

Querschnittsdatenanalyse: Angewandte Regressionsanalyse mit STATA

Prof. Dr. Josef Brüderl
Wintersemester 2018/19

This presentation is licensed under a CC-BY-NC 4.0 license.
You may copy, distribute, and use the slides in your own work, as long
as you give attribution to the original author on each slide that you use.
Commercial use of the contents of these slides is not allowed.



BY

NC

Inhalt

1. Kausalität in den Sozialwissenschaften	06
2. Explorative Datenanalyse	31
3. Einführung in die Regression	39
4. Das multiple lineare Regressionsmodell	58
5. Interpretation von Regressionskoeffizienten	77
6. Regression mit Dummies	86
7. Interaktionseffekte	93
8. Regressionsdiagnostik	107
9. Maximum-Likelihood	120
10. Logistische Regression	132
11. Multinomiales Logit	160
12. Ordinales Logit	174
13. Ausblick/Literatur	186

Lernziele

- Kenntnis verschiedener Querschnitts-Regressionsmodelle
 - Keine Herleitungen, keine Berechnungen per Hand
 - Sondern ein anwendungsorientierter Überblick
- Darstellung und Interpretation der Regressionsergebnisse
 - Insbesondere die graphische Darstellung der Regressionsergebnisse wird betont („Das Zeitalter der Regressionstabelle ist vorbei“)
- Interpretation von Interaktionen
 - Selbst im linearen Modell wird hier viel falsch gemacht
 - Bei nicht-linearen Modellen ist es noch komplizierter
- Praktische Umsetzung der Regressionsmodelle mit STATA
 - Die grundlegenden STATA-Befehle sind in den Folien enthalten
 - Zusätzlich kann man anhand der begleitenden STATA Do-Files die Berechnungen nachvollziehen

ALLBUS 2002

- Bevölkerungsumfrage alle 2 Jahre seit 1980 (N ~ 3.000)
 - Von GESIS als Service für die Sozialforschung
 - Trenddaten
- ALLBUS 2002 (N=2.820)
 - Einwohnermelderegisterstichprobe
 - Ostdeutsche überrepräsentiert
 - GG: alle deutschsprachigen Personen über 18, wohnhaft in D in Privathaushalten
 - Ausschöpfung: 47%
 - Mündliches Interview (CAPI)
 - Infos: <http://www.gesis.org/allbus>

ALLBUS 2002: Datenaufbereitung

- Für den Kurs wurden einige Variablen aufbereitet
 - Abgespeichert im Datensatz: **AllbReg.dta**
- Abhängige Variablen
 - eink: monatliches Nettoeinkommen in Euro
 - rechts: Links-Rechts Selbsteinstufung (Skala 1-10)
 - arblo: Arbeitslosigkeit in den letzten 10 Jahren (0=nein, 1=ja)
 - partei: Wahlabsicht (CDU, SPD, FDP, Grüne, PDS)
 - oecdeink: Nettoäquivalenzeinkommen in Euro
- Unabhängige Variablen
 - bild: schulische und berufliche Bildung in Jahren
 - alter: Alter in Jahren
 - exp: Berufserfahrung (Berechnung: $\text{alter} - \text{bild} - 6$)
 - prestv: Berufsprestige des Vaters (Magnitude-Skala)
 - frau: Dummy für Frau
 - ost: Dummy für Ostdeutscher
 - beruf: berufliche Stellung (Arbeiter, Angest., Beamter, Selbst.)

Daten: ALLBUS 2002 Do-File: 00 Datenaufbereitung.do
--

Kapitel 1:

Kausalität in den Sozialwissenschaften




Ziele empirischer Sozialforschung


- Beschreibung (Deskription)
 - Die genaue Beschreibung der sozialen Welt kommt zuerst
 - „It is a capital mistake to theorize in advance of the facts“
(Warnung von Sherlock Holmes an Dr. Watson)
- Erklärung
 - Hat man die Fakten geklärt, kann man nach den Ursachen fragen
 - Dies ist die Suche nach Kausaleffekten (Kausalanalyse)
- Politikberatung
 - Hat man Fakten und kausale Zusammenhänge, so kann man politische Maßnahmen empfehlen
 - Dazu benötigt man aber Vorstellungen über den Soll-Zustand (politisches Ziel). Da dies normativ ist, nicht Teil der Wissenschaft.
 - Bsp.: Anstieg der Einkommensungleichheit
 - In welchen Einkommensgruppen verändert sich was?
 - Dann kann man nach den Ursachen fragen
 - Dann kann man politische Maßnahmen empfehlen

Kausaldiagramme (DAGs)

- Knoten: beobachtete Variable
- Offener Knoten: latente Variable
- Gerichtete Kante:
Kausalbeziehung
- Bidirektionale Kante:
Assoziation durch gemeinsame latente Ursache („confounder“)



- Die drei grundlegenden Muster der Kausalbeziehung dreier Variablen
 - Intervenierende Variable
 - Konfundierende Variable
 - Collider Variable



Was ist Wissenschaft?

- Ziel: Wissenschaft will Wissen schaffen
 - Nicht nur moralisieren und/oder politisieren
- Methode I:


Lee Smolin, Professor für theoretische Physik

“[W]ir müssen darauf bestehen, sie [die Ideen] testen – oder falsifizieren – zu können. Darauf beruht der Fortschritt der Wissenschaft in den vergangenen 400 Jahren. Wenn man eine theoretische Struktur hat, die nichts erklärt und nichts vorhersagt, hört man auf, Wissenschaft zu betreiben. Dann haben wir es mit der Gefahr von nicht überprüfbaren Theorien [...] zu tun.


- Methode II: Konsequentes Anzweifeln aller Ergebnisse (auch der eigenen!)
(aus: Richtlinien der LMU München zur Selbstkontrolle in der Wissenschaft)

Theorie

- Kausalanalysen basieren auf Theorien
 - Eine “Theorie” ist eine Menge von miteinander verknüpften und logisch konsistenten Aussagen, von denen eine nichtleere Teilmenge empirisch prüfbare Aussagen (Hypothesen) sind



- Das Geschäft der (kausalanalytischen) Sozialforschung ist die empirische Überprüfung der Gültigkeit von (aus Theorien abgeleiteten) Hypothesen
 - Z.B.:



Exkurs: Mängel soziologischer Theorien

- Viele soziologische Theorien sind allerdings wissenschaftlich unfruchtbar
 - Oft ist unklar, welche theoretischen Konzepte eigentlich eine wesentliche Rolle spielen
 - Viele Theorien sind zu ungenau, um falsch zu sein
 - Viele Theorien lassen keine Herleitung von empirisch überprüfbaren Hypothesen zu, weil sie u.a. Konstrukte verwenden,
 - welche keine Entsprechung in der Realität haben
 - und/oder kaum operationalisier- und messbar sind


Empirische Überprüfung I

- DIE wissenschaftliche Methode: das Experiment
 - Versuchs- und Kontrollgruppe
 - Randomisierung
 - Dadurch unterscheiden sich Versuchs- und Kontrollgruppe nicht
 - Keine unbeobachtete Heterogenität
 - Kontrollierte Stimulussetzung durch Forscher
 - Damit ist sichergestellt, dass die uV der aV zeitlich vorgeht
 - Keine Endogenität
- Ein sauber durchgeführtes Experiment erlaubt einen sicheren Kausalschluss
- Experimente sind aber in den Sozialwissenschaften oft nicht praktikabel

Empirische Überprüfung II

- Deshalb erhebt man oft Daten über X und Y ex-post-facto und berechnet deren Korrelation
- **Korrelation ist aber nicht gleich Kausalität**
 - Es könnte auch eine „Scheinkorrelation“ vorliegen (s.u.)
- Um von einer Korrelation auf Kausalität schließen zu können, müssen folgende Bedingungen gelten:
 - X und Y sind korreliert
 - X geht Y zeitlich voran (keine Endogenität)
 - Die Korrelation von X und Y bleibt erhalten, auch wenn man für dritte Variablen kontrolliert (keine unbeobachtete Heterogenität)

Korrelation ist nicht gleich Kausalität




<https://xkcd.com/552/>

Das Problem: Selbstselektion

- Bei einem Experiment werden die Vpn vom Forscher den beiden Gruppen per Randomisierung zugewiesen
- Bei ex-post facto Designs überlässt man es den Personen selbst, in welche Gruppe sie gehen (Selbstselektion)
- Das führt leicht zu unbeobachteter Heterogenität
- **Selbstselektion ist das allgegenwärtige methodische Problem in der Sozialforschung!**
 - Beispiele, bei denen dieses Problem nicht bedacht wurde und die so (oder ähnlich) in Studien berichtet wurden und werden(!)
 - Ehemänner leben länger
 - Ehemänner verdienen mehr
 - Ärmere Menschen leben kürzer
 - Bewohner von Betonblöcken sind häufiger krank
 - Häufiges Fernsehen auf Privatsendern macht dumm
 - Zähneputzen senkt das Herzinfarktrisiko

Folge: Scheinkorrelation/Konfundierung

- X und Y korrelieren zwar, aber Grund hierfür ist eine dritte Variable Z, die sowohl X als auch Y kausal verursacht
 - Die Korrelation ist „echt“, aber die Kausalität ist „scheinbar“ (Scheinkausalität)
- Schematisch anhand eines DAG



- Z ist eine „antezedierende“ Variable (Drittvariable, Confounder)
- Durch die beiden Kausaleffekte entsteht eine Korrelation von X und Y
- Es wäre ein Fehler diese Korrelation als kausal zu interpretieren

- Durch Kontrolle von Z (Drittvariablenkontrolle) kann man das Problem beheben

Drittvariablenkontrolle


- Z.B. mittels konditionaler Kreuztabellen (Partialtabellen)
 - Z wird konstant gehalten: Für jede Ausprägung von Z wird eine eigene Kreuztabelle ($X \times Y$) erstellt (dreidimensionale Kreuztabelle)
 - Damit erhält man für jede Ausprägung von Z einen eigenen, konditionalen Korrelationskoeffizienten:

$$r_{XY \cdot Z_1}, r_{XY \cdot Z_2}, \text{ usw.}$$

- Die messen die Korrelation von X und Y unter Kontrolle von Z
 - Damit ist Z jeweils konstant und kann nicht mehr die Ursache für eine eventuelle Korrelation von X und Y sein
 - Sind die konditionalen Korrelationskoeffizienten ungleich Null, so können wir von Kausalität ausgehen
- Problem: es kann mehrere Drittvariablen geben
 - Lösung: multivariate Analyseverfahren (Regression)
- Regression hat in der Sozialforschung eine zentrale Rolle:
Sie ist der Ersatz für das Experiment

Bsp.: Macht Homöopathie gesund?


Gesundheitszustand Befragter nach Homöopathieerfahrung



Quelle: Idee von Stefanie Heyne
Daten: Allbus 2012
Do-File: 00a Homoeopathie

Bsp.: Macht Homöopathie gesund?

- Dieser Zusammenhang ist evtl. eine Scheinkorrelation
 - Zwei potentielle Confounder: Bildung und Alter



Bsp.: Macht Homöopathie gesund?

	(1)	(2)	(3)
Erfahrung mit homoe	0.129*** (0.035)	-0.002 (0.035)	-0.029 (0.033)
Niedr. Bildung (Ref.)			
Mittlere Bildung		0.390*** (0.040)	0.196*** (0.040)
Hohe Bildung		0.673*** (0.043)	0.438*** (0.043)
Alter			-0.017*** (0.001)
_cons	3.491***	3.194***	4.185***
N	3419	3419	3419
R-sq	0.004	0.073	0.148
Standard errors in parentheses			
* p<0.05, ** p<0.01, *** p<0.001			

Daten: Allbus 2012
 Do-File: 00a Homoeopathie



Abhängige Variable: Gesundheitseinschätzung 1 - 5

Methoden der Kausalanalyse

- „Selection on observables“: Confounder gemessen
 - Man kann für sie kontrollieren
 - Regression (1. Sem.: „Querschnittsdatenanalyse“)
 - Matching (3. Sem.: „Kausalanalyse“)
- „Selection on unobservables“: Confounder nicht gemessen
 - Regressions- und Matching-Schätzer sind verzerrt
 - Unbeobachtete Heterogenität, „omitted variable bias“
 - Unverzerrte Schätzer kann man erhalten mit
 - Instrumentalvariablen Ansatz (3. Sem.: „Kausalanalyse“)
 - Exogene Variation identifiziert den Kausaleffekt
 - Regression Discontinuity Ansatz (3. Sem.: „Kausalanalyse“)
 - Homogenität von Personen an einer Schwelle
 - Within-Panelanalyse (2. Sem.: „Längsschnittdatenanalyse“)
 - Homogenität einer Person über die Zeit

Mediation

- Bei Konfundierung ist Z „antezedierend“ (zeitlich vor X und Y)
- Ist Z intervenierend (zeitlich zwischen X und Y), so liegt eine Mediation vor (auch „Intervention“ genannt)
- Eine Mediation ist im Unterschied zur Konfundierung kein Problem der Kausalanalyse, sondern der 2. Schritt
 - Z ist ein „kausaler Mechanismus“
 - Man weiß nun, wie der Kausaleffekt von X auf Y zustande kommt



- (Totaler) Kausaleffekt: a
- Direkter Kausaleffekt: b
- Indirekter Kausaleffekt: $c \cdot d$
- Es gilt: $a = b + c \cdot d$
- Kausalanalyse
 - 1. Schritt: schätze den totalen KE
 - 2. Schritt: kontrolliere für Z
 - $b < a$: Z ist ein Mechanismus

Beispiel: Kirchgangshäufigkeit


- Mit dem ALLBUS 1994 untersuchen wir, wie sich der Wohnort (West/Ost) auf den Kirchgang auswirkt

Kirchgang nach Wohnort			$V = 0,28$
	West	Ost	
Selten/nie	55%	84%	
Öfter	45%	16%	
N	2339	1104	

- Könnte „Konfession“ ein intervenierender Mechanismus sein? Deshalb kontrollieren wir für Konfession ($2 \times 2 \times 3$ -Tabelle)

Kirchgang nach Konfession und Wohnort						
	Katholiken		Protestanten		Konfessionslose	
	West	Ost	West	Ost	West	Ost
Selten/nie	42%	38%	61%	59%	93%	97%
Öfter	58%	62%	39%	41%	7%	3%
	$V = 0,01$		$V = 0,01$		$V = 0,07$	

Beispiel: Kirchgangshäufigkeit



Beispiel: Kirchgangshäufigkeit


- Um den Kausalmechanismus ganz zu verstehen, erstellen wir noch die Kreuztabellen $X \times Z$ und $Z \times Y$

Konfession nach Wohnort		
	West	Ost
Katholik	47%	3%
Protestant	41%	26%
Konfessionsl.	12%	71%

$V = 0,62$

Kirchgang nach Konfession		
	selten	öfter
Katholik	41%	59%
Protestant	60%	40%
Konfessionsl.	96%	4%

$V = 0,46$



Das gesamte Kausalmodell präsentieren wir übersichtlich in einem „Pfaddiagramm“. An die Pfeile schreiben wir die bivariaten Korrelationskoeffizienten. Die konditionalen Korrelationskoeffizienten von „Wohnort“ auf „Kirchgang“ sind fast null und machen deutlich, dass hier praktisch kein direkter Kausaleffekt vorliegt. „Konfession“ ist der kausale Mechanismus, der den KE von „Wohnort“ auf „Kirchgang“ vollständig erklärt.

Extrem: Suppression

- Falls der indirekte Effekt ein anderes Vorzeichen hat, als der direkte Effekt, fällt der totale Effekt kleiner aus

$$a = b + c \cdot d$$

- In extremen Fällen ist der totale Effekt gar nahe Null (verdeckte Korrelation, Suppression)
 - Oder hat gar das entgegengesetzte Vorzeichen
- Bsp.: Diskriminierung von Frauen bei der Studienzulassung?

- Aus: Krämer, Walter (1995)
Denkste! Campus-Verlag
 - Fiktives Beispiel

	M	F	Σ
nicht zugel.	400	450	850
zugela ssen	100 (20%)	50 (10%)	150
Σ	500	500	1000

$$\Phi = (-) 0.14$$

Beispiel: Studienzulassung

Kontrolliert man für die intervenierende Variable „Studienfach“ verschwindet der Effekt: es gibt nur einen schwachen direkten Effekt.

	Mathe		
	M	F	Σ
nicht zug.	100	10	110
zug.	80 (44%)	10 (50%)	90
Σ	180	20	200
$\Phi = (+) 0.03$			

	SoWi		
	M	F	Σ
nicht zug.	300	440	740
zug.	20 (6%)	40 (8%)	60
Σ	320	480	800
$\Phi = (+) 0.04$			

Beispiel: Studienzulassung

Frauen bewerben sich
häufiger für Sowi

	M	F	Σ
Mathe	180	20	200
Sowi	320	480	800
Σ	500	500	1000


$$\Phi = (+) 0.40$$

Sowi hat niedrigere
Zulassungsquoten als Mathe

	Mathe	Sowi	Σ
nicht zug.	110	740	850
zug.	90	60	150
Σ	200	800	1000


$$\Phi = (-) 0.42$$

- Der direkte Effekt ist Null
- Der indirekte Effekt ist negativ
- Deshalb ist der totale Effekt negativ
- Der totale Effekt wird vollständig durch die Studienfachwahl erklärt
 - Es gibt keine Diskriminierung



Moderation (Interaktion)

Die Beziehung von X und Y fällt unterschiedlich aus, je nachdem welchen Wert Z annimmt (Z heißt auch „Moderator“)



Beispiele:


- Sport (X), Gesundheit (Y), Erkältung (Z)
- Einsatz (X), Erfolg (Y), Motivation (Z)

Beispiel: M. Halbwachs (1930) Les Causes du Suicide

Halbwachs stellte fest, dass es einen Zusammenhang zwischen Konfession und Selbstmordrate gibt: Katholiken 19,9 Selbstmorde (pro 100.000), Protestanten 39,6 Selbstmorde (pro 100.000). Kontrolliert man den Wohnort, so verschwindet der Zusammenhang für Städte, auf dem Land wird er stärker.

