

Analysen politikwissenschaftlicher Datensätze mit Stata

JOHANNES
GUTENBERG
UNIVERSITÄT
MAINZ

Sitzung 5: Lineare Regression

Vorbereitung

- Stata durch `z:\profile.do` starten
- Datensatz `z:\daten\rpstrukt` laden
- Achtung: Ab dieser Sitzung werden Stata-Befehle nicht mehr durch Schreibmaschinenschrift hervorgehoben

Modelle

- Modelle sind eine extreme Vereinfachung der Wirklichkeit
- Statistische Modelle modellieren die Zusammenhänge zwischen Variablen
- Lineare Regression ist das einfachste und für die Politikwissenschaft wichtigste Modell

Lineare Regression

- Statistische Modelle beschreiben,
 - wie der erwartete Wert einer abhängigen Variablen
 - mit dem Wert einer oder mehrerer unabhängiger Variablen zusammenhängt
- Im Fall der linearen Regression ist dieser Zusammenhang *linear*, d.h. bei einem positiven Zusammenhang werden
 - für höhere/niedrigere Werte der unabhängigen Variablen
 - *proportional* höhere/niedrigere Werte der abhängigen Variablen erwartet
 - Zusammenhang kann durch eine Gerade veranschaulicht werden

Konkret:

- Geben Sie nochmals ein
 - summ pwbcdu71 if pkathv70 > 54
 - summ pwbcdu71 if pkathv70 < 54
- Dieser Zusammenhang kann durch die Formel $CDU71 = a + b * KATH70$ beschrieben werden
- Allgemein $y = a + b * x$ [systematischer Teil]

Erwartungswert

- Erwartungswert \cong Mittelwertwert
 - Wenn wir sukzessive rheinland-pfälzische Wahlkreise betrachten, „erwarten“ wir für 1971 einen CDU-Anteil von 39,2 Prozent (Mittelwert)
 - „zentrale Tendenz“
 - „bester Tipp“ (geringste quadrierte Abweichung)
- In einem „leeren“ Regressionsmodell entspricht die Konstante dem Mittelwert der abhängigen Variablen: reg pwbcdu71

Erwartungswert

- In einem Regressionsmodell *mit einer unabhängigen Variablen* kann durch Einsetzen für jeden Wert der unabhängigen Variablen ein erwarteter Wert für die abhängige Variable bestimmt werden
- Auch dieser Wert ist ein *Erwartungswert*:
 - der konditionale (d.h. von x abhängige) Mittelwert für den Wert von y ,
 - der sich nach unserem Modell ergeben würde, wenn wir viele Fälle mit dem entsprechenden x -Wert untersuchen würden

Erwartungswerte

- `reg pwbcdu71 pkathv70`
- Wir erwarten, daß der mittlere CDU-Anteil mit jedem Prozentpunkt Katholikenanteil um 0,3 Prozentpunkte zunimmt
- Die Konstante entspricht jetzt dem erwarteten CDU-Anteil, wenn der Katholikenanteil = 0
- `graph twoway (scatter pwbcdu71 pkathv70) (lfit pwbcdu71 pkathv70)`
- Transformation der x-Variablen erleichtert evtl. die Interpretation der Konstante
 - `summ pkathv70`
 - `gen zpkathv70=pkathv70-r(mean)`
 - `reg pwbcdu71 zpkathv70`

