



Fakultät für Humanwissenschaften
Sozialwissenschaftliche Methodenlehre
Prof. Dr. Daniel Lois

Mehrebenenanalyse mit STATA: Grundlagen und Erweiterungen

Stand: April 2015 (V2.0)

Inhaltsverzeichnis


1. Mehrebenenanalyse: Einführung	3
2. Mehrebenenanalyse: Modellvarianten	7
3. Generische STATA-Syntax (metrische AV)	39
4. Bestimmung des Modellfit (R^2)	43
5. Visualisierung und Diagnostik	49
6. Zentrierung	63
7. Logistisches Mehrebenenmodell	69
8. Panelanalyse: RE- und FE-Modelle	85
9. Wachstumskurvenmodelle	119
10. Literaturempfehlungen	130

Mehrebenenanalyse: Grundlagen


- Eine Mehrebenenstruktur liegt vor, wenn Daten einer Analyseebene hierarchisch in einer zweiten geschachtelt sind
- Die nächste Folie zeigt hierzu drei Beispiele: Personen (Ebene 1) sind der übergeordneten Ebene „Land“ oder „Haushalt“ zugeordnet
- Auch Längsschnitt- bzw. Paneldaten lassen sich als Mehrebenenendaten auffassen; hier entspricht Ebene 1 den Messzeitpunkten und die übergeordnete Ebene 2 sind Personen, bei denen eine Variable mehrfach gemessen wird
- Auch komplexere Hierarchien mit 3 oder mehr Ebenen sind denkbar (siehe Beispiel 4)

Mehrebenenanalyse: Grundlagen

Beispiel 1: Personen
(Ebene 1) gruppieren
sich in Ländern
(Ebene 2)




Beispiel 2: Personen
(Ebene 1) gruppieren
sich in Haushalten
(Ebene 2)



Beispiel 3:
Messzeitpunkte
(Ebene 1) gruppieren
sich in Personen
(Ebene 2)



Mehrebenenanalyse: Grundlagen



Beispiel 4: Personen (Ebene 1) gruppieren sich in Haushalte (Ebene 2), Haushalte gruppieren sich in Länder (Ebene 3)

Mehrebenenanalyse: Grundlagen

- Wenn hierarchische Daten vorliegen, sind die einzelnen Beobachtungen auf Ebene 1 (z.B. Personenebene) nicht unabhängig voneinander, was bei der Datenanalyse zu berücksichtigen ist
- Geschieht dies nicht, können Schätzungen von Zusammenhängen, Varianzen und Signifikanzniveaus verfälscht werden (mehr zur Einführung in die Mehrebenenanalyse: → Skript MEA in SPSS)
- Das folgende Skript beschäftigt sich mit Verfahren zur Analyse von Mehrebenenendaten im Programm STATA
- Die einführende Darstellung beschränkt sich auf 2 Ebenen, eine metrische abhängige Variable und Querschnittdaten
- Anschließend werden Panelanalysen als Erweiterung besprochen

Mehrebenenanalyse: Modellvarianten

- Behandelt werden im Folgenden Mehrebenenmodelle mit Zufallskoeffizienten (**multilevel random coefficient modeling**, MRCM)
- Diese Verfahren kann man sich konzeptuell als eine Reihe geschachtelter Regressionsanalysen vorstellen, in denen die Koeffizienten einer Analyseebene zur abhängigen Variablen auf der nächsten Analyseebene werden
- Deshalb wird oft auch von „**hierarchischen linearen Modellen**“ (HLM) gesprochen
- Im Folgenden werden diese Modelle im Rahmen der „systems of equations“-Notation durch separate Gleichungen für jede Analyseebene beschrieben

Mehrebenenanalyse: Modellvarianten

- Beispieldaten: „National Longitudinal Study (1988)“, landesweite Studie zur Mathematikleistung von Schülern der 8. Klasse in den USA (nels88.dta)
- 21.580 Schüler(innen) in 1.003 Schulen (durchschnittlich 21,5 Schüler(innen) pro Schule)
- Abhängige Variable: Mathematikleistungstest (MW = 51,0, SD = 10,2)
- Unabhängige Variablen:
 - Level 1 (Schüler(in)): Sozioökonomischer Status der Eltern als Mittelwert von drei z-standardisierten Komponenten (Bildungsniveaus Mutter und Vater sowie Familieneinkommen)
 - Level 2 (Schulen): Anteil der Minoritätenschüler an der Schülerschaft einer Schule