Wohnort	Katholik	Protestant
Stadt	39,9	37,8
Land	8,8	41,4
Alle	19,9	39,6

Beispiel: Arbeitslosigkeit in Abhängigkeit von Bildung

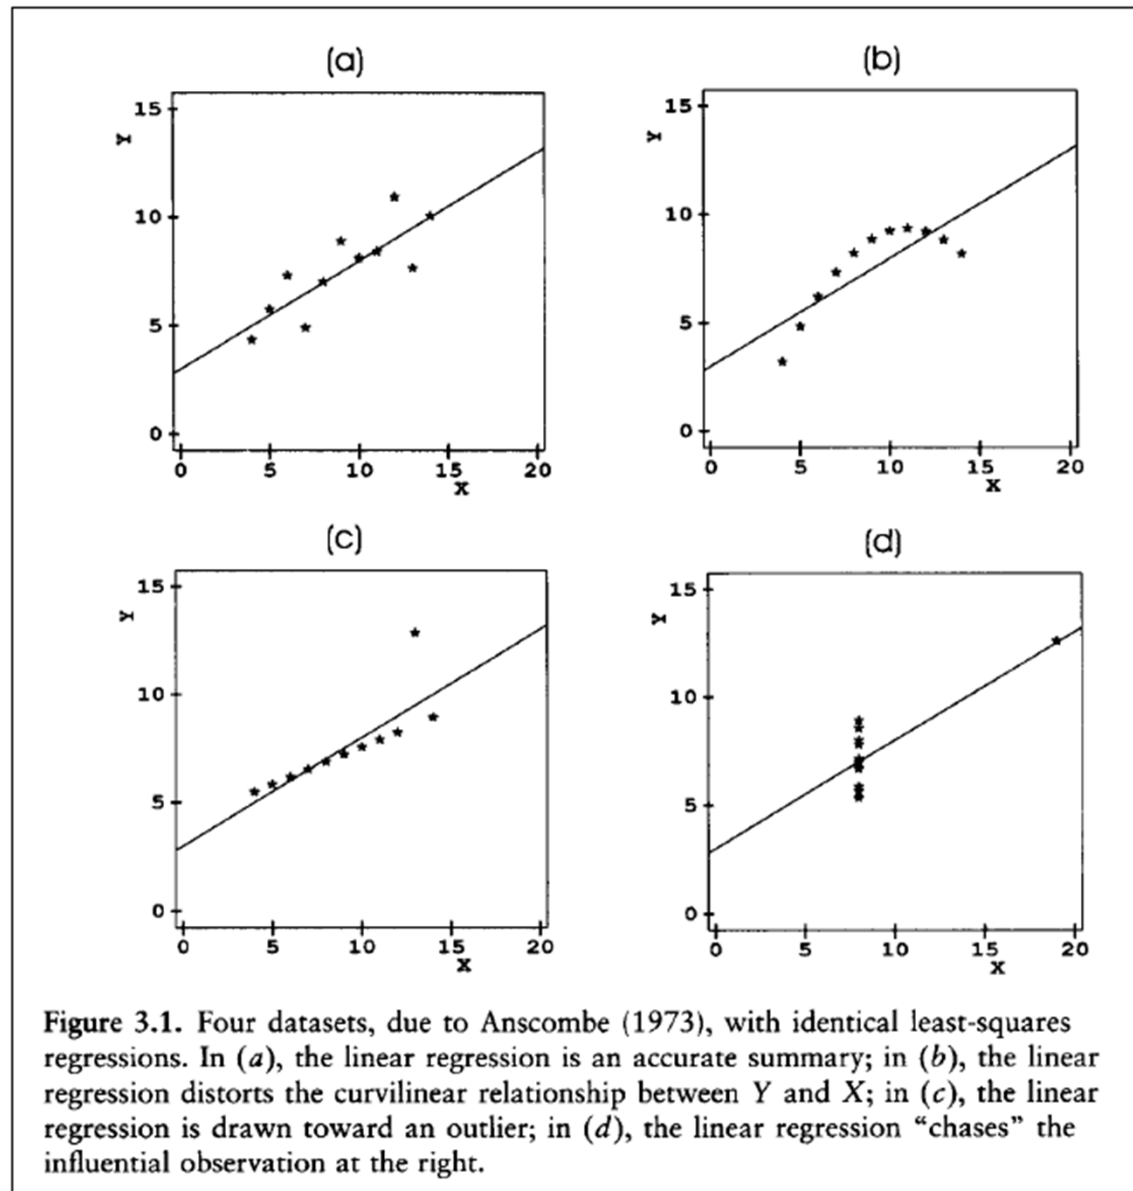


Kapitel 2:

Explorative Datenanalyse




Anscombes Quartett



Univariate Verteilungen

Bsp.: Armut in Deutschland



* Gruppiertes Boxplot West/Ost
`graph box oecdeink, over(v3)`



	West	Ost
Armutsgrenze (60% Median)	682	575
Armutsquote	15,9%	12,1%

Daten: ALLBUS 2002
 Do-File: 00b Armut.do

Beispiel: Armut in Deutschland





Eingezeichnet sind die Armutsgrenzen

Daten: ALLBUS 2002
Do-File: 00b Armut.do

Bivariate Verteilungen: Scatterplot

- Bivariate Zusammenhänge veranschaulicht man am besten mit einem Streudiagramm
 - Überdecken sich die Daten stark, so, „jittered“ man am besten
 - Einen Eindruck von der Art des Zusammenhangs bekommt man mittels einer nicht-parametrischen Regression. Bewährt hat sich hierfür der Lowess-Smoother (locally weighted scatterplot smoother).
 - An der Stelle x_i wird eine lineare Regression berechnet, in die die Daten in der Umgebung gewichtet eingehen. Die Breite der Umgebung ist steuerbar durch „bandwidth“ (z.B. $\text{bwidth}=0.8$). Es wird trikubisch gewichtet. Anhand der Regressionsparameter wird dann \hat{y}_i berechnet. Dies wird für alle X-Werte gemacht. Die Verbindung der (x_i, \hat{y}_i) ergibt die Lowess-Kurve. Je kleiner die Umgebung, desto näher an den Daten ist die Kurve.

Bivariate Verteilungen: Scatterplot




- Beispiel: Einkommen in Abhängigkeit von Bildung
 - Nur Westdeutschland, max. 8 Tsd. Euro (N=1.468)
 - Links ist nicht gejittered, es kommt zu starker Überdeckung. Rechts ist gejittered („jitter(2)“: 2% der Zeichenfläche)
 - Die blaue Kurve ist der Lowess-Smoother
 - Links werden zur Berechnung jeweils 80% der Fälle in der Umgebung verwendet, rechts nur 30%. Die rechte Kurve folgt deshalb wesentlich genauer den Daten, ist dafür aber unregelmäßiger.
 - In beiden Fällen erkennt man kaum Nicht-Linearitäten

Daten: ALLBUS 2002
Do-File: 1 Regression.do


Exkurs: Datentransformationen

- Schiefe und Ausreißer sind für Regressionen ein Problem
- Durch Potenz-Transformationen kann man Schiefe reduzieren
- Tukeys “ladder of powers”




x^3	$q = 3$		produziert
$x^{1.5}$	$q = 1.5$	cyan	Rechtsschiefe
x	$q = 1$	schwarz	
$x^{.5}$	$q = .5$	grün	produziert
$\ln x$	$q = 0$	rot	Linksschiefe
$-x^{-.5}$	$q = -.5$	blau	


Beispiel: Einkommensverteilung



$q=1$



$q=0$



$q=-1$


Exkurs: Potenzfunktionen, ln und e

$$x^{0.5} = x^{\frac{1}{2}} = \sqrt[2]{x}, \quad x^{-0.5} = \frac{1}{x^{0.5}} = \frac{1}{\sqrt[2]{x}}, \quad x^0 = 1$$

Mit \ln notieren wir den (natürlichen) Logarithmus zur Basis $e = 2,71828\dots$:

$$y = \ln x \Leftrightarrow e^y = x$$

Daraus folgt $\ln(e^y) = e^{\ln y} = y$.



Rechenregeln

$e^x e^y = e^{x+y}$	$\ln(xy) = \ln x + \ln y$
$e^x / e^y = e^{x-y}$	$\ln(x/y) = \ln x - \ln y$
$(e^x)^y = e^{xy}$	$\ln x^y = y \ln x$


Kapitel 3:

Einführung in die Regression



Zum Begriff „Regression“

- Regression toward the mean:
„The stature of the adult offspring must on the whole, be more *mediocre* than the stature of their parents“
(Sir Francis Galton, 1889)
- Galton fittete (visuell!) eine Gerade
 - Sein Ergebnis: Steigung von 0,67
- Später wurde dies mit OLS gemacht und auf das Fitten von Geraden mit OLS der Begriff „Regression“ übertragen
 - OLS Ergebnis: Steigung von 0,64
- Die erste inhaltliche Anwendung prägte also den Begriff für ein statistisches Verfahren!




Galtons Daten mit Regressionsgerade
Quelle: Fahrmeir et al. (2007)

Das einfache Regressionsmodell

- Man formuliert folgendes lineare Modell des Zusammenhangs:

$$y_i = \alpha + \beta x_i + \varepsilon_i$$

- α und β sind die Regressionskoeffizienten
 - α : Achsenabschnitt, β : Steigung
 - β : um wie viel Einheiten ändert sich Y, wenn X um eine Einheit steigt
- ε_i ist der Fehlerterm (Abweichung der Daten von der Modellgerade)



OLS-Schätzer

- Man schätzt die Regressionskoeffizienten, indem man die Fehlerquadratsumme minimiert (ordinary least squares, OLS)

$$\min_{\alpha, \beta} \sum_{i=1}^n \varepsilon_i^2 = \min_{\alpha, \beta} \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$$

- Ableiten dieses Ausdrucks, Nullsetzen und Auflösen der beiden daraus resultierenden Gleichungen, liefert die OLS-Schätzer:


$$\hat{\alpha} = \bar{y} - \hat{\beta} \bar{x}$$

$$\hat{\beta} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{s_{XY}}{s_X^2} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}$$

- Die vom Regressionsmodell vorhergesagten Werte sind $\hat{y}_i = \hat{\alpha} + \hat{\beta} x_i$
- Die geschätzten Fehler (Residuen) sind damit $\hat{\varepsilon}_i = y_i - \hat{y}_i = y_i - \hat{\alpha} - \hat{\beta} x_i$

Beispiel

Abinote und Klausurerfolg



Das Bestimmtheitsmaß R^2

- Wie gut passt das Regressionsmodell auf die Daten?
- Die Grundidee ist: Welcher Anteil der Streuung von Y wird durch das Regressionsmodell „erklärt“?
- Streuungszerlegung

- Total sum of squares (TSS):

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

- Model sum of squares (MSS):

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


- Residual sum of squares (RSS):

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

- Die gesamte Streuung kann damit in zwei Teile zerlegt werden

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2$$
$$TSS = MSS + RSS$$

Graphische Interpretation der Streuungszerlegung




Das Bestimmtheitsmaß R^2

- Das Bestimmtheitsmaß ist nun definiert als


$$R^2 = \frac{\text{erklärte Streuung}}{\text{gesamte Streuung}} = \frac{MSS}{TSS} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

- Es gilt: $0 \leq R^2 \leq 1$
- R^2 lässt sich interpretieren als der Anteil der Varianz, der durch die Regressionsgerade (und damit durch X) erklärt wird
- Es gilt: $R^2 = r^2$


r und R²




$r = 1, R^2 = 1$ x



$r = -0.79, R^2 = 0.62$ x



$r = 0, R^2 = 0$ x



$r = 0, R^2 = 0$ x

Signifikanztest für $\hat{\beta}$

- $\hat{\beta}$ ist ein Schätzer
 - Mit einer Stichprobenverteilung
 - Und einem Standardfehler $\hat{\sigma}_{\hat{\beta}}$
- Damit kann man auch ein Konfidenzintervall schätzen
- Ebenso kann man einen Signifikanztest durchführen
 - Nullhypothese: X hat keinen Einfluss auf Y (kein Zusammenhang)
 $H_0: \beta = 0$
 - Die Teststatistik (t-Wert) ist

$$T = \frac{\hat{\beta}}{\hat{\sigma}_{\hat{\beta}}} \sim t(n-2)$$

- Die H_0 wird abgelehnt, falls $|T| > t_{1-\alpha/2}(n-2)$
 - Ab $n > 30$ das $z_{1-\alpha/2}$ Quantil (Faustregel für $\alpha=5\%$: $|T| > 2$)
- Können wir die H_0 verwerfen, so spricht man davon, dass X einen signifikanten Einfluss auf Y hat

Annahmen der Regression

- A1: Linearitätsannahme **(Linearität)**

$$y_i = \alpha + \beta x_i + \varepsilon_i, \quad i = 1, \dots, n$$

- A2: Im Mittel ist der „Fehler“ null

$$E(\varepsilon_i) = 0, \quad \text{für alle } i$$

- A3: Die Fehlervarianz ist konstant **(Homoskedastizität)**

$$V(\varepsilon_i) = \sigma^2, \quad \text{für alle } i$$

- A4: Die Fehlerkovarianzen sind null **(keine Autokorrelation)**

$$\text{Cov}(\varepsilon_i, \varepsilon_j) = 0, \quad \text{für alle } i \neq j$$

- A5: Regressor und Fehler sind unkorreliert **(Exogenität)**

$$\text{Cov}(x_i, \varepsilon_j) = 0, \quad \text{für alle } i \text{ und } j$$

- A6: Fehler normalverteilt (für Sig.tests) **(Normalverteilung)**

$$\varepsilon_i \sim N(0, \sigma^2)$$

Eigenschaften der OLS-Schätzer

- Bei Gültigkeit von A1 bis A5 haben die OLS-Schätzer gewisse wünschenswerte Eigenschaften: Sie sind
- unverzerrt (erwartungstreu): $E(\hat{\beta}) = \beta$
- in der Klasse der linearen, unverzerrten Schätzer die mit der kleinsten Stichprobenvarianz
 - best linear unbiased estimate (BLUE)
 - Gauß-Markov Theorem
- Dabei bedeutet:
 - „linear“: die Schätzer lassen sich als lineare Funktionen der Daten berechnen
 - „unbiased“: die Schätzer sind erwartungstreu
 - „best“: die Schätzer sind effizienter als alle anderen linearen Schätzer

Standardisierte Regressionskoeffizienten

- β hängt von der Maßeinheit von X und Y ab
- Um Vergleichbarkeit herzustellen, wählt man manchmal die Standardabweichung als Maßeinheit
 - Standardisierung von Y und X (Z-Transformation)

$$y_i^* = \frac{y_i - \bar{y}}{s_Y}, \quad x_i^* = \frac{x_i - \bar{x}}{s_X}$$

- Die Regressionsgleichung lautet nun

$$y_i^* = \alpha^* + \beta^* x_i^* + \varepsilon_i^*$$

- Für die standardisierten Regressionskoeffizienten ergibt sich

$$\hat{\alpha}^* = \bar{y}^* - \hat{\beta}^* \bar{x}^* = 0$$

$$\hat{\beta}^* = \frac{s_{X^*Y^*}}{s_{X^*}^2} = r$$

- Beispiel „Abinote und Klausurerfolg“: $r = -0,43$
 - Steigt die Note um eine Standardabweichung, so verringert sich die Punktzahl um 0,43 Standardabweichungen

Stata-Bsp.: Politische Einstellung auf Alter

```
. regress rechts alter if ost==0
```

Source	SS	df	MS				
Model	168.820066	1	168.820066	Number of obs =	1820		
Residual	5989.10081	1818	3.29433488	F(1, 1818) =	51.25		
Total	6157.92088	1819	3.38533308	Prob > F =	0.0000		
				R-squared =	0.0274		
				Adj R-squared =	0.0269		
				Root MSE =	1.815		

rechts	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
alter	.0177624	.0024813	7.16	0.000	.0128959	.0226288
_cons	4.364548	.1233541	35.38	0.000	4.122617	4.606479

Regressionskoeffizient


t-Wert

p-Wert

R²


Daten: ALLBUS 2002
Do-File: 1 Regression.do

Regression: politische Einstellung auf Alter



Exkurs: p-Wert

- Der p-Wert gibt bei Gültigkeit der H_0 die Wahrscheinlichkeit an, dass die Teststatistik den berechneten Wert oder einen, der noch weiter in Richtung der Alternativhypothese liegt, annimmt
- Die Nullhypothese wird dann verworfen, wenn $p \leq \alpha$



$H_0 : \beta = 0$

Prüfverteilung: Bei $n > 30$ ist die t-Verteilung eine Standardnormalverteilung

Die kritischen Werte sind auf dem 5%-Niveau -1,96 und 1,96


Liegt die Teststatistik t z.B. bei 2,4, so kann die H_0 abgelehnt werden

Rechts von t liegt $p/2$ (die Whs., dass noch was Extremes rauskommt) (hier ist $p=0,016$)

Da offensichtlich $p < 0,05$, kann die H_0 abgelehnt werden

Exkurs: Regression als bedingte Verteilung

- Zwei Variablen Y und X
 - mit Realisierungen (y_i, x_i) , für $i=1, \dots, n$
- Die Regression von Y auf X
 - ist die bedingte Verteilung: $f(Y | X=x)$




- X ist hier kategorial.
- Die bedingten Verteilungen haben sehr unterschiedliche Form.
- Eingetragen sind auch die bedingten Mittelwerte. Der Zusammenhang ist U-förmig.