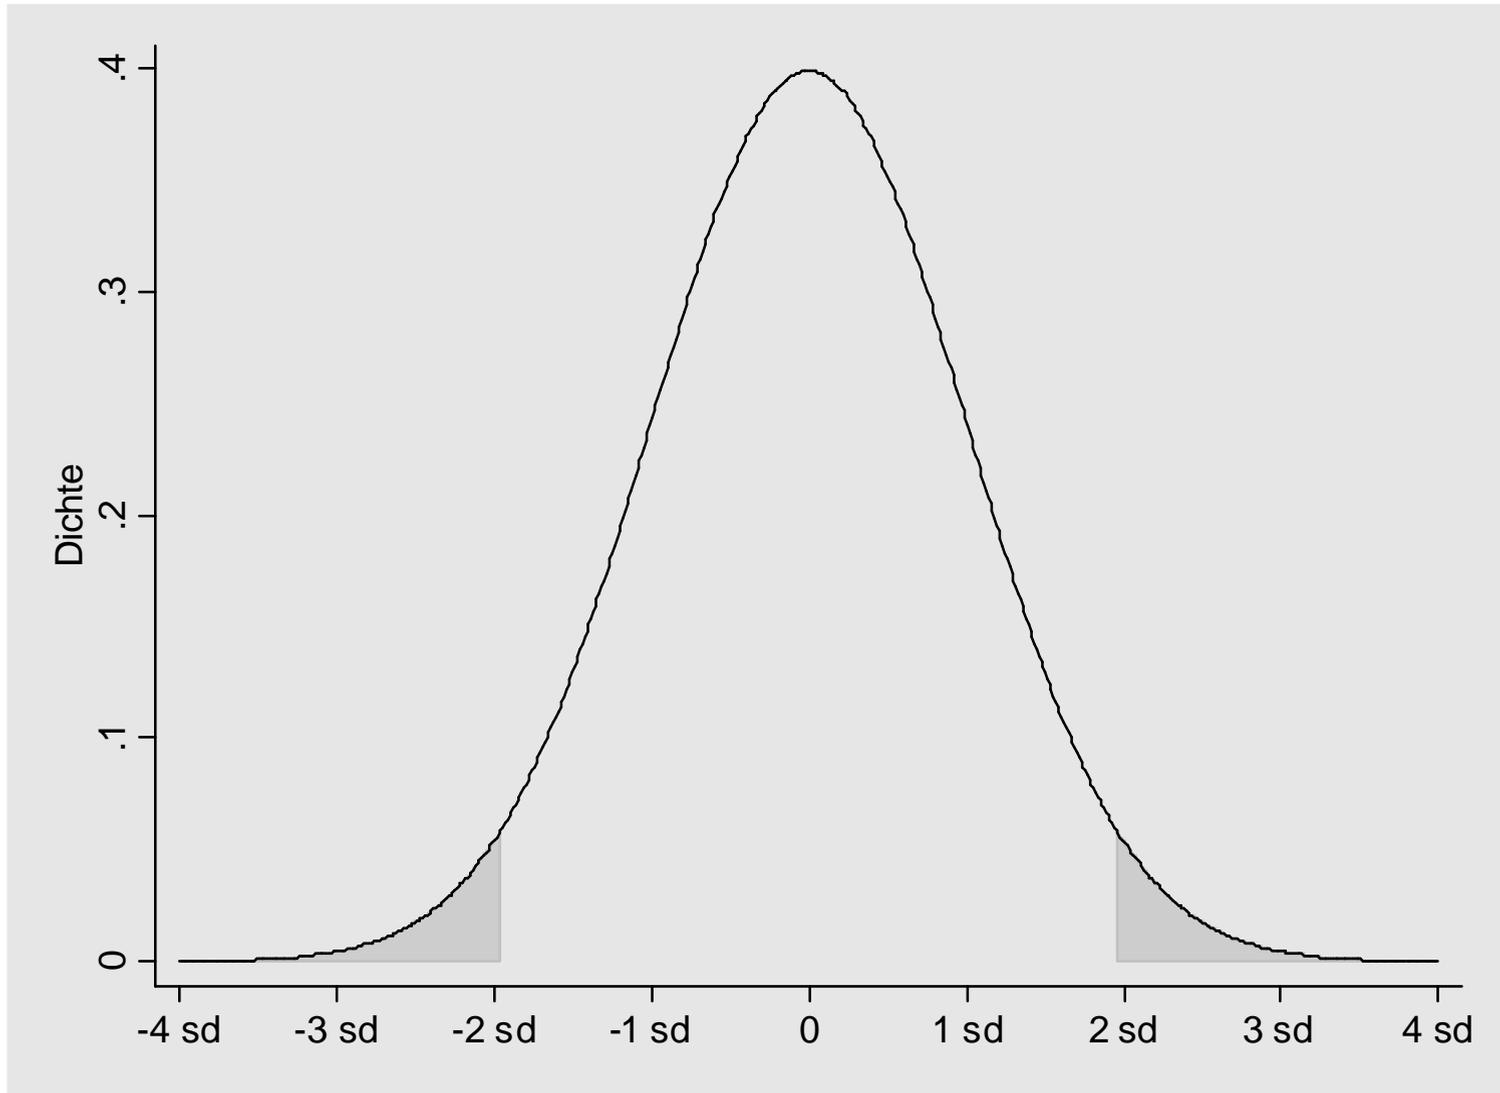
Stochastische Komponente

- `graph twoway (scatter pwbcdu71 pkathv70) (lfit pwbcdu71 pkathv70), xline(85.1)`
- Reale Werte weichen vom erwarteten Wert ab
- Ergänzung des Modells um eine Zufallsvariable: $y = a + b \cdot x + e$
- Erfasst *alle* unsystematischen (nicht modellierten) Einflüsse auf y

Stochastische Komponente

- Zufallsvariable \cong Ziehung (mit Zurücklegen) aus einer Verteilung
- Jedes e wird gezogen aus einer Normalverteilung
 - mit beliebiger Streuung
 - und einem Mittelwert von null
 - Die Ziehungen sind unabhängig voneinander und nicht vom Wert von x beeinflußt
- Normalverteilung
 - enthält viele Werte nahe dem Mittelwert
 - wenige Werte, die stark vom Mittelwert abweichen
 - sinnvolles Modell für das additive Zusammenwirken von vielen zufälligen Einflüssen

Normalverteilung



Annahmen des Regressionsmodells (Auswahl)

- x hat linearen Einfluß auf erwarteten Wert von y [systematische Komponente]
- y -Werte streuen um erwarteten Wert [stochastische Komponente]
- Dieser unsystematische Einfluß wird durch eine Zufallsvariable e modelliert
- e wird manchmal auch als „Fehler“ bezeichnet

Annahmen (Auswahl)

- Für e gilt
 - e ist normalverteilt
 - Für jede Ausprägung der unabhängigen Variablen ist der erwartete Wert von $e=0$
 - zwischen e und den unabhängigen Variablen besteht keine Korrelation
 - Die Varianz von e ist für jede Ausprägung der unabhängigen Variablen konstant (Homoskedastizität)
 - Die Ausprägung von e bei einem Fall hat keinen Einfluß auf die Ausprägung von e bei irgendeinem anderen Fall (keine Autokorrelation des Fehlers)

