gründen gewählt!

Bier zentriert auf Mittelwert der Münchner*innen

Call:
lm(formula = IQ ~ bier.c * muc_dummy1)

Residuals:

Min	1Q	Median	3Q	Max
-22.0866	-5.3774	-0.0536	5.2388	18.7691

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	80.5641	1.1607	69.410	< 2e-16 ***
bier.c	-10.7437	1.2471	-8.615	1.40e-13 ***
muc_dummy1	8.1272	1.6245	5.003	2.55e-06 ***
bier.c:muc_dummy1	-0.4913	1.7201	-0.286	0.776

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 8.06 on 96 degrees of freedom
Multiple R-squared: 0.6841, Adjusted R-squared: 0.6742
F-statistic: 69.3 on 3 and 96 DF, p-value: < 2.2e-16

Call:
lm(formula = IQ ~ bier.c.w * muc_effect)

Residuals:

Min	1Q	Median	3Q	Max
-22.0866	-5.3774	-0.0536	5.2388	18.7691

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	85.8711	0.8189	104.864	< 2e-16 ***
bier.c.w	-10.9893	0.8600	-12.778	< 2e-16 ***
muc_effect	4.0914	0.8189	4.996	2.62e-06 ***
bier.c.w:muc_effect	-0.2456	0.8600	-0.286	0.776

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 8.06 on 96 degrees of freedom
Multiple R-squared: 0.6841, Adjusted R-squared: 0.6742
F-statistic: 69.3 on 3 and 96 DF, p-value: < 2.2e-16

Over- & Underfitting

- Modellpassung
 - Es gibt mehrere Kandidatenmodelle, die die Zusammenhänge in der Realität beschreiben
 - (darüber hinaus gibt es unendlich viele alternative Modelle)
 - Die Modelle können unterschiedlich flexibel („komplex“) sein
 - Da wir die Realität nicht kennen, gibt es Unsicherheit darüber, welches der Modell das relativ beste ist

$$y_i = \beta_0 + \beta_1 x + \epsilon_i$$

$$y_i = \beta_1 \frac{x_1}{x_2} + \epsilon_i$$

$$y_i = \beta_0 + \beta_1 \frac{x_1}{x_2} + \beta_2 x_3 + \beta_3 \frac{1}{x_4} + \epsilon_i$$

- Modellparameter = Parameter innerhalb eines konkreten Modells, die variieren können und mithilfe von Daten geschätzt werden müssen
 - In einfachen Modellen (siehe diese Vorlesung) gilt:
Mehr Modellparameter -> Höhere Flexibilität des Modells
 - In komplexeren Modellen (siehe dieses Semester), wird die Flexibilität manchmal absichtlich durch zusätzliche Modellparameter eingeschränkt
- Schätzung der Parameter: Gegeben der vorgegebenen Modellstruktur – was sind die Parameterausprägungen, die das Modell optimal „auf die Daten einstellen“?
- Manchmal ist ein Modell nicht flexibel genug, um die Daten adäquat modellieren zu können
- Ein gewähltes Modell ist durch die freien Parameter eigentlich eine **Modellfamilie**

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i \begin{cases} \rightarrow y_i = 1.2 + 0.4x_i + \epsilon_i \\ \rightarrow y_i = 3.1 - 3.2x_i + \epsilon_i \\ \rightarrow y_i = -5 + 0.05x_i + \epsilon_i \end{cases}$$

- „Ockhams Rasiermesser“
 - Von mehreren möglichen Erklärungen für ein und denselben Sachverhalt ist die einfachste Theorie allen anderen vorzuziehen.
 - Statistischer Kontext: Wenn zwei unterschiedliche Modelle die Daten gleich gut beschreiben, ist das „einfachere“ Modell vorzuziehen
- Aber:
 - Was bedeutet „einfacher“? Weniger Parameter, weniger Annahmen, ...
 - Meistens liegt ein Trade-Off zwischen Genauigkeit und Einfachheit vor: Ockhams Rasiermesser nicht direkt anwendbar