Quelle: Fox (1997: 17)

Exkurs: Regression als bedingte Verteilung

- Eine solche allgemeine Regression enthält zu viel Information
- Informationsreduktion:
Charakterisierung der Verteilung durch geeignete Kennzahlen
 - Y metrisch: bedingtes arithmetisches Mittel
 - Y metrisch, ordinal: bedingtes Quantil
 - Y nominal: bedingte Häufigkeiten (Kreuztabelle)
- Nicht-parametrische Regression
 - Benutze die Y-Werte in einer Umgebung von x zur Berechnung der Kennzahl (local averaging)
 - Lokale mean (median) Regression
 - Lowess Smoother
- Parametrische Regression
 - Weitere Informationsreduktion: man nimmt an, dass die bedingten Kennzahlen einer Funktion folgen
 - Lineare Mittelwertsregression (OLS Regression)
 - Lineare Medianregression
 - Quantilsregression

Nicht-parametrische und parametrische Regression



Kapitel 4:

Das multiple lineare Regressionsmodell



Das multiple lineare Regressionsmodell

Das Modell:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \varepsilon_i, \quad i = 1, \dots, n$$

- ε_i ist ein Fehlerterm
- β_0 heißt Regressionskonstante
- Die anderen Regressionskoeffizienten definieren eine p-dimensionale Regressionsebene
- Interpretation: β_j gibt an,
um wie viel Einheiten sich Y ändert,
wenn sich X_j um eine Einheit erhöht,
unter Kontrolle der anderen im Modell enthaltenen X-Variablen
 - Synonym: β_j sagt uns, welcher Effekt verbleibt, wenn wir die anderen X-Variablen konstant halten

OLS Schätzung

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

mit :

$$\mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} 1 & x_{11} & \cdots & x_{1p} \\ 1 & x_{21} & \cdots & x_{2p} \\ \vdots & \vdots & & \vdots \\ 1 & x_{n1} & \cdots & x_{np} \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{pmatrix}, \quad \boldsymbol{\varepsilon} = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

Annahmen :

$\boldsymbol{\varepsilon} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I})$ vier Annahmen über die Fehlerverteilung (normalverteilt, im Mittel 0, Homoskedastizität, keine Autokorrelation)

$Cov(\mathbf{X}, \boldsymbol{\varepsilon}) = \mathbf{0}$ Exogenität von X

$rg(\mathbf{X}) = p + 1$ keine linearen Abhängigkeiten (bzw. Multikollinearität)

$$\text{OLS Schätzer : } \hat{\boldsymbol{\beta}} = (\mathbf{X}' \mathbf{X})^{-1} \mathbf{X}' \mathbf{y}$$

Multiples R^2

- Die vorhergesagten Werte ergeben sich aus

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_p x_{ip}$$

- Multiples Bestimmtheitsmaß

$$R^2 = \frac{\text{erklärte Streuung}}{\text{gesamte Streuung}} = \frac{MSS}{TSS} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

- Es besagt, welcher Anteil der Varianz von Y durch alle Regressoren zusammen erklärt wird
 - Fügt man einen weiteren Regressor hinzu, so ist das Bestimmtheitsmaß des erweiterten Modells mindestens genauso groß wie zuvor
 - Ist allerdings die Erklärungskraft der hinzugefügten Variable, gegeben die bereits im Modell enthaltenen Variablen, gering, so wird sich R^2 nur minimal erhöhen
 - Das Hinzufügen weiterer Variablen verbessert das Modell somit nur, wenn diese Variablen einen eigenständigen Erklärungsbeitrag leisten

Signifikanztests

- Test eines einzelnen Regressionskoeffizienten
 - Nullhypothese: X_j hat keinen Einfluss auf Y (kein Zusammenhang)

$$H_0: \beta_j = 0$$

- Die Teststatistik (t-Wert) ist

$$T = \frac{\hat{\beta}_j}{\hat{\sigma}_j} \sim t(n - p - 1)$$

- Die H_0 wird abgelehnt, falls $|T| > t_{1-\alpha/2}(n-p-1)$
 - Ab $n > 30$ das $z_{1-\alpha/2}$ Quantil (Faustregel für $\alpha=5\%$: $|T| > 2$)

- Test des gesamten Modells: overall F-Test

- Nullhypothese: keine X-Variable hat einen Einfluss auf Y

$$H_0: \beta_1 = \beta_2 = \dots = \beta_p = 0$$


- Die Teststatistik (F-Wert) ist

$$F = \frac{\text{MSS}/p}{\text{RSS}/(n-p-1)} \sim F(p, n-p-1)$$

- Die H_0 wird verworfen, falls: $F > F_{1-\alpha}(p, n-p-1)$

Beispiel: Statuszuweisungsmodell

- Blau/Duncan (1967) "The American Occupational Structure"
 - Wie erlangt man seine soziale Position?
Durch „achievement“ oder Statusvererbung?
 - ALLBUS 2002:
 - Abhängige Variable: monatliches Netto-Einkommen in Euro
(nur Westdeutsche, Vollzeit)
 - Status des Vaters: Magnitude-Prestigeskala (Werte von 20-187)
 - „Achievement“: eigene Schul- und Berufsbildung (Werte von 8-23,5)




Beispiel: Stata-Output

```
. regress      eink prestv bild
```

Source	SS	df	MS	Number of obs = 670		
Model	215244302	2	107622151	F(2, 667) = 64.99		
Residual	1.1045e+09	667	1655904.67	Prob > F = 0.0000		
Total	1.3197e+09	669	1972694.65	R-squared = 0.1631		
				Adj R-squared = 0.1606		
				Root MSE = 1286.8		
eink	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
prestv	1.99162	2.004457	0.99	0.321	-1.944187	5.927426
bild	180.2345	17.73502	10.16	0.000	145.4113	215.0577
_cons	-585.4664	224.3659	-2.61	0.009	-1026.015	-144.9179

Daten: ALLBUS 2002
Do-File: 2 LinReg Modell.do

Beispiel: Regressionsebene



Was bedeutet „unter Kontrolle“?

- β_j ist der Effekt von X_j unter Kontrolle der anderen im Modell enthaltenen X-Variablen
 - Man sagt auch: „unter Konstanthaltung“ der anderen im Modell enthaltenen X-Variablen
- Der bivariate Effekt wird von Konfundierungen „bereinigt“

bivariater Effekt
Konfundierung

$$\hat{\beta}_1^* = \frac{r_{X_1Y} - r_{X_1X_2} r_{X_2Y}}{1 - r_{X_1X_2}^2}$$

Standardisierung

- Spezialfall: X_1 und X_2 sind nicht korreliert (Multikausalität)


$$\hat{\beta}_1^* = r_{X_1Y}$$

- Der multiple Regressionskoeffizient ist gleich dem bivariaten

Was bedeutet „unter Kontrolle“?

- Das multiple Modell mit einem Confounder (C)

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 c_i + \varepsilon_i$$




- Der Effekt des Confounders (C) wird „herauspartialisiert“

- $y_i = \alpha + \beta c_i + \varepsilon_{i_Y} \rightarrow \hat{\varepsilon}_{i_Y} = y_i - \hat{\alpha} - \hat{\beta} c_i$
 - Die auf C beruhende Variation ist herausgerechnet: $Cov(\hat{\varepsilon}_{i_Y}, c_i) = 0$
- $x_i = \gamma + \delta c_i + \varepsilon_{i_X} \rightarrow \hat{\varepsilon}_{i_X} = x_i - \hat{\gamma} - \hat{\delta} c_i$
 - Die auf C beruhende Variation ist herausgerechnet: $Cov(\hat{\varepsilon}_{i_X}, c_i) = 0$

- Die Regression mit den Residuen liefert ebenfalls $\hat{\beta}_1$

$$\hat{\varepsilon}_{i_Y} = \beta_1 \hat{\varepsilon}_{i_X} + \varepsilon_i$$




Beispiel: Kontrolle der Herkunft

	(1) Bivariate Regression	(2) Multiple Regression	(3) Residuen Regression
bild	186.82*** (16.45)	180.23*** (17.74)	180.23*** (17.72)
prestv		1.99 (2.00)	
_cons	-555.64* (222.35)	-585.47** (224.37)	0.00 (49.68)
N	670	670	670
R-sq	0.162	0.163	0.134
Standard errors in parentheses			
* p<0.05, ** p<0.01, *** p<0.001			


Daten: ALLBUS 2002
Do-File: 2 LinReg Modell.do

Regel I: Welche Variablen kontrollieren?

- Oft wird ein Standard-Set an „Kontrollvariablen“ verwendet
 - Geschlecht, West/Ost, Alter, Herkunft, Beruf, Bildung, ...
 - Die „kontrolliere Alles auf Verdacht“ Strategie
 - Das ist keine sinnvolle Vorgehensweise!
- Regel: um den (totalen) Kausaleffekt zu identifizieren, kontrolliere nur (!) Confounder
- Wenn man Mediatoren mitkontrolliert: overcontrol-bias
 - Es wird nicht der totale, sondern nur der direkte Effekt geschätzt




$$y_i = \beta_0 + \textcolor{red}{a}x_i + \varepsilon_i$$



$$y_i = \beta_0 + \textcolor{red}{b}x_i + dz_i + \varepsilon_i$$

Regel I: Welche Variablen kontrollieren?

- Ziel: Einen (totalen) Kausaleffekt zu identifizieren
 1. Ein theoretisches Modell (um den Kausaleffekt) entwickeln
 2. Daraus ein maßgeschneidertes Regressionsmodell ableiten
- Beispiel: Kausaleffekt der Berufserfahrung auf Lohn




- Maßgeschneiderte Regression

$$\ln(\text{Wage}) = \alpha + \beta \text{Exp} + \gamma \text{Educ} + \delta \text{Female}$$

- γ und δ sind keine (totalen) Kausaleffekte!

Regel II: Mediationsanalyse

- Wenn man einen Kausaleffekt gefunden hat, kann man im nächsten Schritt fragen: Was ist der Mechanismus?
 - Statistisch ist dies die Frage nach der Mediation: Welche Mediatorvariable(n) kann den Effekt erklären?
- Bsp. Statuszuweisung: Kann die Bildung den Effekt der Herkunft erklären?



- Vorgehen: man fügt der Regression die Mediatorvariable(n) hinzu
 - Reduziert sich der Kausaleffekt (signifikant)?

Beispiel: Statuszuweisungsmodell

	(1)	(2)
prestv	9.61*** (2.00)	1.99 (2.00)
bild		180.23*** (17.74)
_cons	1343.23*** (128.51)	-585.47** (224.37)
N	670	670
R-sq	0.034	0.163

Standard errors in parentheses
 * p<0.05, ** p<0.01, *** p<0.001

Der signifikante Kausaleffekt von „Prestige Vater“ wird unter Kontrolle des Mediators „Bildung“ deutlich kleiner und ist nicht mehr signifikant.

Oft wird in so einem Fall von „signifikanter Mediation“ gesprochen.

Das ist aber voreilig, denn dafür braucht es einen Signifikanztest für den indirekten Effekt. Diesen liefert der Sobel-Test.

In unserem Fall werden 79% des totalen Effektes signifikant mediert.

Sobel-Goodman Mediation Tests


	Coef	Std Err	Z	P> Z
Indirect effect =	7.61593	1.04689	7.27483	3.5e-13
Direct effect =	1.99162	2.00446	.993595	.32042
Total effect =	9.60755	1.99636	4.81255	1.5e-06

Proportion of total effect that is mediated: .79270271

Daten: ALLBUS 2002
Do-File: 2 LinReg Modell.do

Beispiel: Statuszuweisung

- Das gesamte Kausalmodell mit den standardisierten Regressionskoeffizienten
 - Origin, Education, Destination: OED-Dreieck
 - Der direkte Herkunftseffekt ist schwach (und nicht signifikant)
 - Es gibt einen starken indirekten Effekt über Bildung




Daten: ALLBUS 2002
Do-File: 2 LinReg Modell.do

Das Signifikanztest-Ritual

- Unsinnige Anwendung der Signifikanztests in der Praxis
 - Multiples Testen und Publikations-Bias
 - Auch wenn in Wirklichkeit kein relevanter Effekt vorliegt, so werden von 100 Forschern irrtümlicherweise 5 einen „signifikanten“ Effekt finden und genau diese 5 „signifikanten“ Effekte werden publiziert
 - Analog: Variablen-/Modellselektion anhand von t-Tests
 - Nicht-signifikante Ergebnisse werden nicht publiziert (s. nächste Folie)
 - Folge: viele publizierte Ergebnisse sind zufällig zustande gekommen (also falsch, obwohl sie „signifikant“ sind)
 - Viele Forscher schauen nur noch auf die „Sternchen“
 - Aber: „Signifikanz ist nicht gleich Relevanz“
- Das Signifikanztestritual hat in den Sozialwissenschaften eine Menge an unsinnigen Ergebnissen produziert. Die Jagd nach Signifikanzen hat die Jagd nach der Realität verdrängt. Signifikanztests sollten deshalb abgeschafft werden!
(Ziliak/McCloskey, 2008)

Publications-Bias

Histogram of z Statistics From the *American Sociological Review*, the *American Journal of Sociology*, and *The Sociological Quarterly* (Two-Tailed)



Regel III: Welches Signifikanzniveau?

- Statt Abschaffung, Verbesserung der Praxis (s.a. Krämer 2011)
 - Kein „Sternchenquetschen“: kein 10%-Signifikanzniveau
 - Achte mehr auf Effektstärke (und Effektrichtung!)
 - Keine Variablenselektion anhand von Signifikanztests
 - Auch nicht-signifikante Ergebnisse sind wichtig!
- Statt R^2 -Zentrierung hin zur X-Zentrierung der Sozialforschung
 - Konzentriere dich auf einen Effekt und versuche den mittels harter Spezifikationstests zu widerlegen (Falsifikationismus!)

Kapitel 5: Interpretation von Regressionskoeffizienten



Interpretation von Regressionskoeffizienten

- Das multiple Regressionsmodell (ohne Personenindex i)

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

- Daraus ergibt sich der bedingte Erwartungswert

$$E(y|\mathbf{x}) = \beta_0 + \beta_1 x_1 + \beta_2 x_2$$

- Verschiedene Interpretationsmöglichkeiten
 - Marginaleffekt (marginal effect, **ME**)

$$\frac{\partial E(y|\mathbf{x})}{\partial x_j} = \beta_j$$

- Effekt der Veränderung von X_j um eine Einheit (discrete change, **DC**)

$$\frac{\Delta E(y|\mathbf{x})}{\Delta x_j} = E(y|\mathbf{x}, x_j + 1) - E(y|\mathbf{x}, x_j) = \beta_j$$

- Fazit: Im linearen Modell sind DC und ME identisch gleich dem Regressionskoeffizienten!

Graphische Präsentation von Regressionsergebnissen

- Anstatt einer Tabelle mit vielen Zahlen: Regressionsgraphen
(Bauer, 2015)
- Im Prinzip drei Typen:
 1. Plotten der Marginaleffekte von X: (Effektplot) **Koeffizientenplot**
 - ME für metrische Variablen, DC für Dummies
 2. Plotten der vorhergesagten Werte von Y: **Profile-Plot**
 - Welcher Wert von Y ergibt sich für verschiedene X-Werte?
 - Für alle Fälle in den Daten werden die beobachteten Werte eingesetzt, \hat{y}_i berechnet und dann gemittelt (predictive margins)
 3. Plotten der Effekte von X gegeben Z: **konditionaler Effektplot**
 - Wie verändert sich der ME von X mit Z?
 - Hilfreich für Interaktionen

Präsentation der Regressionskoeffizienten

- Bsp. Einkommensregression
 - Monatliches Nettoeinkommen in Euro (nur Vollzeitwerbstätige)
 - Bildungsjahre, Prestige Vater/100, Ostdeutscher, Frau, berufliche Stellung

```
regress eink bild prestv ost frau i.beruf
esttab using "RegTabelle.rtf", r2 b(%6.1f)
```


```
coefplot, drop(_cons) xline(0) base
```

Bildungsjahre	123.3***
	(7.67)
Prestige Vater / 100	47.4
	(0.31)
Ostdeutscher	-364.7***
	(-4.26)
Frau	-583.5***
	(-6.71)
Ber.: Arbeiter (Ref.)	
Ber.: Angestellter	371.8***
	(3.54)
Ber.: Beamter	667.9***
	(3.75)
Ber.: Selbständiger	860.7***
	(5.62)
Konstante	163.2
N	948
R ²	0.214

t statistics in parentheses

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

Regressionskoeffizienten und 95%-KI




Effekt auf monatliches Nettoeinkommen in Euro

Daten: ALLBUS 2002

Do-File: 3 LinReg Interpretation.do

Profile-Plot

- Hilfreich zur Veranschaulichung von Regressionskoeffizienten
 - Man plottet die vorhergesagten Werte der Outcome-Variable
 - Z.B. die geschätzte Regressionsgerade für eine metrische Variable
 - Evtl. für verschiedene inhaltlich interessierende Gruppen
 - Predictive Margins
 - Für jede Beobachtung wird mit ihren Kovariatenwerten ein Vorhersagewert berechnet
 - Nur die „marginvars“ werden auf fixierte Werte gesetzt
 - Anschließend wird über alle Vorhersagewerte gemittelt
 - Dies ist eine Art „kontrafaktisches“ Vorgehen!



Veranschaulichung des Bildungs- und des Geschlechtseffektes

„frau“ und „bild“ sind hier die marginvars

```
margins frau, at(bild=(8 18))  
marginsplot, noci
```

$$\hat{y}_M = 409 + 123 \times \text{Bild}$$
$$\hat{y}_F = 409 + 123 \times \text{Bild} - 584$$

Daten: ALLBUS 2002
Do-File: 3 LinReg Interpretation.do

Interpretation einer Polynomregression

$$y = \beta_0 + \beta_1 x_1 + \beta_2 \text{Exp} + \beta_3 \text{Exp}^2 + \epsilon$$

Daten: ALLBUS 2002
Do-File: 3 LinReg Interpretation.do

$$\frac{\partial E(y)}{\partial \text{Exp}} = \beta_2 + 2 \times \beta_3 \text{Exp}, \quad \text{Exp}_{\max/\min} = -\frac{\beta_2}{2 \times \beta_3}$$

```
. regress      eink bild ost frau c.exp c.exp#c.exp
```

Source	SS	df	MS	Number of obs =	1118
Model	474909648	5	94981929.7	F(5, 1112) =	65.83
Residual	1.6045e+09	1112	1442907.24	Prob > F	= 0.0000
				R-squared	= 0.2284
				Adj R-squared	= 0.2249
Total	2.0794e+09	1117	1861613.69	Root MSE	= 1201.2

eink	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
bild	180.95	12.36	14.64	0.000	156.69	205.20
ost	-448.92	77.23	-5.81	0.000	-600.45	-297.39
frau	-435.94	75.63	-5.76	0.000	-584.33	-287.55
exp	49.53	12.57	3.94	0.000	24.88	74.19
c.exp#c.exp	-0.63	0.29	-2.19	0.029	-1.20	-0.07
_cons	-971.85	202.76	-4.79	0.000	-1369.68	-574.01

Interpretation einer Polynomregression

```
. margins, dydx(exp) at(exp=(0 10 20 30 40 50))
```


	Delta-method			
	dy/dx	Std. Err.	z	P> z
0	49.53	12.57	3.94	0.000
10	36.91	7.18	5.14	0.000
20	24.28	3.38	7.18	0.000
30	11.66	6.13	1.90	0.057
40	-0.97	11.41	-0.08	0.932
50	-13.59	17.00	-0.80	0.424

```
. test exp exp#exp
```

```
( 1) exp = 0
( 2) c.exp#c.exp = 0
```

```
F( 2, 1112) = 26.21
Prob > F = 0.0000
```

$$\text{Exp}_{\max} = -\frac{49,53}{2 \times -0,63} = 39,3$$



Profile-Plot

```
margins, at(exp=(0(2)50))
marginsplot
```

Daten: ALLBUS 2002
Do-File: 3 LinReg Interpretation.do

Das semi-logarithmische Regressionsmodell

$$\ln(y) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$$\Leftrightarrow y = \exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon)$$

$$\frac{\partial E(y)}{\partial x_1} = E(y)\beta_1$$

Marginaleffekt

$$\frac{\Delta E(y)}{\Delta x_1} = E(y)(e^{\beta_1} - 1) \Rightarrow \frac{\frac{\Delta E(y)}{\Delta x_1}}{E(y)} = e^{\beta_1} - 1$$

Discrete Change

prozentuale Veränderung

$(e^{\beta_1} - 1) \times 100$ ist die prozentuale Veränderung von Y bei Erhöhung von X um eine Einheit.