Linear Regression

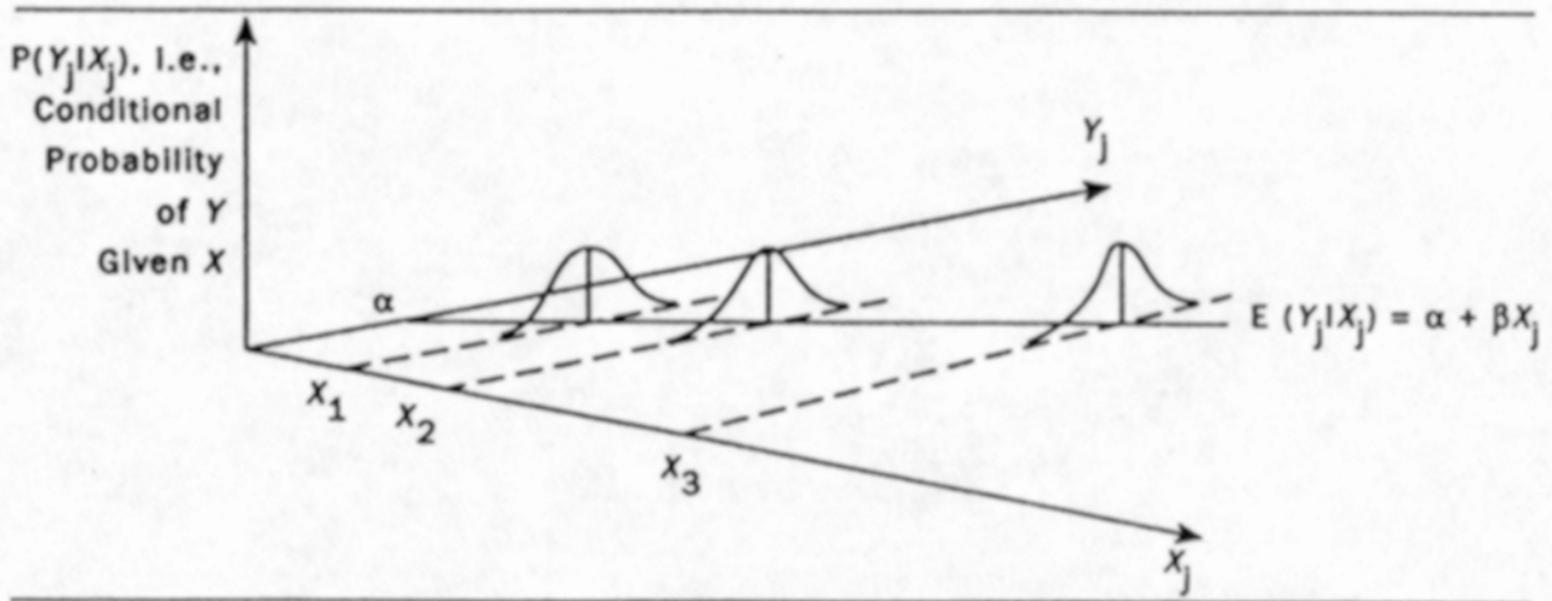


Figure 2.2. Regression Assumptions for a Bivariate Model

Bestimmung der Parameter

- Gesucht werden Parameter, die
 - die Summe der quadrierten Abweichungen zwischen beobachteten und erwarteten Werten minimieren
 - d.h. die Gerade optimal in die Punktwolke einpassen
 - Lineare Regression wird deshalb auch als OLS („Ordinary Least Squares“) bezeichnet
- Berechnung
 - von Hand: Abweichungsprodukte und Quadrate
 - Computer benutzt intern Matrix-Algebra
 - äquivalent, funktioniert auch mit mehreren unabhängigen Variablen
- Stata-Kommando: `whelp reg`

Lineare Regression

- Zur Veranschaulichung kann man sich vorstellen, daß die beobachteten y -Werte durch einen Daten Generierenden Prozeß (DGP) zustande kommen
- Ein y -Wert entsteht durch das additive Zusammenwirken eines gegebenen x -wertes und eines zufälligen e -wertes

Simulation

- use z: \daten\regsim,replace
- enthält 10.000 „Fälle“
- x: linkssteile Variable mit Mittelwert von 4 und sd von 2,8 (graph hist x)
- Normalverteilte Zufallsvariable:
 - gen e=20*invnorm(uniform())
 - summ e oder graph hist e,normal
- y erzeugen: $\text{gen } y = 5 + 2.3 * x + e$

Simulation

- Parameter des Modells per Regression bestimmen: `reg y x`
- vorhergesagte Werte
 - `predict yhat`
 - `summ yhat y`
 - Vergleich mit Sum of Squares
- Residuen:
 - `predict r, resid`
 - `summ r e`

R-Quadrat

- Gibt an, wieviel Prozent der Gesamtvarianz von y auf die systematische Komponente des Modells zurückgehen
- Oft als „Maß der Modellgüte“ oder ähnliches bezeichnet
- Tatsächliche Bedeutung meist überschätzt
- Wert hängt von den Varianzen in der Stichprobe ab, kann deshalb nicht über Stichproben hinweg verglichen werden