Einfacheres Modell

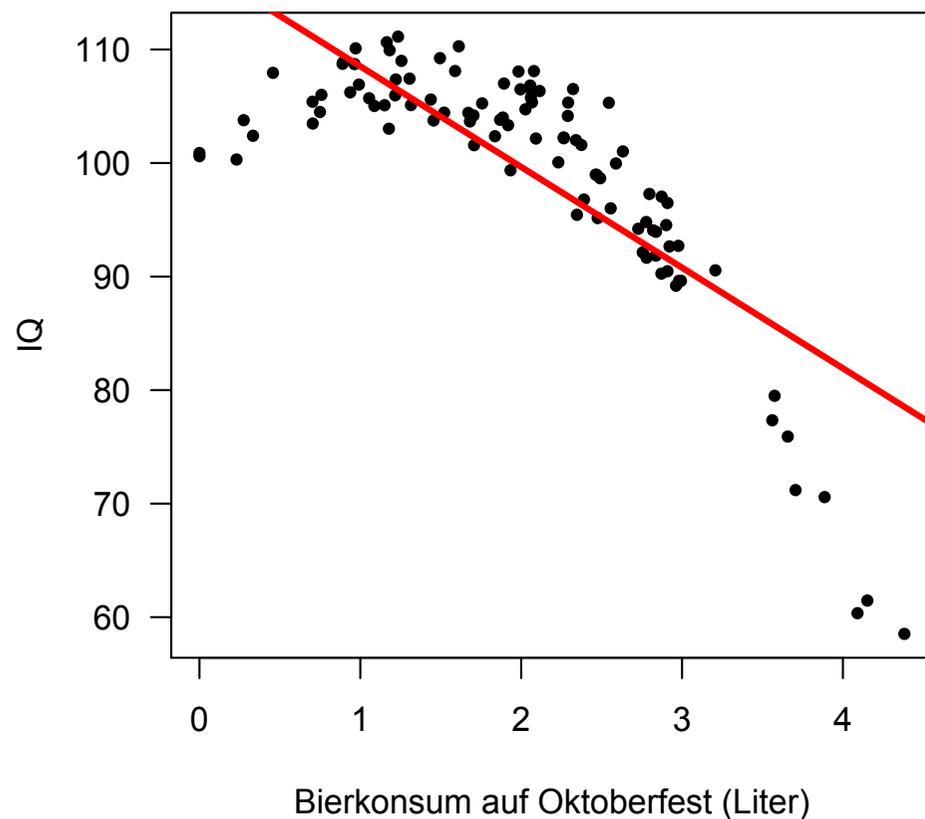
$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i$$

Komplexeres Modell

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \epsilon_i$$

Obwohl der Term quadratisch ist (also eine Kurve abbildet), ist es ein lineares Modell, weil alle Einzelterme linear kombiniert werden

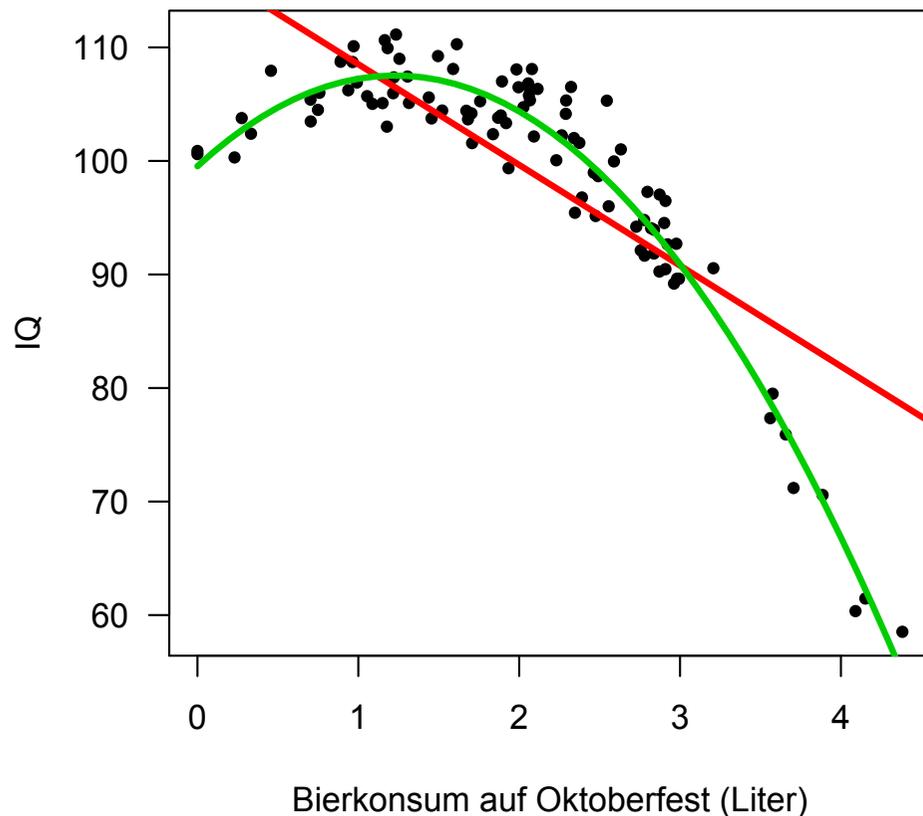
- Underfitting: Ein Modell hat nicht flexibel genug, um die Daten adäquat abbilden zu können
- Problem: Inadequates Abbild der Daten, Schlechte Vorhersagekraft



```
lm(formula = y ~ x)
```