$\beta_1 \times 100$ ist eine gute Näherung, falls $|\beta_1| < 0,1$.

Das semi-logarithmische Regressionsmodell

```
. regress lneink bild ost frau c.exp c.exp#c.exp
```

Source	SS	df	MS	Number of obs = 1118		
Model	138.195766	5	27.6391532	F(5, 1112) = 145.12		
Residual	211.79019	1112	.190458804	Prob > F = 0.0000		
				R-squared = 0.3949		
				Adj R-squared = 0.3921		
Total	349.985956	1117	.313326729	Root MSE = .43642		

lneink	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
bild	0.0863	0.0045	19.21	0.000	0.0775	0.0951
ost	-0.2496	0.0281	-8.90	0.000	-0.3047	-0.1946
frau	-0.2317	0.0275	-8.43	0.000	-0.2856	-0.1777
exp	0.0431	0.0046	9.43	0.000	0.0341	0.0520
c.exp#c.exp	-0.0006	0.0001	-6.13	0.000	-0.0008	-0.0004
_cons	5.8124	0.0737	78.90	0.000	5.6678	5.9569

Die exakten „Discrete Change“ %-Effekte

- Bildungsrendite: +9,1%
- Ostdeutscher: -22,1%
- Frau: -20,7%

Daten: ALLBUS 2002
Do-File: 3 LinReg Interpretation.do

Kapitel 6:

Regression mit Dummies



Regression mit Dummy

Einkommen in Abhängigkeit von Bildung und Geschlecht
 Dummy-Kodierung: 0 = Mann, 1 = Frau

```
. regress eink bild frau
```

Source	SS	df	MS				
Model	358146421	2	179073211	Number of obs	=	1118	
Residual	1.7213e+09	1115	1543745.36	F(2, 1115)	=	116.00	
Total	2.0794e+09	1117	1861613.69	Prob > F	=	0.0000	
				R-squared	=	0.1722	
				Adj R-squared	=	0.1707	
				Root MSE	=	1242.5	

eink	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
bild	169.2551	12.44852	13.60	0.000	144.8299	193.6803
frau	-511.2477	77.71202	-6.58	0.000	-663.7259	-358.7694
_cons	-264.8927	172.6304	-1.53	0.125	-603.6097	73.82433

Interpretation: Bei gleicher Bildung verdienen Frauen im Schnitt 511 Euro weniger als Männer.

Daten: ALLBUS 2002
 Do-File: 4 LinReg Dummies.do

Kategoriale uV mit mehr als 2 Ausprägungen

- Auch kategoriale Variablen sind in der multiplen Regression möglich
 - Aber erst nach Dummy-Bildung!
 - Grundprinzip: Für jede Ausprägung wird eine Dummy gebildet
 - In die Regression werden alle Dummies außer einer (Referenzkategorie) aufgenommen
- Beispiel: berufliche Stellung

berufliche Stellung	D1	D2	D3	D4
Arbeiter	1	0	0	0
Angestellter	0	1	0	0
Beamter	0	0	1	0
Selbständiger	0	0	0	1

- Werden keine weiteren unabhängigen Variablen berücksichtigt, so entspricht die Konstante β_0 dem Mittelwert der Referenzkategorie
- Die Koeffizienten β_j der Dummies geben den Mittelwertunterschied der betreffenden Kategorie zur Referenzkategorie an

Generierung der Dummies

```
. tabulate beruf, gen(d)
```

beruf	Freq.	Percent	Cum.
Arbeiter	360	29.22	29.22
Angestellter	622	50.49	79.71
Beamter	90	7.31	87.01
Selbständiger	160	12.99	100.00
Total	1,232	100.00	

```
. tabulate beruf d1
```

beruf	beruf==Arbeiter		Total
	0	1	
Arbeiter	0	360	360
Angestellter	622	0	622
Beamter	90	0	90
Selbständiger	160	0	160
Total	872	360	1,232

Daten: ALLBUS 2002
Do-File: 4 LinReg Dummies.do

Interpretation der Dummies

```
. table beruf, contents(sum d1 sum d2 sum d3 sum d4)
```

beruf	sum(d1)	sum(d2)	sum(d3)	sum(d4)
Arbeiter	360	0	0	0
Angestellter	0	622	0	0
Beamter	0	0	90	0
Selbständiger	0	0	0	160

```
. table beruf, contents(mean eink)
```

beruf	mean(eink)
Arbeiter	1332.902
Angestellter	1894.345
Beamter	2480.987
Selbständiger	2714.033

```
. regr eink d2 d3 d4
```

eink	Coef.
d2	561.4422
d3	1148.084
d4	1381.131
_cons	1332.903

Regression mit kategorialer uV

```
. regress eink bild i.beruf
```

Source	SS	df	MS	Number of obs = 1072	
Model	330638913	4	82659728.2	F(4, 1067)	= 52.89
Residual	1.6674e+09	1067	1562726.39	Prob > F	= 0.0000
Total	1.9981e+09	1071	1865609.69	R-squared	= 0.1655
				Adj R-squared	= 0.1624
				Root MSE	= 1250.1

eink	Coef.	Std. Err.	t	P> t
bild	130.5443	14.63054	8.92	0.000
beruf				
2	216.6888	95.98289	2.26	0.024
3	562.1304	171.8194	3.27	0.001
4	919.5047	143.5743	6.40	0.000
_cons	-141.8791	179.5353	-0.79	0.430

Bivariate Effekte

bild	165
angest	561
beamt	1148
selbst	1381

i.beruf sagt Stata, dass „beruf“ eine Indikatorvariable ist. Stata bildet dann die „virtuellen“ Dummies „2.beruf“, „3.beruf“ und „4.beruf“. Referenzkategorie ist automatisch der kleinste Wert 1=Arbeiter.

Daten: ALLBUS 2002
Do-File: 4 LinReg Dummies.do

Regression mit kategorialer uV

```
. testparm i.beruf
```

```
( 1) 2.beruf = 0
( 2) 3.beruf = 0
( 3) 4.beruf = 0
```

```
F( 3, 1067) = 15.01
Prob > F = 0.0000
```

Signifikanz des Berufs?

```
. regress eink bild ib3.beruf
```

Beamte als Referenzkategorie

eink	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
bild	130.5443	14.63054	8.92	0.000	101.8364	159.2522
beruf						
1	-562.1304	171.8194	-3.27	0.001	-899.2727	-224.9881
2	-345.4416	154.3745	-2.24	0.025	-648.3538	-42.52949
4	357.3743	183.0629	1.95	0.051	-1.829857	716.5784
_cons	420.2513	271.3571	1.55	0.122	-112.2028	952.7055

Daten: ALLBUS 2002
Do-File: 4 LinReg Dummies.do

Kapitel 7: Interaktionseffekte



Berücksichtigung von Interaktionseffekten

- Der Effekt von X hängt vom Wert von Z ab
 - Z nennt man auch Moderator-Variable (Interaktion = Moderation)
- Berücksichtigung in einer Regression
 - Nimm die Hauptterme in die Regression (X und Z)
 - Füge einen Interaktionsterm hinzu
 - Das Produkt von X und Z (deshalb auch „Produktterm“)
 - Hierbei unterstellt man eine multiplikative Interaktion

$$y = \beta_0 + \beta_1 x + \beta_2 z + \beta_3 (x * z) + \epsilon$$

Der (konditionale) Marginaleffekt von X

$$\frac{\partial E(y)}{\partial x} = \beta_1 + \beta_3 z$$

$$z = 0: \frac{\partial E(y)}{\partial x} = \beta_1$$

$$z = 1: \frac{\partial E(y)}{\partial x} = \beta_1 + \beta_3$$

Der (konditionale) Marginaleffekt von Z

$$\frac{\partial E(y)}{\partial z} = \beta_2 + \beta_3 x$$

$$x = 0: \frac{\partial E(y)}{\partial z} = \beta_2$$

$$x = 1: \frac{\partial E(y)}{\partial z} = \beta_2 + \beta_3$$

Der Interaktionseffekt

$$\frac{\partial^2 E(y)}{\partial x \partial z} = \beta_3$$

Dummy-Interaktion: Geschlecht/Wohnort

* Ohne Interaktion

```
. regress eink bild frau ost
```

eink	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
bild	172.4277	12.31945	14.00	0.000	148.2557	196.5996
frau	-484.5974	76.98204	-6.29	0.000	-635.6436	-333.5513
ost	-410.0585	78.53404	-5.22	0.000	-564.1498	-255.9672
_cons	-182.3318	171.3636	-1.06	0.288	-518.5635	153.9

* Mit Interaktion

```
. regress eink bild i.frau i.ost frau#ost
```


Number of obs = 1118

R-squared = 0.1947


eink	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
bild	171.3628	12.3170	13.91	0.000	147.1957	195.5299
frau	-592.1200	95.0501	-6.23	0.000	-778.6176	-405.6225
ost	-526.8585	99.1837	-5.31	0.000	-721.4665	-332.2504
frau#ost	311.5265	161.9030	1.92	0.055	-6.1431	629.1960
_cons	-132.5139	173.1033	-0.77	0.444	-472.1594	207.1317

Dummy-Interaktion: Geschlecht/Wohnort

ohne Interaktion



mit Interaktion



<u>Designmatrix</u>	Frau	Ost	Ofrau	Einkommens- unterschied
	-592	-527	312	
Mann West	0	0	0	0
Mann Ost	0	1	0	-527
Frau West	1	0	0	-592
Frau Ost	1	1	1	-807

Referenzgruppe

Daten: ALLBUS 2002
Do-File: 5 LinReg Interaktion.do

Slope-Interaktion: Geschlecht/Bildung

```
. * Ohne Interaktion
. regress eink c.bild i.frau
```

eink	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
bild	169.2551	12.44852	13.60	0.000	144.8299	193.6803
frau	-511.2477	77.71202	-6.58	0.000	-663.7259	-358.7694
_cons	-264.8927	172.6304	-1.53	0.125	-603.6097	73.82433

```
. * Mit Interaktion
. regress eink c.bild i.frau i.frau#c.bild
```


Number of obs = 1118
R-squared = 0.1765

eink	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
bild	190.2989	15.17511	12.54	0.000	160.5239	220.0739
frau	335.2419	359.1157	0.93	0.351	-369.3776	1039.861
frau#c.bild	-63.77517	26.41776	-2.41	0.016	-115.6094	-11.94099
_cons	-546.0541	207.9355	-2.63	0.009	-954.0433	-138.0648


Frauen verdienen mehr als Männer!?

Slope-Interaktion: Geschlecht/Bildung

ohne Interaktion



mit Interaktion



<u>Designmatrix</u>	Konstante	Frau	Bild	Fbild	Regressions- gerade
Mann	-546	0	1	0	$-546 + 190 \cdot \text{Bild}$
Frau	335	1	1	1	$-211 + 126 \cdot \text{Bild}$

Daten: ALLBUS 2002
Do-File: 5 LinReg Interaktion.do

Slope-Interaktion: Zentrierung

- Warum wurden wir in die Irre geführt?
 - Der Effekt von „Frau“ ist bei Bild=0 zu interpretieren
 - Dies ist offensichtlich eine sinnlose Interpretation
 - Problem tritt immer auf, wenn die metrische Interaktionsvariable keinen sinnvollen 0-Wert hat (z.B. auch bei Alter)
 - Abhilfe: Zentrieren der metrischen Variable ($cbild = bild - \text{mean}(bild)$)

```
. regress eink c.cbild i.frau i.frau#c.cbild
```

Source	SS	df	MS	Number of obs =	1118
Model	367104408	3	122368136	F(3, 1114) =	79.61
Residual	1.7123e+09	1114	1537089.85	Prob > F =	0.0000
Total	2.0794e+09	1117	1861613.69	R-squared =	0.1765
				Adj R-squared =	0.1743
				Root MSE =	1239.8

eink	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
cbild	190.2989	15.17511	12.54	0.000	160.5239	220.0739
frau	-513.8864	77.55202	-6.63	0.000	-666.0509	-361.7219
frau#c.cbild	-63.77517	26.41776	-2.41	0.016	-115.6094	-11.94099
_cons	1987.661	46.14574	43.07	0.000	1897.119	2078.204


Berichte auch die konditionalen Marginal effekte I

- Wir wissen nun, dass sich die Bildungsrenditen signifikant unterscheiden
- Oft wollen wir aber auch die Bildungsrendite in den beiden Gruppen wissen
 - Dies ist die Frage nach den konditionalen Marginal effekten
 - `margins frau, dydx(cbuild)`
- Man erhält sie auch über eine alternative Parametrisierung (**nested effects**)
- Im Beispiel: Bildungsrendite für Männer und Frauen getrennt
 - „Bild“ aus dem Modell nehmen, ersetzen durch:
 - „Bild_F“: Bildung für Frauen, 0 sonst (zentriert)
 - „Bild_M“: Bildung für Männer, 0 sonst (zentriert)

. regress eink cbild_m cbild_f frau						
Source		SS	df	MS	Number of obs = 1118	
-----+-----						
Model		367104408	3	122368136	F(3, 1114) = 79.61	
Residual		1.7123e+09	1114	1537089.85	Prob > F = 0.0000	
-----+-----						
Total		2.0794e+09	1117	1861613.69	R-squared = 0.1765	
					Adj R-squared = 0.1743	
					Root MSE = 1239.8	
-----+-----						
eink		Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
-----+-----						
cbild_m		190.2989	15.17511	12.54	0.000	160.5239 220.0739
cbild_f		126.5237	21.62439	5.85	0.000	84.09456 168.9528
frau		-513.8864	77.55202	-6.63	0.000	-666.0509 -361.7219
_cons		1987.661	46.14574	43.07	0.000	1897.119 2078.204
-----+-----						

Berichte auch die konditionalen Marginal-effekte II

- Symmetrie: Bildung moderiert den Effekt von „Frau“
 - Konditionale Marginal-effekte „Frau“: $335 - 64 \cdot \text{Bild}$
 - Ab Bild=6 ist der Effekt negativ. Dann geht die „Schere“ weiter auf
 - Achtung: der Interaktionseffekt (-64) ist zwar signifikant, das sagt uns aber nichts über die Signifikanz des Fraueneffekts!
 - Deshalb: ab welchem Bildungsniveau verdienen Frauen signifikant weniger als Männer?



Conditional-Effects-Plot

In Stata 12 leicht zu produzieren

```
margins, at(bild=(8(1)18)) dydx(frau)
marginsplot
```

Daten: ALLBUS 2002
Do-File: 5 LinReg Interaktion.do

Vollständige Interaktion mit Ost

- Will man Interaktionen aller Variablen zulassen
 - Interaktionsterme für alle Variablen (+ Hauptterm)
 - Test der Signifikanz der Interaktion für jede Variable einzeln
 - Signifikanztest für alle Interaktionseffekte (+Haupteffekt)
(entspricht Signifikanztest für getrennte Modelle, Chow-Test)

```
. regress eink i.ost##(i.frau c.cbild)
```

eink	Coef.	Std. Err.	t	P> t
cbild	181.2513	14.78765	12.26	0.000
frau	-588.6129	95.07484	-6.19	0.000
ost	-524.2035	99.1876	-5.28	0.000
ost#cbild	-32.26021	26.70952	-1.21	0.227
ost#frau	313.2981	161.8763	1.94	0.053
_cons	2148.898	54.73564	39.26	0.000

```
. * CHOW TEST
. contrast ost ost#i.frau ost#c.cbild, overall
```

	df	F	P>F
Overall	3	10.83	0.0000

Daten: ALLBUS 2002
Do-File: 5 LinReg Interaktion.do

Regeln für den Umgang mit Interaktionen

- Beide Hauptterme müssen im Modell sein
 - Ansonsten kaum realistische Restriktionen und schwer interpretierbar
 - Kollinearität zwischen Haupttermen und Interaktionstermen ist ein Datenproblem, kein Spezifikationsproblem! Bei hoher Kollinearität braucht man halt mehr Daten. Es macht aber keinen Sinn, den Hauptterm zu eliminieren.
- Zentriere metrische Interaktionsvariablen
 - Regressionskoeffizienten sind keine durchschnittlichen Marginaleffekte, sondern die Marginaleffekte an der Stelle $Z = 0$ (bzw. $X = 0$)
 - Bzw. wenn man Z zentriert hat: an der Stelle $Z = \text{mean}(Z)$
 - Zentrieren macht die Interpretation einfacher!
- Berichte inhaltlich bedeutsame Marginaleffekte (plus KI)
 - Z kategorial: berichte die Marginaleffekte von X in den Kategorien von Z
 - Z metrisch: plote den Marginaleffekt von X gegen Z (Conditional-Effects-Plot)


Schließlich: Ein Humankapitalmodell getrennt für West/Ost

AV: logarithmiertes Einkommen

	West	Ost
bild	0.089*** (16.50)	0.082*** (10.15)
exp	0.047*** (8.86)	0.029*** (3.35)
exp ²	-0.001*** (-5.56)	-0.000* (-2.38)
frau	-0.246*** (-7.25)	-0.186*** (-3.96)
_cons	5.723*** (64.68)	5.793*** (43.08)
<i>N</i>	752	366
<i>R</i> ²	0.424	0.281

t statistics in parentheses

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$



N.B.: Die Tabelle wurde direkt aus Stata mit dem Befehl „esttab“ erzeugt.