R-Quadrat

- use `z: \daten\regsim2,replace`
- `graph twoway (scatter y x) (lfit y x)`
- `reg y x`
- `graph twoway (scatter y x) (lfit y x)`
`if x > 14 & x < 17`
- `reg y x if x > 14 & x < 17`

R-Quadrat

- Mit Aggregatdaten läßt sich sehr leicht ein hohes R-Quadrat erreichen, da die nicht erklärte Varianz auf der Individualebene ignoriert wird
- Beispiel
 - use z: \daten\elecstudies,replace
 - reg ca relig
 - collapse ca relig,by(var003)
 - scatter ca relig
 - reg ca relig
 - Das Modell ist nicht besser (im Gegenteil), aber R^2 ist fast dreimal größer

Multiple lineare Regression

- Oft ist es plausibel anzunehmen, daß
 - mehrere unabhängige Variable parallel auf eine abhängige Variable wirken
 - diese Einflüsse additiv zusammenwirken
- $y = a + b_1 * x_1 + b_2 * x_2$
z.B.
 $SPD75 = a + b_1 * KATH70$
 $+ b_2 * ARB70$

Multiple lineare Regression

- Koeffizienten (b_1, b_2 etc.) beschreiben, welche Veränderungen der abhängigen Variablen zu erwarten ist, wenn die entsprechende unabhängige Variable variiert und *alle anderen unabhängigen Variablen konstant gehalten werden*
- Konstante gibt den erwarteten Wert der abhängigen Variablen an, wenn alle unabhängigen Variablen gleich null sind (nicht immer sehr anschaulich; evtl. unabhängige Variablen zentrieren)

Warum multiple Regression?

- Soziale Phänomene lassen sich selten auf eine einzige Ursache zurückführen
- Bei bivariater Betrachtung können „Scheinkorrelationen“ auftreten
- `use z: \daten\regsim3,replace`
- `reg kons alter`
 - Mit jedem Lebensjahr nimmt der erwartete Konservatismuswert um 0.25 Punkte zu
 - je älter, desto konservativer
 - `scatter kons alter`