Mehrebenenanalyse: Modellvarianten

- In einem ersten Schritt ist mit Hilfe eines sog. **Nullmodells** ohne erklärende Variablen zu überprüfen, ob die Anwendung eines Mehrebenenmodells notwendig und angemessen ist
- Neben verschiedenen grafischen Analysemöglichkeiten (siehe z.B. Luke 2004: 17ff), die sich vor allem bei einer überschaubaren Anzahl von Level 2-Einheiten anbieten, besteht ein formeller Test in der Berechnung des sog. **Intraclassenkorrelationskoeffizienten** (ICC, symbolisiert mit ρ , „rho“)
- Dieser gibt den Anteil der Level 2-Varianz an der Gesamtvarianz in der abhängigen Variablen wieder (σ_{u0} = Level 2-Varianz, σ_r = Level 1-Varianz):

$$\rho = \frac{\sigma_{u0}^2}{(\sigma_{u0}^2 + \sigma_r^2)}$$

Mehrebenenanalyse: Modellvarianten

- Wie das Nullmodell formal definiert ist, zeigt die nächste Folie
- Y_{ij} ist die Mathematikleistung von Schüler(in) i in Schule j
- Der einzige feste („fixed“) Effekt ist der Gesamtmittelwert („grand mean“) der Matheleistung über alle Schüler(innen) und alle Schulen (Y_{00})
- Der Fehlerterm wird in zwei Komponenten aufgeteilt:
 - Die Varianz zwischen Schulen (u_{0j}), d.h. Abweichungen des jeweiligen Schulmittelwertes vom Gesamtmittelwert und
 - Die Varianz zwischen Schülerinnen und Schülern innerhalb von Schulen (r_{ij}), d.h. die Abweichungen des jeweiligen individuellen Wertes vom Schulmittelwert
- u_{0j} und r_{ij} sind „random effects“

Mehrebenenanalyse: Modellvarianten

Klasse	Nr.	Gleichungen
Unkonditioniert („Nullmodell“)	1	Level 1: $Y_{ij} = \beta_{0j} + r_{ij}$ Level 2: $\beta_{0j} = \gamma_{00} + u_{0j}$ i = 1,2,..., n Level-1-Einheiten (hier: Schüler(innen)) j = 1,2,..., m Level-2-Einheiten (hier: Schulen)

Mehrebenenanalyse: Modellvarianten

- Die nächste Folie zeigt die Ergebnisse des Nullmodells für das Beispiel
- Geschätzt wird hier nur ein fester Effekt, der Gesamtmittelwert der Matheleistung über alle Schüler(innen) und Schulen (50,8); dieser Wert entspricht γ_{00} in der Formel zu Modell Nr. 1
- Die Standardabweichung der Level 1-Residuen, d.h. die Abweichungen der Schüler(innen) vom Schulmittelwert (r_{ij}), entspricht dem Wert 8,75 („sd(Residual)“)
- Die Standardabweichung des Random Intercept (u_{0j}), d.h. die Abweichungen der Schulmittelwerte vom Gesamtmittelwert ($v1$ ist die Schul-ID), entspricht dem Wert 5,15 („sd(_cons)“)

Mehrebenenanalyse: Modellvarianten

Mixed-effects ML regression
Group variable: id

Number of obs = 21580
Number of groups = 1003

Obs per group: min = 1
 avg = 21.5
 max = 67

Log likelihood = -78482.726

wald chi2(0) = .
Prob > chi2 = .