Daten: ALLBUS 2002
Do-File: 5 LinReg Interaktion.do

Ein komplexes Modell

Daten: ALLBUS 2002
Do-File: 3a LinReg Regressionsplots.do

```
. regress eink bild frau i.ost##(i.beruf c.exp##c.exp)
```

bild	142.4947	14.5792	9.77	0.000	113.8873	171.1021
frau	-470.5558	80.4638	-5.85	0.000	-628.4426	-312.6690
1.ost	458.5089	330.7956	1.39	0.166	-190.5811	1107.5989

beruf						
Angestellter	431.1194	112.9495	3.82	0.000	209.4889	652.7499
Beamter	387.5722	192.8944	2.01	0.045	9.0731	766.0714
Selbständiger	1138.4152	169.4858	6.72	0.000	805.8487	1470.9817

exp	57.3432	15.9833	3.59	0.000	25.9807	88.7057
c.exp#c.exp	-0.8235	0.3554	-2.32	0.021	-1.5209	-0.1261

ost#beruf						
1#Angestellter	-264.1148	176.2388	-1.50	0.134	-609.9322	81.7026
1#Beamter	846.6789	345.1562	2.45	0.014	169.4104	1523.9474
1#Selbständiger	-599.7550	263.7621	-2.27	0.023	-1.12e+03	-82.1988

ost#c.exp	-65.5124	30.2477	-2.17	0.031	-124.8648	-6.1601
ost#c.exp#c.exp	1.1592	0.6706	1.73	0.084	-0.1567	2.4751


Die Ergebnisse dieses Modells sind in Tabellenform praktisch nicht zu interpretieren

Systematik der Regressionsplots

* I) Koeffizientenplots

```
coefplot, drop(_cons) xline(0) base //hier nicht sehr hilfreich
```

```
margins, dydx(*) // Plot der "Average Marginal Effects" (AME)
marginsplot, horizontal xline(0) plotopts(connect(i)) // auch
nicht sehr informativ
```




* II) Profile Plot (PP)

```
margins beruf //PP mit kategorialer Variable
marginsplot, plotopts(connect(i))
```

```
margins, at(exp=(0(5)50)) //PP mit metrischer Variable
marginsplot, recast(line) recastci(rarea)
```

```
margins beruf#ost //Interaktion kategor. Variablen
marginsplot, plotopts(connect(i)) [1]
```




```
margins ost, at(exp=(0(5)50)) //Interaktion metr./kateg. Var.
marginsplot, noci recast(line) [2]
```

* III) Conditional-Effects Plot (CEP)

```
margins ost, dydx(exp) //AMEs Exp nach Ost (CEP I)
marginsplot, horizontal xline(0) plotopts(connect(i))
```

```
margins, dydx(ost) at(exp=(0(2)50)) //AMEs Ost nach Exp (CEPII)
marginsplot, recast(line) recastci(rline) yline(0) [3]
```



Kapitel 8:

Regressionsdiagnostik

- Linearität
- Homoskedastizität
- Normalverteilung
- Ausreißer



Regressionsdiagnostik

- Die Schätzung der Regressionskoeffizienten und die Tests auf ihre Signifikanz sind von Annahmen abhängig
- Deshalb sollte auch immer überprüft werden, ob diese Annahmen gerechtfertigt sind. Im Folgenden:
 - Multikollinearität
 - Linearitätsannahme A1/A2
 - Homoskedastizitäts-Annahme A3
 - Normalverteilungsannahme A6
 - zusätzlich: Ausreißerdiagnostik
- Meist analysiert man dazu die Residuen (Residuenanalyse)
 - Die Residuen sind Schätzer für die Fehlerterme

$$\hat{\varepsilon}_i = \hat{\varepsilon}(y_i|x_i) = y_i - \hat{y}_i$$

Multikollinearität

- Perfekte Kollinearität: lineare Abhängigkeit unter den Variablen
 - Modell nicht schätzbar (ab $r \geq 0,99$ wird es kritisch)
 - Stata lässt automatisch Variablen weg, um Kollinearität zu beheben
- „Mäßige“ Multikollinearität ($r < 0,99$)
 - OLS schätzbar und konsistent
 - Aber S.E.s der betroffenen Variablen größer (Schätzung unpräzise)
 - Das sehen viele Forscher als Problem („Sternchenjagd“)

- Diagnose: variance-inflation-factor (VIF)

$$\hat{V}(\hat{\beta}_j) = \frac{\hat{\sigma}^2}{(n-1)s_{x_j}^2} \frac{1}{1-R_j^2} \rightarrow VIF = \frac{1}{1-R_j^2}$$

- Die S.E.s sind „inflationiert“ mit Faktor \sqrt{VIF}
 - Faustregel: problematisch falls $VIF > 30$
- Maßnahme
 - Spezifikation überprüfen (aber nicht: einfach Variable weglassen)
 - Mehr Daten erheben, damit die Schätzung präziser wird
 - Index bilden (betroffene Variablen messen dasselbe?)

Multikollinearität

Interaktionsterme korrelieren stark

```
regress eink    c.bild##frau
              c.exp##c.exp
```

```
. estat vif
```

Variable	VIF	1/VIF
-----+-----		
bild	1.54	0.649513
1.frau	21.48	0.046559
frau#c.bild	21.83	0.045815
exp	14.55	0.068728
c.exp#c.exp	14.72	0.067929
-----+-----		
Mean VIF	14.82	

Mit zentrierten Variablen ist das Problem geringer!

```
regress eink    c.bild_cen##frau
              c.exp##c.exp
```

```
. estat vif
```

Variable	VIF	1/VIF
-----+-----		
bild_cen	1.54	0.649513
1.frau	1.01	0.991694
frau#c.bild_cen	1.49	0.669306
exp	14.55	0.068728
c.exp#c.exp	14.72	0.067929
-----+-----		
Mean VIF	6.66	

Linearität


Daten: ALLBUS 2002
Do-File: 6 LinReg Diagnostik.do

- Nicht-Linearität erkennt man in einem Residuen-Plot
 - Residuen gegen die uV auftragen
 - Abweichungen von der Null-Linie Anzeichen von Nicht-Linearität
 - In STATA: component-plus-residual plot (cprplot)
 - hilfreich: nicht-parametrischer Smoother (lowess)
 - weicht der Lowess von Regressionsgerade ab, dann Nicht-Linearität

* Beispiel: Berufserfahrung

```
regress eink bild exp frau  
cprplot exp, lowess
```

Der Lowess (grün) zeigt nur geringfügige Abweichungen von der Gerade. Es liegt also keine Nicht-Linearität vor.




Linearität

Daten: ALLBUS 2002
Do-File: 6 LinReg Diagnostik.do

- Alternative: Man gruppiert die Variable und plottet die für die Gruppen vorhergesagten Werte
 - So kann man graphisch die Linearität beurteilen
 - Man kann auch testen, welche Polynomterme signifikant sind

```
recode expgr 0/10=1 10/20=2 20/30=3 30/40=4 40/50=5
regress eink bild frau i.expgr
margins expgr //Vorhergesagtes Einkommen in den Gruppen
marginsplot //Plot der vorhergesagten Werte
contrast p.expgr, asobserved //Test, ob Polynomterme signifikant sind
```



	df	F	P>F
expgr			
(linear)	1	18.08	0.0000
(quadratic)	1	0.92	0.3371
(cubic)	1	0.17	0.6825
(quartic)	1	0.18	0.6715
Joint	4	10.44	0.0000
Residual	1111		


Homoskedastizität

Daten: ALLBUS 2002
Do-File: 6 LinReg Diagnostik.do

- Heteroskedastizität: Residuen streuen unterschiedlich
 - STATA: residual-versus-fitted-values Plot (rvfplot)

```
regress eink bild exp frau  
rvfplot, yline(0)
```

Deutlicher Trichter erkennbar:
Streuung der Residuen bei
großen Werten von y-Dach
höher.
Grund: rechtsschiefe
Einkommensverteilung.
Abhilfe: Transformation (s.u.)




Normalverteilungsannahme

- Folgen die Residuen einer Normalverteilung?
 - STATA: Normal-Probability Plot (qnorm)

```
regress eink bild exp frau  
predict res1, residual  
qnorm res1
```

Daten: ALLBUS 2002
Do-File: 6 LinReg Diagnostik.do


Die Residuen weichen deutlich von der roten Referenzlinie ab. Die Normalverteilungsannahme ist verletzt.
Grund: rechtsschiefe Einkommensverteilung
Abhilfe: logarithmische Transformation




Semi-logarithmische Einkommensregression

```
. * logarithmische Transformation der aV  
. generate lneink = ln(eink)  
. regress lneink bild exp frau
```

Daten: ALLBUS 2002
Do-File: 6 LinReg Diagnostik.do



Kein augenfälliges Muster erkennbar:
Homoskedastie



Nur mehr geringe Abweichungen an den
Ränder: Residuen fast normalverteilt

Robuste Standardfehler

- Man kann die S.E.s „robust“ berechnen, d.h. sie sind robust gegen Verletzungen von A3
 - Huber-White-Sandwich-Estimator (option: `vce(robust)`)

	(1)	(2)
	normale S.E.s	robuste S.E.s
bild	181.58*** (12.36)	181.58*** (18.75)
exp	22.15*** (3.38)	22.15*** (3.18)
frau	-474.57*** (76.49)	-474.57*** (70.69)
N	1118	1118
R-sq	0.203	0.203
Standard errors in parentheses		
* p<0.05, ** p<0.01, *** p<0.001		

Normaler Standardfehler:

$$\hat{V}(\hat{\beta}) = \hat{\sigma}^2 (X'X)^{-1},$$

wobei $\hat{\sigma}^2 = \frac{\sum_i \hat{\epsilon}_i^2}{n - k}.$

Huber-White-Sandwich-Estimator:


$$\hat{V}_W(\hat{\beta}) = (X'X)^{-1} X' D X (X'X)^{-1},$$

wobei $D = \text{diag}(\hat{\epsilon}_1^2, \dots, \hat{\epsilon}_n^2)$


Ausreißerdiagnostik

- Ein Datenpunkt ist einflussreich, wenn seine Beseitigung die Ergebnisse der Regression deutlich verändert
 - Fälle mit ungewöhnlichem X- und Y-Wert (Ausreißer) haben Einfluss
 - Problem: das Ergebnis repräsentiert evtl. nur wenige Ausreißer
- Einflussdiagnostik
 - Im Streudiagramm erkennt man einflussreiche Datenpunkte
 - Im multiplen Fall: Partielles-Regressions Streudiagramm
 - Cook's D: Veränderung der Regressionskoeffizienten, wenn man einen Fall weglässt. Fälle mit besonders hohem D haben starken Einfluss.
- Abhilfe
 - Ist der einflussreiche Datenpunkt korrekt vercodet?
 - Fehlspezifikation? Was haben die einflussreichen Datenpunkte gemeinsam?
 - Weglassen ist keine Lösung, das ist Manipulation!


Partielle-Regressions Streudiagramme



coef = 181.5751, se = 12.36355, t = 14.69



coef = 22.14759, se = 3.3750942, t = 6.56




coef = -474.57316, se = 76.490927, t = -6.2

Plottyp: Added-variable plots
avplots

Daten: ALLBUS 2002
Do-File: 6 LinReg Diagnostik.do

Einflussreiche Datenpunkte



```
* Indexplot von Cook's D
gen nr=_n
scatter D nr, msymbol(i) mlabel(nr)
mlabposition(0)
```

Besonderen Einfluss hat Fall 120.
Wir schauen uns die Fälle über 0,1 an.

```
. list eink bild exp frau if D>0.1 & D~=.
```

	eink	bild	exp	frau
120.	15200	23.5	5.5	0
1137.	15000	12	4	0

Es handelt sich um „Großverdiener“.
Überprüfen, ob deren Einkommen
richtig vercodet wurde.

Daten: ALLBUS 2002
Do-File: 6 LinReg Diagnostik.do

Kapitel 9:

Maximum-Likelihood Schätzung



Maximum-Likelihood Schätzung

- Die Parameter nicht-linearer Regressionsmodelle werden meist mit Maximum-Likelihood (ML) geschätzt
- Kurze Darstellung des Maximum-Likelihood Prinzips
 - Gegeben Daten: (y_i, x_i)
 - Gegeben Regressionsmodell: $f(Y = y_i | x_i, \beta)$
 - Schätzprinzip: Bestimme β so, dass die Wahrscheinlichkeit diese Daten zu beobachten, maximal wird
 - Die Wahrscheinlichkeit (Likelihood) der Daten unter dem gegebenen Modell und unabhängiger Stichprobenziehung ist

$$L(\beta) = \prod_{i=1}^n f(y_i, x_i; \beta)$$

- Für die Berechnung ist es vorteilhaft, die Log-Likelihood zu maximieren

$$l(\beta) = \sum_{i=1}^n \ln f(y_i, x_i; \beta)$$

- Ableiten und Null-Setzen liefert die ML-Schätzer

Eigenschaften der ML-Schätzer

- ML-Schätzer haben einige wünschenswerte Eigenschaften (asymptotisch!)

- Konsistent (unverzerrt)

$$E(\hat{\boldsymbol{\beta}}_{ML}) = \boldsymbol{\beta}$$

- Normalverteilt

$$\hat{\boldsymbol{\beta}}_{ML} \sim N(\boldsymbol{\beta}, I(\boldsymbol{\beta})^{-1}), \quad \text{wobei } I(\boldsymbol{\beta}) = -E\left(\frac{\partial^2 \ln L}{\partial \boldsymbol{\beta} \partial \boldsymbol{\beta}'}\right)$$

- Effizient

- Die ML-Schätzer haben minimale Varianz (unter den konsistenten Schätzern)
- Sie erreichen die Rao-Cramer Schranke

ML-Schätzer des binären Logit-Modells

- Anwendung auf das binäre Logit-Modell (McFadden 1972)

$$L(\boldsymbol{\beta}) = \prod_{i=1}^n \{P(Y = 1|\mathbf{x}_i, \boldsymbol{\beta})^{y_i} \cdot P(Y = 0|\mathbf{x}_i, \boldsymbol{\beta})^{(1-y_i)}\}$$

$$L(\boldsymbol{\beta}) = \prod_{i=1}^n \left\{ \left[\frac{e^{\boldsymbol{\beta}'\mathbf{x}_i}}{1 + e^{\boldsymbol{\beta}'\mathbf{x}_i}} \right]^{y_i} \cdot \left[\frac{1}{1 + e^{\boldsymbol{\beta}'\mathbf{x}_i}} \right]^{(1-y_i)} \right\}$$

- Logarithmieren, Ableiten und Null-Setzen liefert die Schätzgleichungen

$$\sum_{i=1}^n y_i \mathbf{x}_i = \sum_{i=1}^n \frac{e^{\hat{\boldsymbol{\beta}}'\mathbf{x}_i}}{1 + e^{\hat{\boldsymbol{\beta}}'\mathbf{x}_i}} \mathbf{x}_i$$

- Dies ist ein nicht-lineares Gleichungssystem,
Lösung deshalb mittels iterativer numerischer Algorithmen

Signifikanztests

- Test eines einzelnen Regressionskoeffizienten
 - Nullhypothese: X_j hat keinen Einfluss auf Y (kein Zusammenhang)
 $H_0: \beta_j = 0$
 - Die Teststatistik (z-Wert) ist $Z = \frac{\hat{\beta}_j}{\hat{\sigma}_j} \sim N(0,1)$
 - Die H_0 wird abgelehnt, falls $|Z| > z_{1-\alpha/2}$
 - Ab $n > 100$ sinnvoll (Faustregel für $\alpha = 5\%$: $|Z| > 2$)
- Test des gesamten Modells: Likelihood-Ratio (LR) Test
 - Nullhypothese: keine X -Variable hat einen Einfluss auf Y
 $H_0: \beta_1 = \beta_2 = \dots = \beta_p = 0$
 - Die Teststatistik (LR-Wert) ist $\chi^2 = -2 \ln \left(\frac{L_0}{L_1} \right) = 2(\ln L_1 - \ln L_0)$
 - L_0 : Likelihood des Modells nur mit Konstante (Nullmodell)
 - L_1 : Likelihood des Gesamtmodells
 - Die H_0 wird verworfen, falls: $\chi^2 > \chi^2_{1-\alpha}(p)$

Modellfit: Pseudo-R²

- R² nicht sinnvoll, da keine sinnvolle Streuungszerlegung
- In Analogie: Pseudo-R² Maße
 - Wie viel von der Likelihood des Nullmodells wird durch das Gesamtmodell „erklärt“
 - Null, wenn die weiteren X-Variablen nichts erklären
 - Maximum allerdings kleiner Eins
 - McFadden's Pseudo-R²

$$R_{MF}^2 = \frac{\ln L_0 - \ln L_1}{\ln L_0}$$

- nicht: Anteil erklärter Varianz
 - Relative Log-Likelihood Verbesserung (im Vergleich zum Nullmodell)
 - Fällt kleiner aus, als das R² des Linearen Wahrscheinlichkeitsmodells
- Weitere Pseudo-R² s. Long/Freese (2006) S. 109 ff
 - Manche Autoren präferieren McKelvey/Zavoina's R²

ML-Output

- Beispiel: Logit Modell der Arbeitslosigkeit
 - Im ALLBUS 2002 wurden Erwerbstätige gefragt, ob sie die letzten 10 Jahre arbeitslos waren (1=Arbeitslosigkeit)
 - Hinzu: die gegenwärtig Arbeitslosen
 - Sinnvoll: Einschränkung auf 30-65 Jährige