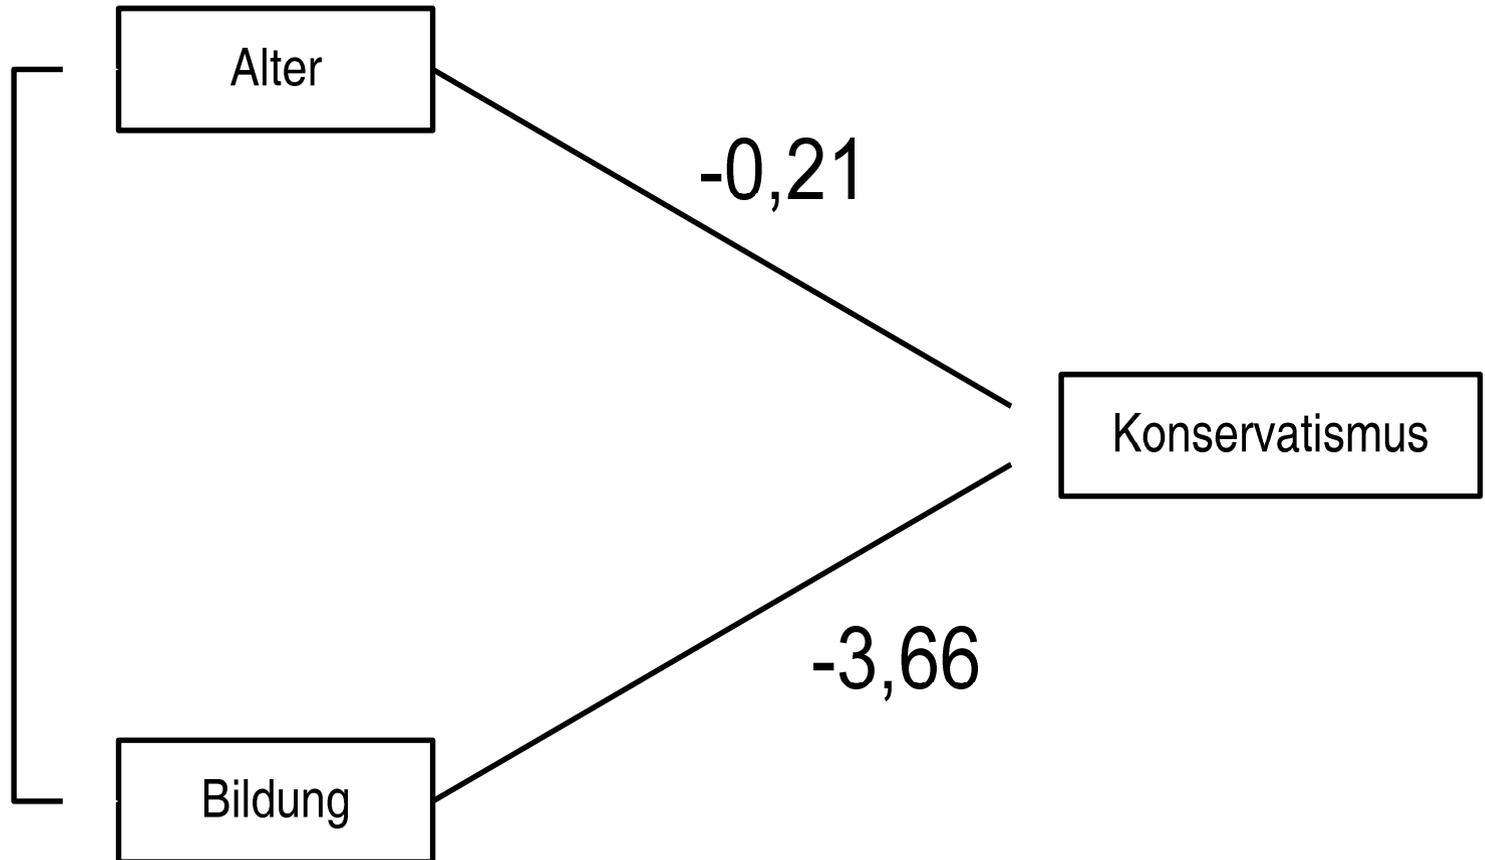
Modell 1



Warum multiple Regression?

- Zusammenhang zwischen Alter und Konservatismus kommt eventuell durch niedrigere Bildung der älteren Befragten zustande
 - scatter kons alter if bildung > 10
 - reg kons alter if bildung > 10
- Systematisch:
 - reg kons alter bildung
 - Simultane Schätzung unter wechselseitiger Kontrolle der Einflußfaktoren

Modell 2



Warum multiple Regression?

- Das bedeutet:
 - Bildung hat „in Wirklichkeit“ (d.h. bei Kontrolle des Alters) einen stärker negativen Einfluß auf Konservatismus als zunächst erkennbar
 - Für jede beliebige Altersgruppe nimmt der erwartete Konservatismus-Wert pro Punkt auf der Bildungsskala um 3,7 Punkte ab
 - Der Einfluß des Alters ist in „Wirklichkeit“ (bei Kontrolle der Bildung) schwach negativ!
 - Für jede beliebige Bildungsgruppe nimmt der erwartete Konservatismus-Wert pro Lebensjahr um 0,21 Punkte ab
 - Bei niedriggebildeten jungen sind die höchsten, bei hochgebildeten älteren Bürgern die niedrigsten Werte zu erwarten
 - Koeffizienten beziehen sich auf „natürliche“ Einheiten. Durch Standardisierung können Koeffizienten eventuell leichter vergleichbar gemacht werden (,beta)

Warum multiple Regression?