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_cons	50.80271	.1748084	290.62	0.000	50.46009	51.14533

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Identity				
sd(_cons)	5.153382	.132303	4.900489	5.419326
sd(Residual)	8.753068	.0431388	8.668924	8.838028

LR test vs. linear regression: chibar2(01) = 4430.18 Prob >= chibar2 = 0.0000

Mehrebenenanalyse: Modellvarianten

- Die Intraklassenkorrelation wird wie folgt berechnet: $5,15^2 / (5,15^2 + 8,75^2) = 0,257$
- 26% der Varianz in der Mathematikleistung gehen folglich auf Unterschiede zwischen den Schulen zurück und 74% entsprechend auf Unterschiede innerhalb von Schulen bzw. zwischen Schülerinnen und Schülern
- Ob ein Mehrebenenmodell (gegenüber OLS) statistisch angemessen ist, zeigt der Likelihood-Ratio-Test unterhalb des Modelloutputs
- Nullhypothese: Modellanpassung verschlechtert sich nicht, wenn Random Intercept auf 0 restringiert wird (abzulehnen, da $p \leq 0,0000$)

Mehrebenenanalyse: Modellvarianten

- Die nächste Modellklasse wird unter dem Begriff „**Random Intercept**“ zusammengefasst
- Annahme: Es gibt zwar Unterschiede im Y-Mittelwert zwischen den Level 2-Einheiten (variierende Intercepts), der Effekt einer oder mehrerer Level 1-Variablen unterscheidet sich jedoch in Richtung und Stärke nicht zwischen den Level 2-Einheiten
- In Modell Nr. 2 (nächste Folie) ist eine Individualvariable X_{ij} als Prädiktor enthalten, während die Level 2-Modellierung nach wie vor dem Nullmodell entspricht
- Dieses Modell ähnelt einer einfachen OLS-Regression, das Subscript j (bei β_0 und β_1) zeigt allerdings, dass je ein Level 1-Modell pro Level 2-Einheit geschätzt wird

Mehrebenenanalyse: Modellvarianten

Klasse	Nr.	Gleichungen
Random Intercept Modell mit Prädiktor auf Level 1	2	Level 1: $Y_{ij} = \beta_{0j} + \beta_{1j}X_{ij} + r_{ij}$ Level 2: $\beta_{0j} = \gamma_{00} + u_{0j}$ $\beta_{1j} = \gamma_{10}$

Mehrebenenanalyse: Modellvarianten

- Die nächste Folie zeigt ein empirisches Beispiel mit dem Level 1-Prädiktor „ses“ (sozioökonomischer Status der Eltern)
- Pro Anstieg der ses-Skala um eine Standardabweichung erhöht sich die Mathematikleistung um $\beta_{1j} = 4,84$ Einheiten
- Wie in einer konventionellen Regression wird dabei implizit angenommen, dass der ses-Effekt nicht zwischen den Level 2-Einheiten (Schulen) variiert (das Modell ist dafür „blind“)
- u_{0j} (3,31) und r_{ij} (8,37) bilden nun den Teil der Streuung zwischen Schulen bzw. zwischen Schülerinnen und Schülern ab, der nicht durch den sozioökonomischen Status der Eltern erklärt wird

Mehrebenenanalyse: Modellvarianten

Mixed-effects ML regression
Group variable: id

Number of obs = 21580
Number of groups = 1003

Obs per group: min = 1
avg = 21.5
max = 67

Log likelihood = -77180.674

wald chi2(1) = 3048.86
Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interva]	
ses	4.839826	.0876518	55.22	0.000	4.668032	5.01162
_cons	51.081	.1206795	423.28	0.000	50.84448	51.31753

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interva]	
id: Identity				
sd(_cons)	3.312886	.1022267	3.118463	3.519429
sd(Residual)	8.365104	.041312	8.284525	8.446467

LR test vs. linear regression: chibar2(01) = 1402.63 Prob >= chibar2 = 0.0000

Mehrebenenanalyse: Modellvarianten

- Im nächsten Schritt wird das Modell um einen Level 2-Prädiktor W_j erweitert
- Level 2-Variablen variieren nur zwischen den Kontexteinheiten (z.B. Schulen), sind jedoch innerhalb einer Kontexteinheit konstant
- Auf Level 2 werden nun Niveauunterschiede in der Matheleistung zwischen Schulen (β_{0j}) als Funktion des Prädiktors W_j erklärt
- u_{0j} bildet hier verbleibende Niveauunterschiede zwischen Schulen ab, die durch W_j nicht erklärt werden