Daten: ALLBUS 2002
Do-File: 7 ML.do

Das Iterationsprotokoll

```
. logit arblos bild alter frau ost
```

```
Iteration 0:    log likelihood =  -850.0254
Iteration 1:    log likelihood = -776.09162
Iteration 2:    log likelihood = -774.80455
Iteration 3:    log likelihood = -774.80199
Iteration 4:    log likelihood = -774.80199
```

Protokoll der Iterationsschritte

- Hohe, negative Werte der Log-Likelihood, da Likelihood fast 0
- „Iteration 0“ ist der Startwert: $\ln(L_0)$
- Steigen an, d.h. die L der Daten nimmt zu
- Zum Schluss werden die Schritte kleiner
- Mit der 4. Iteration ist die Konvergenz erreicht: $\ln(L_1)$

Header

```
Logistic regression      Number of obs =   1329
                        LR chi2(4)    = 150.45
                        Prob > chi2    = 0.0000
Log likelihood = -774.802 Pseudo R2   = 0.0885
```

Schätzsample nach
„listwise deletion“

LR-Teststatistik:
 $2(-775 + 850)$

R^2 -McFadden:
 $\frac{-850 + 775}{-850}$

ML-Output

z-Wert

p-Wert

Koeffizienten Tabelle

Daten: ALLBUS 2002
Do-File: 7 ML.do

arblos	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
bild	-0.13	0.02	-5.96	0.000	-0.17	-0.09
alter	-0.04	0.01	-5.15	0.000	-0.05	-0.02
frau	-0.04	0.12	-0.31	0.757	-0.28	0.21
ost	1.22	0.13	9.68	0.000	0.97	1.47
_cons	2.22	0.45	4.92	0.000	1.34	3.11

- **Zahl der Nachkommastellen in der Tabelle**

- `set cformat %9.2f` //Format der Koeffizienten, S.E., KI
- `set pformat %5.3f` //Format des p-Wert

- **Schätzooptionen**

- `level(90)` 90%-Signifikanzniveau
- `vce(robust)` robuste Standardfehler (Huber-White-Sandwich)
- `vce(cluster VC)` Abhängigkeit in den durch VC definierten Gruppen

- **Weitere Schätzstatistiken**

- `estat vce` Varianz-Kovarianzmatrix der ML-Schätzer

Standardisierte Koeffizienten

- Manchmal will man Koeffizienten vergleichen: Standardisierung
 - X-Standardisierung: Koeffizienten multipliziert mit Standardabw. von X
 - Volle-Standardisierung: Koeffizienten multipliziert mit Standardabw. von X und dividiert mit Standardabweichung von Y

```
. listcoef, help           //funktioniert nur, wenn SPost Ados geladen sind
```

arblos	b	z	P> z	e^b	e^bStdX	SDofX
bild	-0.13053	-5.959	0.000	0.8776	0.6722	3.0425
alter	-0.03801	-5.154	0.000	0.9627	0.7199	8.6480
frau	-0.03851	-0.309	0.757	0.9622	0.9811	0.4942
ost	1.22097	9.684	0.000	3.3905	1.7956	0.4794

```

b = raw coefficient
z = z-score for test of b=0
P>|z| = p-value for z-test
e^b = exp(b) = factor change in odds for unit increase in X
e^bStdX = exp(b*SD of X) = change in odds for SD increase in X
SDofX = standard deviation of X

```

Daten: ALLBUS 2002
Do-File: 7 ML.do

Tests für komplexere Hypothesen

Sind Alter und Alter² gemeinsam signifikant?

```
. logit arblo bild frau ost
  (output omitted)
. estimates store null
.
. logit arblo bild frau ost alter c.alter#c.alter
```

Daten: ALLBUS 2002
Do-File: 7 ML.do

arblo	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
bild	-0.13	0.02	-5.96	0.000	-0.17	-0.09
frau	-0.03	0.13	-0.21	0.830	-0.27	0.22
ost	1.23	0.13	9.71	0.000	0.98	1.47
alter	-0.13	0.07	-1.79	0.073	-0.28	0.01
c.alter#c.alter	0.00	0.00	1.29	0.197	-0.00	0.00
_cons	4.28	1.66	2.57	0.010	1.02	7.54

```
. estimates store full
.
. test alter alter#alter      //Wald Test
```

```
( 1) [arblo]alter = 0
( 2) [arblo]c.alter#c.alter = 0
```

```
      chi2( 2) =    28.66
Prob > chi2 =    0.0000
```

```
. lrtest null full          //LR-Test
```

```
Likelihood-ratio test          LR chi2(2) =    29.18
(Assumption: null nested in full) Prob > chi2 =    0.0000
```

Fitmaße

```
. logit arblos bild alter frau ost
(output omitted)
```

Daten: ALLBUS 2002 Do-File: 7 ML.do
--

```
. fitstat //funktioniert nur, wenn SPost Ados geladen sind
```

Measures of Fit for logit of arblos

Log-Likelihood Maße

Log-Lik Intercept Only:	-850.025	Log-Lik Full Model:	-774.802
		LR(4):	150.447
		Prob > LR:	0.000

Pseudo R2 Maße (zum Vergleich: R2 = 10,9%)

McFadden's R2:	0.088	McFadden's Adj R2:	0.083
ML (Cox-Snell) R2:	0.107	Cragg-Uhler(Nagelkerke) R2:	0.148
McKelvey & Zavoina's R2:	0.149	Efron's R2:	0.110

Maße aus der Vorhersagetabelle

Count R2:	0.698	Adj Count R2:	0.105
-----------	-------	---------------	-------

Informations Maße

AIC:	1.174	AIC*n:	1559.604
BIC:	-7972.845	BIC':	-121.678

Modellvergleich mit BIC

- Vorschlag von Raftery (1996, Sociological Methodology)
 - BIC (Bayesian Information Criterion) zum Vergleich auch von nicht-verschachtelten Modellen. Mehrere Varianten: hier BIC'

$$BIC' = -LR + p \ln N$$

- LR: Likelihood-Ratio Teststatistik, p: Zahl Regressoren, N: Fallzahl
- Das Modell mit dem negativeren BIC' ist besser

Daten: ALLBUS 2002
Do-File: 7 ML.do

```
. logit arblos bild frau ost
. fitstat, saving(mod1)          //funktioniert nur, wenn SPost Ados geladen sind
. logit arblos bild frau ost alter c.alter#c.alter
. fitstat, using(mod1)          //funktioniert nur, wenn SPost Ados geladen sind
```

	Current logit	Saved logit	Difference
Model:			
LR	152.092(5)	122.908(3)	29.184(2)
Prob > LR	0.000	0.000	0.000
McFadden's R2	0.089	0.072	0.017
BIC'	-116.131	-101.332	-14.800

Difference of 14.800 in BIC' provides very strong support for current model.

Note: p-value for difference in LR is only valid if models are nested.

Kapitel 10:

Logistische Regression

- Das lineare Wahrscheinlichkeitsmodell
- Das logistische Modell
- Multiple logistische Regression
- Interpretation der Koeffizienten
- Interaktionseffekte
- Das Skalierungsproblem
- Logit vs. Probit



Regression mit kategorialen Outcomes

- Bei kategorialen Outcomes kann man lineare Wahrscheinlichkeitsmodelle einsetzen (linear probability model, LPM)
- Meist werden aber nicht-lineare Modelle verwendet (nonlinear probability models, NLPM)
 - Binäres Outcome
 - Logit (logistische Regression), Probit, etc.
 - Multinomiales Outcome
 - Multinomiales Logit, multinomiales Probit
 - Ordinales Outcome
 - Ordinales Logit, ordinales Probit
- Kodierung
 - Die abhängige Variable sollte 0, 1, ... kodiert sein

Das lineare Wahrscheinlichkeitsmodell

- Man kann eine dichotome aV linear modellieren

$$E(y) = \beta_0 + \beta_1 x_1 + \cdots + \beta_p x_p = \boldsymbol{\beta}' \mathbf{x}$$

- Da gilt $E(y) = P(Y = 0) \cdot 0 + P(Y = 1) \cdot 1 = P(Y = 1)$
- Erhält man das lineare Wahrscheinlichkeitsmodell (LPM)

$$P(Y = 1) = \beta_0 + \beta_1 x_1 + \cdots + \beta_p x_p = \boldsymbol{\beta}' \mathbf{x}$$

- Beispiel: Im ALLBUS 2002 wurden Erwerbstätige gefragt, ob sie die letzten 10 Jahre arbeitslos waren (1=Arbeitslosigkeit)
 - Hinzu: die gegenwärtig Arbeitslosen
 - Sinnvoll: Einschränkung auf 30-65 Jährige


Das lineare Wahrscheinlichkeitsmodell

```
. regress arblos alter
```

Daten: ALLBUS 2002
Do-File: 9 Logit Modell.do

Source	SS	df	MS	Number of obs	=	1,330
Model	4.34325173	1	4.34325173	F(1, 1328)	=	19.68
Residual	293.077049	1,328	.220690549	Prob > F	=	0.0000
Total	297.420301	1,329	.223792551	R-squared	=	0.0146
				Adj R-squared	=	0.0139
				Root MSE	=	.46978

arblos	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
alter	-.0066123	.0014905	-4.44	0.000	-.0095363	-.0036883
_cons	.6295199	.0670537	9.39	0.000	.4979772	.7610625



Mit jedem Jahr, sinkt die Whs. arbeitslos gewesen zu sein um 0,7 Prozentpunkte.

Probleme LPM:

- 1) LPM macht Prognosen jenseits $[0, 1]$.
- 2) Fehler sind heteroskedastisch und nicht-normalverteilt.
- 3) Die lineare Funktion unterstellt konstante Effekte. Oft macht es Sinn, abnehmende Effekte zu modellieren, wenn P nahe 0 oder 1 ist.

Das Logit-Modell

- Aufgrund der Probleme des LPM verwendet man zur Modellierung von Wahrscheinlichkeiten oft Verteilungsfunktionen $F(\cdot)$, deren Wertebereich $[0,1]$ ist:

$$P(Y = 1) = F(\beta'x)$$

- **Probit:** Standard-Normalverteilung $\Phi(\cdot)$ [Varianz = 1]


$$P(Y = 1) = \Phi(\beta'x)$$

- **Logit:** Standard-Logistische-Verteilung $\Lambda(\cdot)$ [Varianz = $\pi^2/3 = 3,29$]

$$P(Y = 1) = \frac{e^{\beta'x}}{1 + e^{\beta'x}} = \frac{1}{1 + e^{-\beta'x}}$$

$$P(Y = 0) = 1 - P(Y = 1) = \frac{1}{1 + e^{\beta'x}}$$

$$P(Y = 1) = \frac{1}{1 + e^{-(2 \cdot x)}}$$



Das Logit-Modell

```
. logit arblos alter
```

```
Iteration 0:    log likelihood = -850.43747    [ln(L0)]
```

```
...
```

```
Iteration 3:    log likelihood = -840.59929    [ln(L1)]
```

```
Logistic regression
```

```
Number of obs    =    1,330
```

```
LR chi2(1)       =    19.68
```

```
Prob > chi2      =    0.0000
```


```
Log likelihood = -840.59929
```

```
Pseudo R2       =    0.0116
```

LR-Teststatistik:
 $2(-840,6 + 850,4)$

$$R^2_{MF} = \frac{-850,4 + 840,6}{-850,4}$$

arblos	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
alter	-.0302412	.006902	-4.38	0.000	-.0437688	-.0167136
_cons	.6498028	.3051853	2.13	0.033	.0516507	1.247955




z-Wert

$$P(Y = 1) = \frac{1}{1 + e^{-(0.65 - 0.03 \cdot x)}}$$

Nur Vorzeicheninterpretation: Mit jedem Jahr, sinkt die Whs. arbeitslos gewesen zu sein.


Daten: ALLBUS 2002
 Do-File: 9 Logit Modell.do

STATA-Beispiel: Vergleich LPM und Logit-Modell



- Liegt $P(Y=1)$ im Intervall $[0,2; 0,8]$, so kommen LPM und Logit-Modell zu identischen Ergebnissen

STATA-Beispiel: Diagnostik (funktionale Form)



Das Logit-Modell repräsentiert den Zusammenhang in den Daten ganz gut.
Der Zusammenhang ist annähernd linear.
Problem: Überprüfung ist hier nur bivariat!

STATA-Beispiel: diskretes X

```
. tab   arblos ost, col chi2
```

arblos	ost		Total
	0	1	
0	645 75.44	236 49.68	881 66.24
1	210 24.56	239 50.32	449 33.76
Total	855 100.00	475 100.00	1,330 100.00

Pearson chi2(1) = 90.5715 Pr = 0.000

In diesem Fall reproduziert das logistische Modell exakt die Kreuztabelle (saturiertes Modell)

$$P(Y = 1|ost = 0) = \frac{1}{1 + e^{-(-1,12)}} = 0,246$$

$$P(Y = 1|ost = 1) = \frac{1}{1 + e^{-(-1,12+1,13)}} = 0,503$$

Daten: ALLBUS 2002
Do-File: 9 Logit Modell.do

```
. logit arblos ost
```

LR chi2(1) = 89.14

arblos	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ost	1.134775	.1213824	9.35	0.000	.8968694	1.37268
_cons	-1.122143	.0794499	-14.12	0.000	-1.277862	-.9664237

STATA-Beispiel: Multiple logistische Regression

```
. logit arblos bild alter frau ost[, or]
```

Logistic regression

Number of obs = 1329

LR chi2(4) = 150.45

Prob > chi2 = 0.0000

Log likelihood = -774.80199

Pseudo R2 = 0.0885

arblos	Coef.	Std. Err.	z	P> z	Odds
bild	-.1305347	.0219059	-5.96	0.000	0.88
alter	-.0380065	.0073747	-5.15	0.000	0.96
frau	-.0385114	.1246573	-0.31	0.757	0.96
ost	1.220968	.1260793	9.68	0.000	3.39
_cons	2.22248	.4519836	4.92	0.000	

Daten: ALLBUS 2002
Do-File: 9 Logit Modell.do

Interpretation der Koeffizienten

- Wie bei linearer Regression: die Effekte der anderen uVs sind „herauspartialisiert“
- Logit-Effekte: nur das Vorzeichen ist interpretierbar
- Odds-Effekt: multiplikative Effekte auf die „Chance“ (z-Werte unverändert!)

Interpretation der Koeffizienten

- Das Logit-Modell hat drei äquivalente Formulierungen:

$$\text{Whs.: } P(Y = 1) = \frac{e^{\beta'x}}{1 + e^{\beta'x}} \quad \text{„Wahrscheinlichkeit“}$$

$$\text{Odds: } \frac{P(Y=1)}{P(Y=0)} = e^{\beta'x} \quad \text{„Odds / Chance“}$$

$$\text{Logit: } \ln \left(\frac{P(Y=1)}{P(Y=0)} \right) = \beta'x \quad \text{„log. Odds / log. Chance“}$$

- Deshalb drei mögliche Interpretationen:
 - β_j ist der lineare, additive Effekt auf das Logit (unverständlich)
 - $\exp(\beta_j)$ ist der multiplikative Effekt auf die Odds (komplex)

$$\text{Odds-Ratio (OR)} := \frac{O_{x+1}}{O_x} = \frac{\exp(\beta(x+1))}{\exp(\beta x)} = \exp(\beta)$$

- Wahrscheinlichkeitseffekte sind am anschaulichsten, müssen aber mit speziellen Routinen ausgerechnet werden


STATA-Beispiel

- Logit-Interpretation (Bildungs-Effekt)
 - Das Logit sinkt um 0,13 mit jedem zusätzlichen Bildungsjahr
 - Das ist sehr unanschaulich
- Odds-Interpretation (Ost-Effekt)
 - Das Odds (die „Arbeitslosigkeits-Chance“) ist im Osten um den Faktor $\exp(1,22) = 3,4$ höher
 - Auch Prozentinterpretation: $(\exp(\beta_j) - 1) \cdot 100$
Das Odds ist im Osten um 240% höher
 - Falsch: die Whs. erhöht sich um 240%!
 - Die Odds-Ratio ist 3,4
 - Ca. Werte aus Kreuztabelle: $P(\text{Arblos}|\text{Ost})=0,5$, $P(\text{Arblos}|\text{West})=0,25$
 - $OR = \frac{\frac{50}{50}}{\frac{25}{75}} = 3$
 - Odds („Chancen“) sind leider auch ziemlich unanschaulich

Achtung bei der Interpretation von Odds-Ratios

Odds-Ratios werden häufig falsch verstanden. Hierzu ein Beispiel.

Um wie viel höher ist die Wahrscheinlichkeit nach der 4. Klasse aufs Gymnasium zu gehen, für ein Kind von Abiturienten im Vergleich zu Kindern von Hauptschülern (bei gleicher Leistung, für die hier kontrolliert ist)?



Die Odds-Ratio in diesem Modell ist etwa 6.

Z.B. Note 2,5:

Abi 60%

Hauptschule 20%

→ $OR = 60/40 / 20/80 = 6$

Also ist die „Chance“ 6 mal so hoch.