Residual standard error: 6.704 on 98 degrees of freedom
Multiple R-squared: 0.6148, Adjusted R-squared: 0.6108

- Underfitting: Ein Modell hat nicht flexibel genug, um die Daten adäquat abbilden zu können
- Problem: Inadequates Abbild der Daten, Schlechte Vorhersagekraft
- Das flexiblere Modell mit quadratischem Term „passt besser“



```
lm(formula = y ~ x)
```

Residual standard error: 6.704 on 98 degrees of freedom
Multiple R-squared: 0.6148, Adjusted R-squared: 0.6108

```
lm(formula = y ~ x + I(x^2))
```

Residual standard error: 2.623 on 97 degrees of freedom
Multiple R-squared: 0.9416, Adjusted R-squared: 0.9404

With four parameters I can fit
an elephant, and with five I can
make him wiggle his trunk.



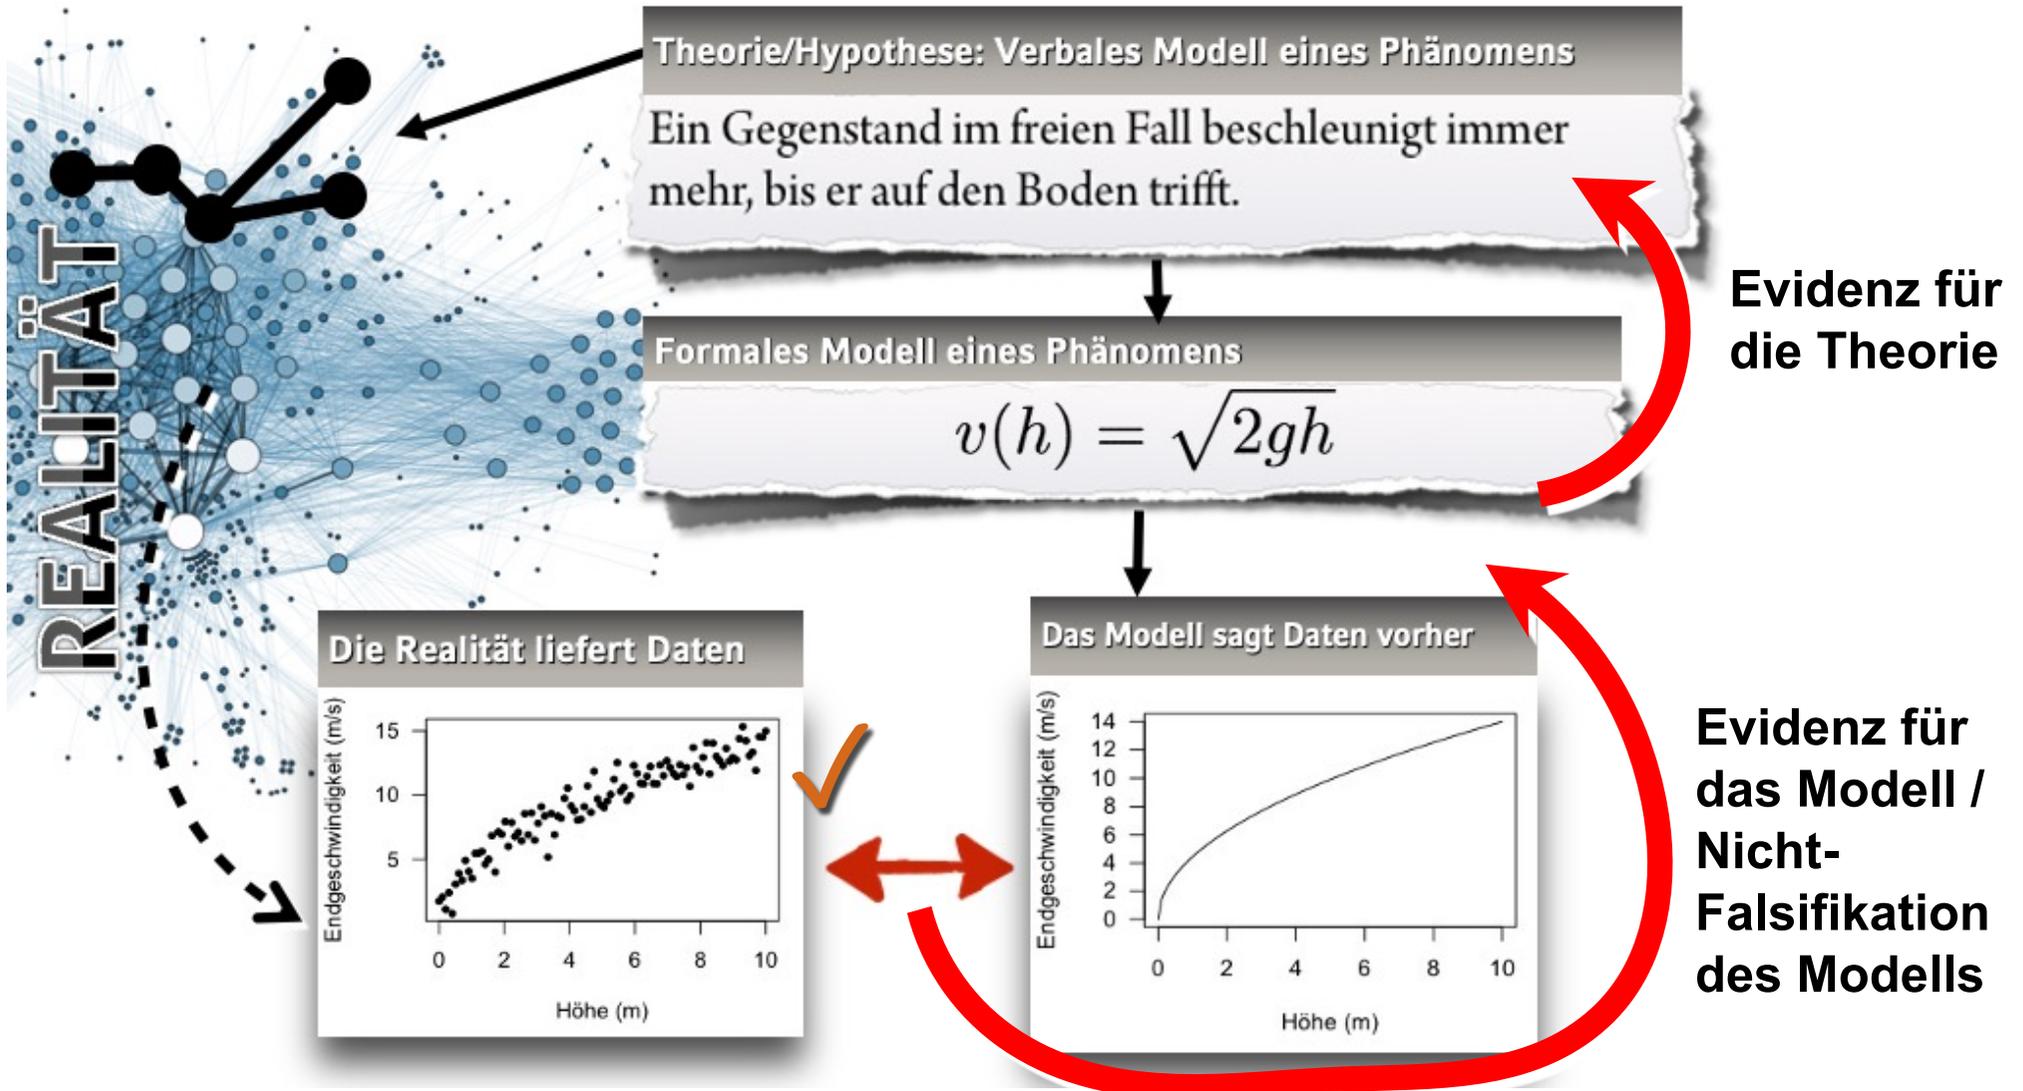
CC-BY 3.0 - [wikispaces](#)