Mehrebenenanalyse: Modellvarianten

Klasse	Nr.	Gleichungen
Random Intercept Modell mit Prädiktoren auf beiden Ebenen	3	Level 1: $Y_{ij} = \beta_{0j} + \beta_{1j}X_{ij} + r_{ij}$ Level 2: $\beta_{0j} = \gamma_{00} + \gamma_{01}W_j + u_{0j}$ $\beta_{1j} = \gamma_{10}$

Mehrebenenanalyse: Modellvarianten

- Als Beispiel für einen Level 2-Prädiktor W_j wird die Variable „pminor“, der Anteil von Minderitätenschülern an der Schülerschaft einer Schule, aufgenommen
- Es zeigt sich ein negativer Segregationseffekt: Mit steigendem Anteil von Minderitätenschülern reduziert sich die individuelle Schülerleistung ($\gamma_{01} = -0,71$)
- Dennoch verbleiben signifikante unerklärte Leistungsunterschiede zwischen den Schulen ($u_{0j} = 2,96$)
- Der „Netto-ICC“ beträgt in diesem Modell noch: $2,96^2 / (8,36^2 + 2,96^2) = 0,11$

Mehrebenenanalyse: Modellvarianten

Mixed-effects ML regression
Group variable: id

Number of obs = 21580
Number of groups = 1003

Obs per group: min = 1
avg = 21.5
max = 67

Log likelihood = -77092.257

wald chi2(2) = 3439.77
Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ses	4.763394	.087467	54.46	0.000	4.591962	4.934826
pminor	-.7101004	.0515238	-13.78	0.000	-.8110852	-.6091155
_cons	53.15955	.1867613	284.64	0.000	52.7935	53.52559

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Identity				
sd(_cons)	2.963009	.0956041	2.781431	3.156442
sd(Residual)	8.362506	.0412718	8.282004	8.443789

LR test vs. linear regression: chibar2(01) = 1118.30 Prob >= chibar2 = 0.0000

Mehrebenenanalyse: Modellvarianten

- Zum Vergleich zeigt die folgende Folie ein konventionelles lineares Regressionsmodell (OLS) mit den gleichen Variablen
- Da die hierarchische Datenstruktur (Schüler(innen) in Schulen) unberücksichtigt bleibt, ist eine zentrale OLS-Annahme (unkorrelierte Residuen) verletzt
- Konsequenz: nach unten verzerrte Standardfehler
- Auch die Effekte der Kovariaten („ses“ und „pminor“) unterscheiden sich, da die Niveauunterschiede zwischen Schulen (Random Intercept) nicht im Modell kontrolliert sind

Mehrebenenanalyse: Modellvarianten

. reg math ses pminor

Source	SS	df	MS
Model	550226.065	2	275113.032
Residual	1686648.01	21577	78.1687913
Total	2236874.08	21579	103.659765

Number of obs = 21580
 F(2, 21577) = 3519.47
 Prob > F = 0.0000
 R-squared = 0.2460
 Adj R-squared = 0.2459
 Root MSE = 8.8413


math	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ses	5.774249	.0780922	73.94	0.000	5.621183	5.927316
pminor	-.622698	.0288439	-21.59	0.000	-.6792342	-.5661617
_cons	53.04134	.1029983	514.97	0.000	52.83945	53.24322

Mehrebenenanalyse: Modellvarianten


- Die nun vorzustellenden Modelle firmieren unter dem Begriff „**Random Slope**“ oder „Slopes as Outcome“
- Derartige Modelle sind anzuwenden, wenn man davon ausgeht, dass sich nicht nur Unterschiede im mittleren Y-Wert zwischen den Level 2-Einheiten ergeben, sondern dass zusätzlich der Effekt eines Level 1-Prädiktors zwischen den Level 2-Einheiten variiert
- Das folgende Schaubild soll dies verdeutlichen

Mehrebenenanalyse: Modellvarianten

Random Intercept:



Random Slope:



Mehrebenenanalyse: Modellvarianten

- In Modell Nr. 4 wird für jede Level 2-Einheit ein Koeffizient β_{1j} (slope) für den Effekt von X_{ij} geschätzt
- Der mittlere Effekt von X_{ij} über alle Schulen hinweg wird durch γ_{10} repräsentiert
- u_{1j} ist eine neue Varianzkomponente und erfasst die Abweichungen der schulspezifischen X_{ij} -Effekte vom mittleren Effekt γ_{10}
- Wenn u_{1j} statistisch signifikant ist, ist der Random Slope angemessen