Aber Achtung: das sind keine Whs.verhältnisse:

Bei 2,5 ist das 3

Bei 1,5 ist das ca. 1

Daten: DJI Kinderpanel

Quelle: Diplomarbeit Volker Roth


Wahrscheinlichkeitsinterpretation

- „Discrete Change“ (DC) und „Marginaleffekt“ (ME)

$$\frac{\Delta P(Y = 1)}{\Delta x_j} = P(Y = 1 | \bar{x}, \bar{x}_j + 1) - P(Y = 1 | \bar{x}, \bar{x}_j)$$

$$\frac{\partial P(Y = 1)}{\partial x_j} = F'(\boldsymbol{\beta}'\bar{x}) = f(\boldsymbol{\beta}'\bar{x})\beta_j$$

- Man beachte: DC und ME hängen von den X ab! Weshalb man X-Werte setzen muss (hier: das Mittel, MEM und DCM)
- DC oder ME?
 - X kategorial: verwende DC
 - X metrisch: verwende ME
 - Long/Freeese plädieren auch hier für DC, da der ME nur eine Näherung ist (s. Graphik)



Quelle: Long/Freeese (2006) S. 169

Average Marginal Effect (AME)

- Marginaleffekte sind nicht eindeutig
 - Je nachdem, an welcher Stelle man sie berechnet, fallen sie anders aus
- Average marginal effects
 - Seit einigen Jahren die Lehrmeinung: um eine eindeutige Kennzahl zu erhalten, bilde den Durchschnitt der ME in der Stichprobe


$$AME_j = \frac{1}{N} \sum_{i=1}^N ME_{ij} = \frac{1}{N} \sum_{i=1}^N f(\hat{\beta}' x_i) \hat{\beta}_j$$

- In Stata: `margins, dydx(*)`
 - Für kategoriale X berechnet Stata ADC
- Interpretation: P(Y=1) erhöht sich – im Mittel aller Beobachtungen der vorliegenden Stichprobe – um AME Prozentpunkte, wenn sich X um eine Einheit (bzw. marginal) erhöht

STATA-Bsp.: Vorhergesagte Wahrscheinlichkeiten

Alter und Bildung


```
logit arblo bild alter frau ost  
  
margins, at(alter=(30(5)70) bild=(8 18))  
marginsplot, noci
```



Dies sind Profile-Plots

Berufliche Stellung und Ost

```
logit arblo bild alter frau ///  
      i.ost i.beruf  
margins beruf#ost  
marginsplot, plotopts(connect(i))
```



Daten: ALLBUS 2002
Do-File: 9 Logit Modell.do

STATA-Beispiel: AMEs


```
. logit arblo bild alter i.frau i.ost
. margins, dydx(*)
```

Daten: ALLBUS 2002
Do-File: 9 Logit Modell.do

Average marginal effects Number of obs = 1329

		Delta-method			
		dy/dx	Std. Err.	z	P> z
bild		-0.0260	0.0042	-6.24	0.000
alter		-0.0076	0.0014	-5.34	0.000
1.frau		-0.0077	0.0247	-0.31	0.757
1.ost		0.2636	0.0266	9.91	0.000

Note: dy/dx for factor levels is the discrete change from the base level.



Alter und Bildung sind hier durch 10 geteilt, damit die Skalierungen vergleichbar sind.

STATA-Beispiel: Vergleich mit LPM

	Logit	LPM
Bildung	AME -0,0260	-0,0248
Alter	AME -0,0076	-0,0074
Frau	ADC -0,0077	-0,0092
Ost	ADC 0,2636	0,2633

Das LPM approximiert die AMEs sehr gut

- Das Logit-Modell: ein umständlicher Weg, um im Endeffekt nur wieder die Effekte des LPM zu erhalten?
- Simulationen (Best/Wolf 2012) zeigen allerdings, dass das LPM bei nicht-normalverteilten (stark schiefen) X-Variablen zu verzerrten Ergebnissen führen kann
- Dennoch spricht Vieles (Interaktionseffekte, Gruppenvergleich, s.u.) dafür, das LPM zu verwenden. Deshalb erlebt das LPM in den letzten Jahren wieder eine Renaissance (Breen et al. 2018)

Interaktionseffekte

- Im linearen Modell $y = \beta_0 + \beta_1 x + \beta_2 z + \beta_3 (x \cdot z) + \varepsilon$

$$\frac{\partial^2 E(y)}{\partial x \partial z} = \beta_3$$

- Inteff ist konstant und gleich dem Koeffizienten des Produktterms

- Im Logit $P(Y = 1) = F[\beta_0 + \beta_1 x + \beta_2 z + \beta_3 (x \cdot z)] = F(u)$

$$\frac{\partial^2 P(Y = 1)}{\partial x \partial z} = \frac{\partial (\beta_1 + \beta_3 z) F'(u)}{\partial z} = \beta_3 F'(u) + (\beta_1 + \beta_3 z) F''(u) (\beta_2 + \beta_3 x)$$

- Inteff $\neq \beta_3$
- Inteff ist nicht konstant, sondern hängt von allen Kovariaten ab
 - Das Vorzeichen des Inteff kann sich von β_3 unterscheiden ($F''(u)$ kann kleiner null sein)
 - Je nach Kovariatenwert kann das Vorzeichen des Inteff anders sein (wir haben also positive und negative Inteff in den selben Daten)
- Die Signifikanz des Inteff kann nicht durch Test von β_3 geprüft werden
- Bereits das Modell ohne Produktterm modelliert einen Inteff

$$\left. \frac{\partial^2 P(Y = 1)}{\partial x \partial z} \right|_{\beta_3=0} = \beta_1 F''(u) \beta_2$$

Interaktionseffekte

Fazit: Produktterme in nicht-linearen Modellen erhöhen die Komplexität enorm. Um zu verstehen, was man hier eigentlich modelliert, muss man Profile-Plots zur Hilfe nehmen (mehr dazu findet man in Ai/Norton 2003).

Beispiel: Polynomregression mit Alter und Alter² und Interaktion mit „Ost“

```
. logit arblo bild frau i.ost##(c.alter c.alter#c.alter)
```

arblo	Coef.	Std. Err.	z	P> z
bild	-0.1336	0.0220	-6.08	0.000
frau	0.0010	0.1260	0.01	0.993
1.ost	1.8372	3.3693	0.55	0.586
alter	-0.0761	0.1032	-0.74	0.461
c.alter#c.alter	0.0002	0.0012	0.15	0.880
1.ost#c.alter	-0.0786	0.1540	-0.51	0.610
1.ost#c.alter#c.alter	0.0014	0.0017	0.83	0.404
_cons	3.5295	2.2561	1.56	0.118


Daten: ALLBUS 2002
Do-File: 9 Logit Modell.do

STATA-Beispiel: Interaktionseffekte

Profile-Plot

Polynomregression mit Alter²


```
logit arbloos bild frau i.ost      ///  
      c.alter c.alter#c.alter  
margins ost, at(alter=(30(5)65))  
marginsplot, noci
```



Profile-Plot

Polynomreg. + Interaktion mit Ost

```
logit arbloos bild frau          ///  
      i.ost##(c.alter c.alter#c.alter)  
margins ost, at(alter=(30(5)65))  
marginsplot, noci
```



Daten: ALLBUS 2002
Do-File: 9 Logit Modell.do


Interaktionseffekte

Conditional AME-Plot


```
logit arblo bld frau ///  
      i.ost##(c.alter c.alter#c.alter)  
margins, at(alter=(30(2)70)) dydx(ost)  
marginsplot, recast(line) recastci(rline)
```

Wem das alles zu kompliziert ist:
Das LPM ist eine gute Alternative und bekanntlich ist dort die Interpretation von Interaktionseffekten deutlich einfacher!

Konditionaler AME von 'Ost' und 95%-KI



Konditionaler AME von 'Ost' und 95%-KI



NLPMs als latentes Variablen Modell

Y^* sei eine latente Variable, die wir linear modellieren

$$y^* = a + bx + \sigma\varepsilon$$

- wobei ε ein Fehlerterm ist und σ ein Skalierungsfaktor
- Das binäre, beobachtete Y ergibt sich aus folgendem Schwellenwertmodell

$$y = \begin{cases} 1, & y^* > 0 \\ 0, & y^* \leq 0 \end{cases}$$

- Daraus ergibt sich $P(Y = 1)$ als

$$P(Y = 1) = P(y^* > 0) = P(a + bx + \sigma\varepsilon > 0) =$$

$$P(\sigma\varepsilon > -(a + bx)) = P(\varepsilon < \alpha + \beta x) = F(\alpha + \beta x)$$

- wobei $\alpha = \frac{a}{\sigma}$ und $\beta = \frac{b}{\sigma}$
- Je nach Annahme über $F(\cdot)$ kommt man zu Probit oder Logit
 - Die Varianz von ε ist dabei fest (s.o.)
 - Deshalb benötigt das Modell den Skalierungsfaktor σ

Das Skalierungsproblem

- Die Abhängigkeit der Koeffizienten vom (unbekannten) Skalierungsfaktor ist normalerweise kein Problem, da die Wahrscheinlichkeiten trotzdem eindeutig schätzbar sind
- Der Skalierungsfaktor wird allerdings zum Problem, wenn man vergleichen will (Überblick bei Breen et al. 2018)
 1. Genestete Modelle (Modellvergleich)
 2. Modelle über Gruppen, Kohorten, Länder, etc. (Gruppenvergleich)
- Die Skalierungsfaktoren unterscheiden sich zwischen Modellen/Gruppen (unterschiedliche unbeobachtete Heterogenität)
 - Die geschätzten Logit-Koeffizienten unterscheiden sich allein deshalb (gilt dann natürlich analog für Odds-Ratio Effekte)
 - Vergleiche von Koeffizienten zwischen Modellen/Gruppen sind somit von unbeobachteter Heterogenität konfundiert!

Modellvergleich

Erweiterung eines Logit-Modells um Z. Dann:

1. Die Erklärungskraft des linearen Prädiktors steigt. Da die Varianz von ε festgelegt ist, muss σ sinken. Deshalb werden die Koeffizienten größer (Koeffizienten-Inflation, KIF)

- $\sigma_2 < \sigma_1$, weshalb die Logit-Koeffizienten alle (!) größer werden

2. Der Effekt von X verändert sich
(falls Confounding oder Mediation)

Generell gilt: die Veränderung des Effekts von X wird in Richtung 0 verzerrt

Deshalb ist die soz. Literatur voll von Artefakt-Befunden, dass Drittvariablen keine Confounder/Mediatoren sind

$$\ln \left(\frac{P(Y = 1)}{P(Y = 0)} \right) = \frac{a}{\sigma_1} + \frac{b}{\sigma_1} x$$

$$\ln \left(\frac{P(Y = 1)}{P(Y = 0)} \right) = \frac{a}{\sigma_2} + \frac{b}{\sigma_2} x + \frac{c}{\sigma_2} z$$

	Modell (1)	Modell (2)
IQ	0,80	0,99
Mädchen		2,00
Konstante	-0,01	-1,01

Simulation von Mood (2010):

Logit Modell für die Wahrscheinlichkeit des Übergangs zur Universität.
IQ und Geschlecht sind unkorreliert!

Modellvergleich

- Es existieren diverse Lösungsvorschläge
- Bei kleinem R^2 ist die KIF gering (Best/Wolf 2012)
 - Allerdings ist es kein gutes Argument, mit der schlechten Erklärungskraft des Modells zu argumentieren
- Karlson/Holm/Breen (2012): KHB-Verfahren
 - Erweitere die Regression um das Residuum der Regression von Z auf X. Damit hat das reduzierte Modell die gleiche Erklärungskraft und es kommt zu keiner KIF

$$\text{Logit} = \alpha + \beta x + \gamma \hat{\varepsilon}_{z|x}$$

- Danach noch AME, wg. besserer Interpretierbarkeit
 - Stata-Ado: khb
- AMEs
 - Simulationen (z.B. Best/Wolf 2012) zeigen, dass die AMEs nicht von der KIF betroffen sind
- Das LPM ist vom Skalierungsproblem nicht betroffen

Gruppenvergleich

- Gruppenvergleich
 - Die Skalierungsfaktoren (σ) sind im Normalfall in den Gruppen unterschiedlich und man kennt sie nicht
 - Logit-Effekte werden allein deshalb unterschiedlich ausfallen
 - Gruppenvergleiche von NLPM-Koeffizienten beruhen auf nicht überprüfbaren Annahmen (Breen et al. 2018)
- Lösungsvorschläge
 - Heute werden oft die AMEs auch zum Gruppenvergleich verwendet
 - Auspurg/Hinz (2011) zeigen bei einer Analyse zur Veränderung der Bildungsungleichheit über Geburtskohorten, dass man mit OR und AME zu unterschiedlichen Schlussfolgerungen kommt. Sie empfehlen die Verwendung der AMEs.
 - Aber auch die AMEs scheinen nur bedingt vergleichbar zu sein (?)
 - Eine gangbare Lösung scheint das LPM zu sein (?) (Breen et al. 2018)

Logit vs. Probit

	Logit	Probit
Bildungsjahre	-0.131*** (-5.96)	-0.077*** (-6.06)
Alter	-0.038*** (-5.15)	-0.023*** (-5.32)
Frau	-0.039 (-0.31)	-0.023 (-0.30)
Ostdeutscher	1.221*** (9.68)	0.747*** (9.83)
Konstante	2.222***	1.328***
N	1329	1329
R ²	0.088	0.089

t statistics in parentheses

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

Logit und Probit liefern fast immer praktisch identische Ergebnisse. Die Logit-Koeffizienten sind in etwa um den Faktor 1,7 größer (s. Long, 1997, S. 48):

bild: $-0,131 / -0,077 = 1,70$

alter: $-0,038 / -0,023 = 1,65$

frau: $-0,039 / -0,023 = 1,70$

ost: $1,221 / 0,747 = 1,63$

Daten: ALLBUS 2002
Do-File: 9 Logit Modell.do

Kapitel 11: Multinomiales Logit



Regression für multinomiales Y

- Kategoriale aV mit mehr als zwei Ausprägungen
- Multinomiale logistische Regression
 - Y sei multinomial mit Ausprägungen $m = 1, \dots, J$. Ein geeignetes nicht-lineares Wahrscheinlichkeitsmodell zur Modellierung ist

$$P(y = m) = \frac{\exp(\boldsymbol{\beta}'_m \mathbf{x})}{\sum_{k=1}^J \exp(\boldsymbol{\beta}'_k \mathbf{x})}$$

- Alle J Koeffizientenvektoren sind nicht identifiziert, weshalb man einen auf 0 setzen muss. Für $J = 3$ und 1 als Referenzkategorie:

$$P(y = 1) = \frac{1}{1 + \exp(\boldsymbol{\beta}'_2 \mathbf{x}) + \exp(\boldsymbol{\beta}'_3 \mathbf{x})}$$

$$P(y = 2) = \frac{\exp(\boldsymbol{\beta}'_2 \mathbf{x})}{1 + \exp(\boldsymbol{\beta}'_2 \mathbf{x}) + \exp(\boldsymbol{\beta}'_3 \mathbf{x})}$$

$$P(y = 3) = \frac{\exp(\boldsymbol{\beta}'_3 \mathbf{x})}{1 + \exp(\boldsymbol{\beta}'_2 \mathbf{x}) + \exp(\boldsymbol{\beta}'_3 \mathbf{x})}$$

Multinomiales Logit

Anmerkungen:

- Es gilt: $\sum_m P(y = m) = 1$
- Die Wahl der Referenzkategorie ist beliebig. In Stata wird automatisch die Modal-Kategorie gewählt.
- Die Koeffizienten sind der Logit-Effekt jeweils im Vergleich zur Referenzkategorie. Je nach gewählter Referenzkategorie fallen also die Koeffizienten anders aus. Das Modell ändert sich aber nicht, es handelt sich nur um eine Reparametrisierung.
- Für $J = 2$ erhält man das binäre Logit als Spezialfall.
- Das multinomiale Logit kann auch aus einem latenten Variablen Modell hergeleitet werden. Das Problem mit dem Skalierungsfaktor σ existiert hier also auch!
- Schätzung mit ML: $L = \prod P_i$

STATA Beispiel: Wahlabsicht (Sonntagsfrage)

```
. generate partei = v521
. recode partei 1=1 2=2 3=3 4=4 6=5 5 7 8=.
. label define partlbl 1 "CDU" 2 "SPD" 3 "FDP" 4 "Grüne" 5 "PDS"
. label value partei partlbl

. tab partei,m
```

partei	Freq.	Percent	Cum.
CDU	722	25.60	25.60
SPD	660	23.40	49.01
FDP	284	10.07	59.08
Grüne	201	7.13	66.21
PDS	161	5.71	71.91
.	792	28.09	100.00
Total	2,820	100.00	

„Missing“: Republikaner, andere Partei, Nichtwähler,
Unentschlossene, Verweigerer, Ausländer

STATA Beispiel: Wahlabsicht (Sonntagsfrage)

```
. mlogit partei alter bild ost, base(1)           //CDU als Referenzkategorie
```

Multinomial logistic regression

Log likelihood = -2729.6341

Number of obs = 2007
 LR chi2(12) = 307.66
 Prob > chi2 = 0.0000
 Pseudo R2 = 0.0533

partei		Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
CDU		(base outcome)				
SPD	alter	-0.0069	0.0032	-2.14	0.032	-0.0133 -0.0006
	bild	-0.0051	0.0198	-0.26	0.797	-0.0439 0.0338
	ost	0.0995	0.1191	0.84	0.403	-0.1339 0.3329
FDP	alter	-0.0001	0.0042	-0.02	0.982	-0.0084 0.0082
	bild	0.0604	0.0241	2.50	0.012	0.0131 0.1077
	ost	-0.2284	0.1624	-1.41	0.160	-0.5467 0.0899
Grüne	alter	-0.0320	0.0054	-5.96	0.000	-0.0425 -0.0215
	bild	0.1586	0.0270	5.88	0.000	0.1057 0.2115
	ost	-0.7410	0.2138	-3.47	0.001	-1.1600 -0.3221
PDS	alter	-0.0112	0.0057	-1.97	0.049	-0.0223 -0.0000
	bild	0.0763	0.0310	2.46	0.014	0.0156 0.1370
	ost	2.4515	0.2247	10.91	0.000	2.0111 2.8918

Daten: ALLBUS 2002
 Do-File: 10 MLogit.do

Test der Signifikanz der Variablen

- Haben die drei Variablen einen signifikanten Einfluss auf die Wahlabsicht?
 - Die Signifikanztests der einzelnen Logit-Koeffizienten können zu widersprüchlichen Ergebnissen führen.
 - Wir brauchen einen LR-Test

```
. mlogtest, lr                                //funktioniert nur mit "SPost"

**** Likelihood-ratio tests for independent variables (N=2007)

Ho: All coefficients associated with given variable(s) are 0.
```

	chi2	df	P>chi2
alter	42.040	4	0.000
bild	45.950	4	0.000
ost	209.727	4	0.000

Daten: ALLBUS 2002
Do-File: 10 MLogit.do

Test zum Kombinieren von Kategorien

- Kann man Kategorien zusammenfassen?
 - Wenn die Logit-Effekte in einer Kategorie alle Null sind, so ist die Kategorie von der Referenzkategorie nicht unterscheidbar und die beiden Kategorien können zusammengefasst werden
 - Hierfür gibt es einen LR-Test

```
. mlogtest, lrcomb //funktioniert nur mit "SPost"
```

```
**** LR tests for combining alternatives (N=2007)
```

```
Ho: All coefficients except intercepts associated with a given pair  
of alternatives are 0 (i.e., alternatives can be collapsed).
```

Alternatives tested		chi2	df	P>chi2
-----+-----				
SPD-	FDP	12.383	3	0.006
SPD-	Grüne	80.599	3	0.000
SPD-	PDS	154.159	3	0.000
SPD-	CDU	5.429	3	0.143
FDP-	Grüne	47.655	3	0.000
FDP-	PDS	151.772	3	0.000
FDP-	CDU	8.196	3	0.042
Grüne-	PDS	180.703	3	0.000
Grüne-	CDU	93.209	3	0.000
PDS-	CDU	173.940	3	0.000

Interessanterweise scheint es, als ob wir CDU und SPD zusammenfassen könnten. Das werden wir aber aus inhaltlichen Gründen nicht tun!