John von Neumann (1903 - 1957)

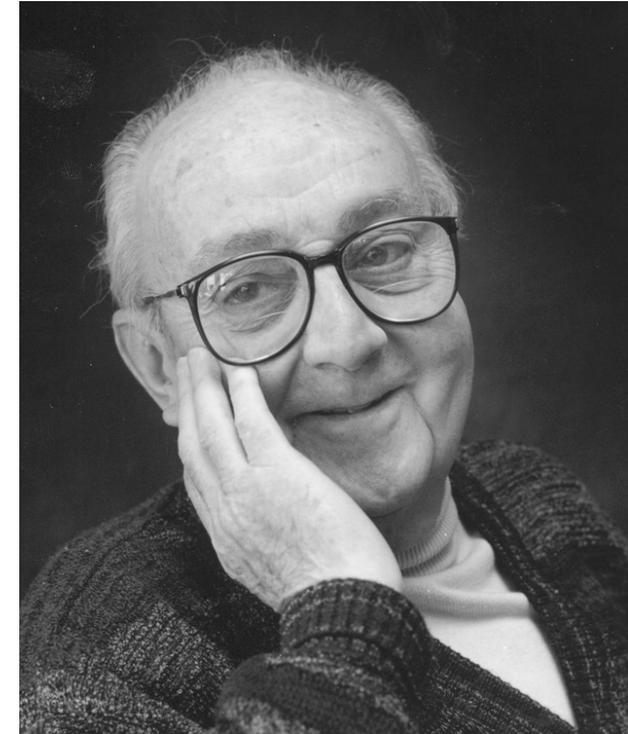
Probleme beim Overfitting

- Scheinbar gute Modellpassung und hohe Vorhersagequalität bei dem ursprünglichen Datensatz, auf den das Modell angepasst wurde.
- Wenn das Modell jedoch auf neue Daten aus der gleichen Population angewendet wird, ist Vorhersagekraft deutlich niedriger.
- Warum? Das flexiblere Modell passt sich offenbar auch an spezifische, unsystematische Kleinigkeiten des Datensatzes an.
- Es greift nicht nur das Signal (d.h., den systematischen Anteil) in den Daten ab, sondern fängt an, das Rauschen mit zu modellieren.
- Da das Rauschen in jedem neuen Datensatz anders sein wird, ist die Vorhersagekraft sogar schlechter als bei einem weniger flexiblen Modell.
- Mehr dazu im zweiten Teil des Semesters über Prädiktive Modellierung.

Wie können wir zu Erkenntnissen über die Welt gelangen?