Mehrebenenanalyse: Modellvarianten

Klasse	Nr.	Gleichungen
Random Slope (Nullmodell)	4	Level 1: $Y_{ij} = \beta_{0j} + \beta_{1j}X_{ij} + r_{ij}$ Level 2: $\beta_{0j} = \gamma_{00} + u_{0j}$ $\beta_{1j} = \gamma_{10} + u_{1j}$

Mehrebenenanalyse: Modellvarianten

- Im Beispiel wird überprüft, ob sich der ses-Effekt signifikant zwischen den Schulen unterscheidet (aus didaktischen Gründen ist auch die Level 2-Variable „pminor“ im Modell)
- Der mittlere ses-Effekt beträgt $\gamma_{10} = 4,72$
- Die Streuung der verschiedenen ses-Effekte in den Schulen um den mittleren ses-Effekt erfasst u_{1j} („sd(ses)“) = 0,942

Mehrebenenanalyse: Modellvarianten

Mixed-effects ML regression
Group variable: id

Number of obs = 21580
Number of groups = 1003

Obs per group: min = 1
avg = 21.5
max = 67

Log likelihood = -77076.732

wald chi2(2) = 3069.95
Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ses	4.723051	.0929388	50.82	0.000	4.540894	4.905208
pminor	-.6992667	.0493492	-14.17	0.000	-.7959893	-.6025441
_cons	53.01624	.1827749	290.06	0.000	52.658	53.37447

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Unstructured				
sd(ses)	.9418268	.1922341	.6312978	1.405102
sd(_cons)	2.932246	.0966765	2.748756	3.127984
corr(ses,_cons)	.5621496	.133498	.2481426	.7692582
sd(Residual)	8.344917	.0419922	8.263019	8.427628

LR test vs. linear regression: chi2(3) = 1149.35 Prob > chi2 = 0.0000

Note: LR test is conservative and provided only for reference.

Mehrebenenanalyse: Modellvarianten

- Ob der Random Slope für „ses“ notwendig ist, kann in STATA wie folgt getestet werden:
 - Berechnung eines Modells mit Random Intercept und festem Effekt von „ses“
 - Speichern der Schätzwerte mit estimate store („ri“, eine frei wählbare Abkürzung, steht für Random Intercept)
 - Berechnung eines Modells mit Random Slope für „ses“, speichern der Schätzwerte („rc“ für Random Component)
 - Likelihood-Ratio Test (Nullhypothese: Modellfit verschlechtert sich nicht, wenn Random Slope auf 0 restringiert wird)
 - Ergebnis: signifikante Verschlechterung der Modellanpassung ohne Random Slope, der damit angemessen ist

Mehrebenenanalyse: Modellvarianten

```
MEA Bonn.do*
1      * Test der Slope-Varianz
2
3      xtmixed math ses pminor || id:, mle
4
5      estimates store ri
6
7      xtmixed math ses pminor || id: ses, covariance(unstructured) mle
8
9      estimates store rc
10
11     lrtest ri rc
```

```
. lrtest ri rc
```

```
Likelihood-ratio test
(Assumption: ri nested in rc)
```


```
LR chi2(2) = 31.05
Prob > chi2 = 0.0000
```

Note: The reported degrees of freedom assumes the null hypothesis is not on the boundary of the parameter space. If this is not true, then the reported test is conservative.