- Parameter verzerrt, wenn relevante Variable nicht im Modell enthalten
- → Weitere Anwendungsvoraussetzungen
 - unabhängige Variablen müssen tatsächlich *additiv* zusammenwirken
 - alle unabhängigen Variablen, die einen nennenswerten systematischen Einfluß auf y haben, müssen im Modell enthalten sein
 - außer wenn die unabhängigen Variablen untereinander unkorreliert (orthogonal) sind

Orthogonalität

- Bei experimentellen Designs werden die unabhängigen Variablen von den Forschern *gesetzt*
- Bei zufälliger Aufteilung auf die Versuchsgruppen keine Korrelationen zwischen unabhängigen Variablen und keine Hintergrundvariablen, die deren Ausprägung beeinflussen

Orthogonalität

Horrorfilm

Alkohol	0	1	Total
0	10	10	20
1	10	10	20
Total	20	20	40

Kollinearität

- Bei Umfragedaten (ex-post-facto Design) in der Regel Korrelation zwischen unabhängigen Variablen
- Manche Kombinationen von Ausprägungen erstens nicht beobachtet, zweitens empirisch unplausibel/unmöglich (angelernter Arbeiter mit Hochschulabschluß)
- Lineare Beziehungen zwischen den unabhängigen Variablen werden als (Multi-) Kollinearität bezeichnet
- Typisch für Umfragedaten z.B. enge Beziehungen zwischen Schulabschluß, Beruf, Einkommen und politischen Einstellungen
- Moderate Kollinearität in Regressionsmodellen ist unproblematisch

Perfekte Kollinearität

- $x_1 = a + b * x_2 \mid R^2 = 1$
- Fehler
 - Intrinsische Beziehung zwischen zwei Variablen
z.B. Geburtsjahr und Alter in Jahren (bei einer Querschnittsbefragung)
 - Bei Dummies: Referenzkategorie durch zusätzlichen Dummy repräsentiert
 - Interaktionseffekte
- Zahl der Fälle < Zahl der Variablen
- Konsequenz: Keine eindeutige Lösung für Regressionsgleichung:
$$y = a + 1 * x_1 + 0 * x_2 \Leftrightarrow y = a + 0 * x_1 + 1 * x_2$$

Hohe Kollinearität

- $x_1 = a + b \cdot x_2 \mid R^2 = > 0.9$
- Interpretationsprobleme: Kann man sich überhaupt vorstellen, daß die übrigen Variablen konstant gehalten werden?
- Standardfehler werden sehr groß = Schätzung schwanken sehr stark über Stichproben hinweg
- Die Schätzungen für den Koeffizienten einer Variablen werden davon beeinflusst, welche anderen Variablen im Modell enthalten sind

Kollinearität

- Diagnose
 - Regression einer unabhängigen Variable auf eine (Kollinearität) oder *alle* (Multikollinearität) anderen unabhängigen Variablen
 - $1-R^2$ =tolerance; Faustregel $\text{tol} > 0.1$
 - $1/\text{tol.} = \text{VIF}$; Faustregel $\text{VIF} < 10$
 - In Stata:
 - `corr alter bildung`
 - `vif` (nach Regressionsbefehl)
- Maßnahmen
 - Alternative Kodierung (bei Interaktionseffekten)
 - Mehr Fälle, möglichst mit „ungewöhnlichen“ Kombinationen der unabhängigen Variablen
 - (theoretisch begründeter) Ausschluß von unabhängigen Variablen
 - Zusammenfassung der hochkorrelierten Variablen zu einem Index/Faktor
 - Fortgeschrittene Methoden

Hausaufgabe

- Erzeugen Sie unter Verwendung von `muster.do` eine lauffähige Datei `rpregression.do`, die
 - den Datensatz `z:\daten\rpstrukt.dta` lädt
 - Ein Regressionsmodell für den Einfluß von Arbeiter- und Katholikenanteil (Volkszählung 1970) auf das Abschneiden der SPD 1975 rechnet
 - eine Grafik erzeugt, die – getrennt für Kreise mit niedrigem ($<54\%$) und hohem ($\geq 54\%$) Katholikenanteil einen Scatterplot und eine Schätzgerade für die Beziehung SPD 1975 vs. Arbeiter 1970 überlagert
- Schicken Sie die Datei bis zum 23.06. an do-files@politik.uni-mainz.de. Verwenden Sie das gewohnte Schema