**All models are wrong,
but some models are
useful.**

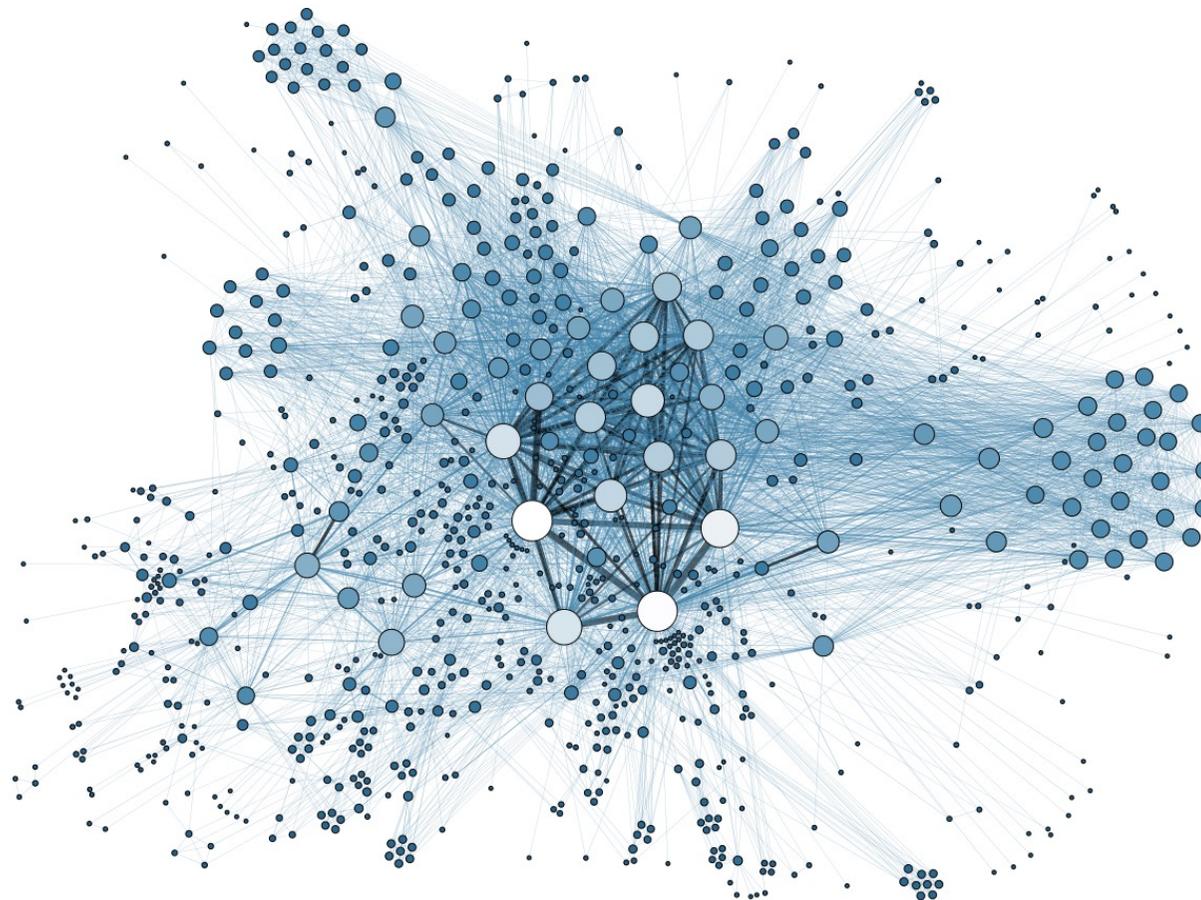


Georg Box, 1919 - 2013

All models are wrong, but some models are useful.



Exkurs: Ockhams Razor



Warum ist „einfacher“ besser? Was ist die Begründung für Ockham's Razor?

- <https://aeon.co/essays/are-scientific-theories-really-better-when-they-are-simpler> by Elliott Sober
- There's no logical justification for Ockham's razor (i.e., there is no proof that, even ceteris paribus, the simpler theory is true/closer to truth).
- E.g. evolution depends on random mutations, crystallized randomness: no reason to assume that simpler is (always) closer to truth.
- Can be seen as a **probabilistic** argument: Of two explanations with the same explanatory power, the simpler has a higher probability of being true / closer to the truth.
- Can be seen as a **pragmatic** argument: When the predictive success is the same, it is easier & more tractable for us to retain the simpler theory, without any practical loss. Saves cognitive capacity, less teaching, less memorizing. Do not waste time on irrelevant stuff.
- See it more as a heuristic, not a law

- Concerning in-sample fit, the more complex model always outperforms the simpler model (or is in the boundary case at least equally good). But: when we switch to out-of-sample predictions, the simpler model can be better (even if you do not believe in „true nulls“)
- Does ‚better‘ mean ‚more true‘ or ‚more useful‘? If the latter, Ockham’s razor can be justified.
- As an antidote to Ockham: Epicurus’ Principle of Multiple Explanations states: “If several theories are consistent with the observed data, retain them all.”
(<http://cage.ugent.be/~ci/Epicurus.html>)
- David MacKay’s online book ITILA (<http://www.inference.phy.cam.ac.uk/itila>) chapter 28 (<http://www.inference.phy.cam.ac.uk/mackay/itprnn/ps/343.355.pdf>) gives the clearest justification for Ockham’s razor I have seen, as a simple consequence of the laws of probability.