Mehrebenenanalyse: Modellvarianten

- Im nächsten Schritt wird nun versucht, nicht nur die Unterschiede zwischen den Level 2-Einheiten bei den Intercepts durch einen Level 2-Prädiktor W_j zu erklären, sondern auch die Unterschiede zwischen den Slopes
- Das Schaubild auf der nächste Folie soll dies verdeutlichen
- Die Regressionsgeraden stehen für variierende Effekte eines Level 1-Prädiktors in verschiedenen Level 2-Einheiten
- Die Einteilung der Level 2-Einheiten in eine blaue und eine rote Gruppe entspricht einem einfachen (dichotomen) Level 2-Prädiktor W_j
- W_j trägt zur Erklärung der Varianz in den Slopes bei, da der Level 1-Prädiktor in der blauen Gruppe eher negative, in der roten Gruppe dagegen eher positive Effekte hat

Mehrebenenanalyse: Modellvarianten



Mehrebenenanalyse: Modellvarianten

- In Modell Nr. 5 wird ein Interaktionseffekte eines Level 1-Prädiktors X_{ij} mit einem Level-2-Prädiktor W_j modelliert (sog. „**cross level interaction**“)
- Die Stärke und Signifikanz des Effektes γ_{11} gibt darüber Auskunft, inwieweit der Effekt des Level 1-Prädiktors X_{ij} in Abhängigkeit von der Ausprägung des Level 2-Prädiktors W_j variiert
- u_{ij} erfasst dann den Teil der Variation im Slope, der nicht durch W_j erklärt wird

Mehrebenenanalyse: Modellvarianten

Klasse	Nr.	Gleichungen
Random Slope mit „cross level interaction“	5	Level 1: $Y_{ij} = \beta_{0j} + \beta_{1j}X_{ij} + r_{ij}$ Level 2: $\beta_{0j} = \gamma_{00} + \gamma_{01}W_j + u_{0j}$ $\beta_{1j} = \gamma_{10} + \gamma_{11}W_j + u_{1j}$

Mehrebenenanalyse: Modellvarianten

- Im Beispiel wird überprüft, ob sich der ses-Effekt in Abhängigkeit vom Minoritätenanteil der Schule unterscheidet
- Die „cross level interaction“ entspricht $\gamma_{11} = -0,189$
- Mit steigendem Anteil von Minoritätenschülern an einer Schule wird der positive Effekt des sozioökonomischen Status der Eltern auf die individuelle Leistung folglich schwächer
- $\gamma_{10} = 4,74$ ist der ses-Effekt bei $p_{\text{minor}} = 0$; da p_{minor} am Gesamtmittelwert zentriert wurde („grand mean centering“), handelt es sich hier um den ses-Effekt bei mittlerem Minoritätenanteil

Mehrebenenanalyse: Modellvarianten

Mixed-effects ML regression
Group variable: id

Number of obs = 21580
Number of groups = 1003
obs per group: min = 1
 avg = 21.5
 max = 67

Log likelihood = -77067.107

wald chi2(3) = 3152.73
Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ses	4.744627	.0920143	51.56	0.000	4.564282	4.924971
pminorc	-.7787827	.0528501	-14.74	0.000	-.8823671	-.6751984
pminor_ses	-.1899312	.0428567	-4.43	0.000	-.2739287	-.1059337
_cons	50.90841	.112466	452.66	0.000	50.68798	51.12884

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Unstructured				
sd(ses)	.8403691	.209818	.5151664	1.370858
sd(_cons)	2.952152	.0966734	2.768628	3.147841
corr(ses,_cons)	.6446315	.1688401	.197231	.8698022
sd(Residual)	8.344065	.0419751	8.262199	8.426741

LR test vs. linear regression: chi2(3) = 1162.66 Prob > chi2 = 0.0000

STATA-Syntax (metrische AV)

- Im Folgenden ist die generische STATA-Syntax für Mehrebenenanalysen im Rahmen des Befehls `xtmixed` dargestellt (für metrische AV)
- Die Option `mle` (maximum likelihood estimation“) ist in STATA 12 nicht mehr notwendig (ML ist hier Voreinstellung)
- Bei Modellen mit Random Slope ist die Option `covariance(unstructured)` empfehlenswert, da ansonsten eine Nullkorrelation zwischen Intercept und Slope angenommen wird
- „ W_{jc} “ soll bedeuten, dass es sich bei cross-level-interaction häufig empfiehlt, den Level 2-Prädiktor an seinem Gesamtmittelwert zu zentrieren, um den Haupteffekt des Level 1-Prädikators sinnvoll interpretieren zu können (s.u.)