Daten: ALLBUS 2002
Do-File: 10 MLogit.do

Unabhängigkeit von irrelevanten Alternativen

- Das multinomiale Logit impliziert eine spezielle Annahme
 - Unabhängigkeit von irrelevanten Alternativen (IIA)

$$\frac{P(y = m)}{P(y = k)} = \exp\{\mathbf{x}(\boldsymbol{\beta}_m - \boldsymbol{\beta}_k)\}$$

- Das Odds ist also unabhängig von den anderen Alternativen
 - In unserem Beispiel dürfte sich das Odds SPD/CDU nicht verändern, wenn eine neue Partei aufträte
 - Wenn z.B. die „Piraten“ hinzukämen, müssten proportional identische Teile der SPD- und CDU-Wähler zu den Piraten wechseln, damit die Odds SPD/CDU gleich bleiben und die IIA gilt
- Es gibt viele Tests der IIA
 - Grundidee: Man vergleicht die Schätzer des vollen Modells mit einem restringierten Modell, in dem eine Kategorie fehlt. Unterscheiden sich die Schätzer, so ist die IIA verletzt.

Unabhängigkeit von irrelevanten Alternativen

- Probleme der IIA-Tests
 - Long/Freeze zeigen, dass diese Tests in finiten Stichproben nicht funktionieren
 - Hausman-McFadden Test liefert oft negative Werte
 - Small-Hsiao hängt ab von der Zufallsaufteilung der Stichprobe
 - Also bleiben eigentlich nur Plausibilitätsüberlegungen:
„Sind die Kategorien klar unterscheidbare Alternativen?“
- Abhilfe wenn IIA verletzt ist
 - Nested Logit (nlogit)

```
. mlogtest, suest base //funktioniert nur mit "SPost"
```

```
**** suest-based Hausman tests of IIA assumption (N=2007)
```

```
Ho: Odds(Outcome-J vs Outcome-K) are independent of other  
alternatives.
```

Omitted	chi2	df	P>chi2	evidence
SPD	11.430	12	0.493	for Ho
FDP	13.196	12	0.355	for Ho
Grüne	5.381	12	0.944	for Ho
PDS	13.095	12	0.362	for Ho
CDU	5.041	12	0.957	for Ho

Daten: ALLBUS 2002
Do-File: 10 MLogit.do

Interpretation

- Vorzeicheninterpretation
 - Das Vorzeichen von β gibt Richtung des Logit- und Odds-Effektes
 - **Dieses Vorzeichen ist aber nicht unbedingt identisch mit dem Vorzeichen des Wahrscheinlichkeitseffektes!**
 - Das wird gern übersehen und kann zu falschen Schlussfolgerungen führen. Ein Beispiel:
 - Im Westen wählen jeweils 30% SPD und CDU
 - Im Osten wählen 20% SPD und 10% CDU
 - Odds(Ost) = $0,2/0,1 = 2$ Odds(West) = $0,3/0,3 = 1$
 - Die Odds-Ratio ist also 2. Es wäre nun aber eine krasse Fehlinterpretation, wenn man schlussfolgern würde, die Ossi wählen doppelt so oft SPD!
- Odds Interpretation
 - e^{β} ist die OR für Variable X_j für $P(y=m) / P(y=1)$
 - Die Odds Interpretation ist schwer zu verstehen

Bsp. Ost(Grüne):

$\beta = -0,7410$, OR = 0,48



Die Odds Grüne/CDU sind im Osten um die Hälfte kleiner.

Vorhergesagte Wahrscheinlichkeiten (Profile-Plots)

Alterseffekt nach Ost/West

```
mlogit partei alter bild ost, base(1)
prgen alter, from(18) to(83) x(ost 1) generate(o)
twoway connected op1 op2 op3 op4 op5 ox
```

Man beachte: Obwohl dieses Modell keine Produktterme enthält, sehen wir deutliche Interaktionen. Z.B. ist der Alterseffekt auf die Grünen im Westen stärker als im Osten.




Daten: ALLBUS 2002
Do-File: 10 MLogit.do

Wahrscheinlichkeitsinterpretation

- Die Marginal Effekte (ME) im multinomialen Logit sind

$$\frac{\partial P_m}{\partial x_j} = P_m \left(\beta_{m,j} - \sum_{k=1}^J \beta_{k,j} P_k \right), \quad \text{wobei } P_m = P(y = m)$$

- Der ME kombiniert alle Koeffizienten der Variable X_j . Er hängt von allen anderen Kovariatenwerten ab.
- Es ist sogar möglich, dass der ME sein Vorzeichen wechselt innerhalb des Wertebereichs von X_j !
- Deshalb verwendet man sinnvollerweise auch hier AMEs







Ein Modell mit Interaktionseffekten!

- Wir schätzen ein komplexes Modell
 - Quadratisches Polynom in Alter
 - Interaktion mit Ost
 - `mlogit partei bild i.ost##(c.alter c.alter#c.alter)`
- Interpretation
 - Eine Regressionstabelle hilft hier nicht mehr weiter
 - Regressionstabellen komplexer nicht-linearer Modelle sind Verschwendung von Papier und Zeit
 - Hier muss man Regressionsplots einsetzen
 - Auf der folgenden Folie sind illustrativ die Alterseffekte auf die Parteien (nicht: FDP) für Ost und West getrennt abgebildet
 - Das Modell erlaubt offensichtlich gänzlich unterschiedliche Alterseffekte!

Daten: ALLBUS 2002 Do-File: 10 MLogit.do

Ein Modell mit Interaktionseffekten!





LUDWIG-
MAXIMILIANS-
UNIVERSITÄT
MÜNCHEN

Kapitel 12: Ordinales Logit



Regression für ordinale Y

- Ordinale aV werden häufig mit OLS analysiert
 - Annahme: Distanzen zwischen den Kategorien sind gleich
 - Diese Annahme ist häufig nicht plausibel, weshalb man ein Regressionsverfahren für ordinale aV verwenden sollte
 - Dennoch liefert das lineare Modell meist ähnliche Ergebnisse (s.u.)
- Ordinal Response Model (ORM)
 - Y sei ordinal mit Ausprägungen $m = 1, \dots, J$. Das latente Variablen Modell lautet:

$$y^* = \boldsymbol{\beta}' \mathbf{x} + \varepsilon$$

- Das Schwellenwertmodell lautet nun mit $J+1$ Schwellen τ

$$y = m, \quad \text{falls } \tau_{m-1} \leq y^* < \tau_m$$

- wobei $\tau_0 = -\infty$ und $\tau_J = \infty$. Es sind also $J-1$ Schwellen zu schätzen. Damit gilt:

$$\begin{aligned} P(y = m) &= P(\tau_{m-1} \leq y^* < \tau_m) \\ \Rightarrow P(y = m) &= F(\tau_m - \boldsymbol{\beta}' \mathbf{x}) - F(\tau_{m-1} - \boldsymbol{\beta}' \mathbf{x}) \end{aligned}$$

Ordinales Logit/Probit

- Die Wahl der Verteilungsfunktion $F(\cdot)$ komplettiert das Modell
 - Standard-Normalverteilung: ordinale Probit
 - Standard-Logistische-Verteilung: ordinale Logit
 - z.B. ordinale Logit für $J=3$:

$$P(y = 1) = \Lambda(\tau_1 - \beta' x)$$

$$P(y = 2) = \Lambda(\tau_2 - \beta' x) - \Lambda(\tau_1 - \beta' x)$$

$$P(y = 3) = 1 - \Lambda(\tau_2 - \beta' x)$$

- Identifikation: es ist nicht möglich $J - 1$ Schwellen und eine Konstante zu schätzen. Stata setzt deshalb die Konstante auf 0.
- Für $J = 2$ erhält man die binären Modelle als Spezialfall.
- In der Ableitung haben wir den Skalierungsfaktor σ ignoriert. Das Problem existiert hier aber natürlich auch!
- Schätzung mit ML: $L = \prod P_i$

STATA Beispiel: „rechte“ politische Einstellung

```
. recode rechts 1/3=1 4/6=2 7/10=3  
. label define relbl 1 "Links" 2 "Mitte" 3 "Rechts"  
. label value rechts relbl  
. tab rechts, m
```

rechts	Freq.	Percent	Cum.
Links	584	20.71	20.71
Mitte	1,560	55.32	76.03
Rechts	517	18.33	94.36
.	159	5.64	100.00
Total	2,820	100.00	

Die aV wird hier gruppiert, um die Outputs übersichtlicher zu machen. Das sollte man bei ernsthaften Analysen nicht tun!

Daten: ALLBUS 2002
Do-File: 11 OLogit.do

STATA Beispiel: „rechte“ politische Einstellung

```
. replace eink = eink/1000 //bessere Skalierung
. ologit rechts alter bild eink frau ost
```

Daten: ALLBUS 2002
Do-File: 11 OLogit.do

```
Iteration 0: log likelihood = -2092.9781
Iteration 1: log likelihood = -2055.7797
Iteration 2: log likelihood = -2055.5577
Iteration 3: log likelihood = -2055.5576
```

Ordered logistic regression

Number of obs = 2137
LR chi2(5) = 74.84
Prob > chi2 = 0.0000
Pseudo R2 = 0.0179

Log likelihood = -2055.5576

rechts	Coef.	Std. Err.	z	P> z	[95% Conf. Intervall]	
alter	0.0068	0.0026	2.63	0.009	0.0017	0.0118
bild	-0.0358	0.0164	-2.18	0.029	-0.0680	-0.0036
eink	0.0448	0.0403	1.11	0.266	-0.0342	0.1239
frau	-0.3677	0.0886	-4.15	0.000	-0.5415	-0.1940
ost	-0.5678	0.0910	-6.24	0.000	-0.7461	-0.3894
/cut1	-1.6625	0.2562			-2.1647	-1.1604
/cut2	1.0128	0.2542			0.5145	1.5111

Ein Modellvergleich

	OLogit	OProbit	OLS
Alter	0.007** (2.63)	0.004** (2.69)	0.002** (2.70)
Bildungsjahre	-0.036* (-2.18)	-0.019* (-2.08)	-0.011* (-2.06)
Einkommen / 1000	0.045 (1.11)	0.026 (1.09)	0.015 (1.09)
Frau	-0.368*** (-4.15)	-0.216*** (-4.22)	-0.123*** (-4.23)
Ostdeutscher	-0.568*** (-6.24)	-0.329*** (-6.25)	-0.188*** (-6.29)
Konstante			2.094*** (25.61)
Cutpoint1	-1.663*** (-6.49)	-0.977*** (-6.75)	
Cutpoint2	1.013*** (3.98)	0.642*** (4.44)	
N	2137	2137	2137
R ²			0.035
pseudo R ²	0.018	0.018	

t statistics in parentheses

* $p < 0.05$, ** $p < 0.01$, *** $p < 0.001$

Daten: ALLBUS 2002
Do-File: 11 OLogit.do

Die Annahme paralleler Regressionen


- Das ORM impliziert eine Annahme
 - Beispiel: ordinale Logit, $J=4$

$$P(y \leq 1) = \Lambda(\tau_1 - \beta' x)$$

$$P(y \leq 2) = \Lambda(\tau_2 - \beta' x)$$

$$P(y \leq 3) = \Lambda(\tau_3 - \beta' x)$$

- Daran erkennt man, dass das ORM äquivalent ist zu drei binären Logits, wobei β identisch ist (nur die Konstanten sind verschieden) [parallel regression/line assumption]
- Testprinzip: man schätzt die binären Logits und testet, ob die $\hat{\beta}$ gleich sind
- Was tun bei Verletzung der Annahme?
 - Problematische Variablen weglassen (normalerweise keine gute Idee)
 - Alternative ORM: z.B. generalisiertes ordinale Logit
 - Multinomiale Modelle



Die Annahme paralleler Regressionen

```
. brant, detail //funktioniert nur mit "SPost"
```

Estimated coefficients from j-1 binary regressions

	y>1	y>2
alter	.00398831	.0102355
bild	-.06185737	.00013163
eink	.07913162	.00707855
frau	-.25742583	-.51034535
ost	-.46197847	-.72218376
_cons	1.9772367	-1.48633

Brant Test of Parallel Regression Assumption

Variable	chi2	p>chi2	df
All	13.84	0.017	5
alter	2.49	0.115	1
bild	6.53	0.011	1
eink	1.20	0.273	1
frau	3.33	0.068	1
ost	3.14	0.076	1

Daten: ALLBUS 2002
Do-File: 11 OLogit.do

A significant test statistic provides evidence that the parallel regression assumption has been violated.

Interpretation

- Vorzeicheninterpretation
 - Vorzeichen von $\hat{\beta}$ gibt Richtung des Effektes auf Y^* bzw. auf $P(Y=J)$
- Odds Interpretation (nur Logit)

$$\frac{P(y \leq 1)}{P(y > 1)} = \exp(\tau_1 - \beta' x)$$

$$\frac{P(y \leq 2)}{P(y > 2)} = \exp(\tau_2 - \beta' x)$$


- Es gibt also $J - 1$ Odds. Aufgrund der Annahme paralleler Regressionen sind die Effekte für alle Odds identisch (deshalb auch oft: „Annahme proportionaler Odds“)
- $\exp(-\beta_j)$ ist der multiplikative Effekt auf die Odds kleiner/größer
- Die Interpretation ist einfacher, wenn man die Odds als größer/kleiner formuliert: $\exp(\beta_j)$
- Die Odds Interpretation ist schwer zu verstehen

Bsp. Frau: $\beta = -0,3677$, $OR = 0,69$
Frauen haben eine um 31% geringere Chance eher rechts als links zu sein.

Profile-Plots


Alter und Bildung

```
ologit rechts alter bild eink frau ost  
margins, at(alter=(18(5)83) ///  
            bild=(8 18)) predict(outcome(3))  
marginsplot, noci
```



Alter (P kumuliert)

```
ologit rechts alter bild eink frau ost  
prgen alter, from(18) to(83) generate(pr)  
//funktioniert nur mit "SPost"  
twoway connected prs1 prs2 prx
```



Daten: ALLBUS 2002
Do-File: 11 OLogit.do

Wahrscheinlichkeitsinterpretation



- Der Marginal Effekt (ME) im ORM ist

$$\frac{\partial P(Y = m)}{\partial x_j} = F'(\tau_m - \beta' \bar{x}) - F'(\tau_{m-1} - \beta' \bar{x}) =$$


$$= \beta_j [f(\tau_{m-1} - \beta' \bar{x}) - f(\tau_m - \beta' \bar{x})]$$

- Man beachte, dass es hier mehrere ME gibt (nämlich J Stück)
 - Die summieren sich über alle Kategorien zu 0!
- Die ME sind die Steigungen in den PPs (bei metrischen Variablen)
- Weiterhin gibt es natürlich auch DC, AME und ADC
 - Das oben Gesagte gilt auch hier!

Daten: ALLBUS 2002
Do-File: 11 OLogit.do



AMEs für unser Beispiel



Interaktionseffekte


Profile-Plot

Polynomreg. + Interaktion mit Ost


```
ologit rechts bild eink frau      ///  
      i.ost##(c.alter c.alter#c.alter)  
margins ost, at(alter=(18(5)83))  ///  
      predict(outcome(3))  
marginsplot,   noci
```

Conditional-Effects-Plot

```
ologit rechts bild eink frau      ///  
      i.ost##(c.alter c.alter#c.alter)  
margins, at(alter=(18(2)82)) dydx(ost)  
      predict(outcome(3))  
marginsplot, recast(line)  
      recastci(rline)
```



Konditionaler Marginaleffekt von 'Ost' und 95%-KI



Daten: ALLBUS 2002
Do-File: 11 OLogit.do



LUDWIG-
MAXIMILIANS-
UNIVERSITÄT
MÜNCHEN

Kapitel 13:

Ausblick/Literatur



Ausblick

- Multiple Imputation
 - `mi` Prefix
- Bayesianische Statistik
 - `bayes` Prefix
- Komplexe Surveydaten
 - `svy` Prefix
- Zähldaten
 - `poisson`, `nbreg`
- Zensierte/trunkierte Daten
 - `tobit`, `intreg`, `truncreg`, `heckman`
- Strukturgleichungsmodelle
 - `sem`
- Mehrebenenmodelle
 - `mixed`, `me...`
- Ereignisdatenmodelle
 - `stcox`, `streg`, `st...`
- Paneldatenmodelle
 - `xtreg`, `xt...`

Literatur

Ai, C. und E. Norton (2003) Interaction terms in logit and probit models. *Economics Letters* 80: 123-129

Auspurg, K. und Th. Hinz (2011) Gruppenvergleiche bei Regressionen mit binären abhängigen Variablen. *ZfS* 40: 62-73.

Best, H. und C. Wolf (2012) Modellvergleich und Ergebnisinterpretation in Logit- und Probit-Regressionen. *KZfSS* 64: 377-395

Breen, R., K. Karlson und A. Holm (2018) Interpreting and Understanding Logits, Probits, and Other Nonlinear Probability Models. *Ann. Rev. Soc.* 44: 39-54.

Karlson, K., A. Holm und R. Breen (2012) Comparing regression coefficients between same-sample nested models using logit and probit: a new method. *Sociol. Methodol.* 42:274–301.

Mood, C. (2010) Logistic Regression: Why we cannot do what we think we can do, and what we can do about it. *Eur. Soc. Rev.* 26: 67-82.