STATA-Syntax (metrische AV)

Klasse	Nr.	Generische STATA-Syntax (xtmixed)
Nullmodell	1	<code>xtmixed Y_{ij} level2id:, mle</code>
Random Intercept mit Kovariaten (L1 + L2)	3	<code>xtmixed Y_{ij} X_{ij} W_j level2id:, mle</code>
Random Slope (Nullmodell)	4	<code>xtmixed Y_{ij} X_{ij} level2id: X_{ij}, /// covariance(unstructured) mle</code>
RS + „cross level interaction“	5	<code>xtmixed Y_{ij} X_{ij} W_{jc} X_{ij}xW_{jc} level2id: X_{ij}, /// covariance(unstructured) mle</code>

STATA-Syntax (metrische AV)

- Mehrebenenmodelle (für metrische AV) können in STATA mit `xtreg`, `xtmixed` oder `gllamm` (nicht mehr empfohlen) geschätzt werden
- `xtreg` ist einerseits schneller, andererseits ist der Output sparsamer und es sind (im Vergleich zu `xtmixed`) nur Modelle mit Random Intercept und zwei Ebenen schätzbar
- Die hierarchische Struktur der Daten wird bei `xtreg` entweder mit `xtset` definiert (z.B. `xtset id`) oder innerhalb des `xtreg`-Befehls mit der `i()`-Option (siehe nächste Folie), bei `xtmixed` immer im Random Part des Befehls (nach „||“)
- Wie die folgenden Folien zeigen, führen `xtreg` und `xtmixed` für ein 2 Level-Modell mit Random Intercept und ML-Schätzung zu (nahezu) identischen Ergebnissen

STATA-Syntax (metrische AV)

Random-effects ML regression
 Group variable: id
 Random effects u_i ~ Gaussian
 Log likelihood = -77092.257

Number of obs = 21580
 Number of groups = 1003
 Obs per group: min = 1
 avg = 21.5
 max = 67
 LR chi2(2) = 2780.94
 Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ses	4.763393	.0904196	52.68	0.000	4.586174	4.940612
pminor	-.7101005	.0515622	-13.77	0.000	-.8111605	-.6090404
_cons	53.15955	.1867911	284.59	0.000	52.79344	53.52565
/sigma_u	2.963014	.0956041			2.781435	3.156446
/sigma_e	8.362505	.0412718			8.282004	8.443789
rho	.1115404	.0065395			.0992452	.1248889

Likelihood-ratio test of sigma_u=0: chibar2(01)= 1118.30 Prob>=chibar2 = 0.000

Mixed-effects ML regression
 Group variable: id
 Log likelihood = -77092.257

Number of obs = 21580
 Number of groups = 1003
 Obs per group: min = 1
 avg = 21.5
 max = 67
 wald chi2(2) = 3439.77
 Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ses	4.763394	.087467	54.46	0.000	4.591962	4.934826
pminor	-.7101004	.0515238	-13.78	0.000	-.8110852	-.6091155
_cons	53.15955	.1867613	284.64	0.000	52.7935	53.52559

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Identity				
sd(_cons)	2.963009	.0956041	2.781431	3.156442
sd(Residual)	8.362506	.0412718	8.282004	8.443789

LR test vs. linear regression: chibar2(01) = 1118.30 Prob >= chibar2 = 0.0000

```

30 * Vergleich xtreg, xtmixed
31
32 xtmixed math ses pminor || id:, mle
33
34 xtreg math ses pminor, i(id) mle
35
  
```

Bestimmung des Modellfit (R^2)

- In der OLS-Regression gibt R^2 an, wie viel Varianz in der abhängigen Variablen durch die unabhängigen Variablen erklärt wird
- Unterschiede in Mehrebenenmodellen:
 - Es wird ein R^2 pro Ebene angegeben
 - Es kann je nach Berechnungsmethode vorkommen, dass sich das R^2 einer Ebene bei der Aufnahme zusätzlicher Prädiktoren reduziert und sogar negativ wird
- Im Folgenden wird je eine Berechnungsvariante für das totale R^2 sowie das Level-1 und das Level 2- R^2 demonstriert

Bestimmung des Modellfit (R²)

```

Mixed-effects ML regression      Number of obs   =   21580
Group variable: id              Number of groups =    1003

                                Obs per group: min =     1
                                avg   =    21.5
                                max   =     67

                                Wald chi2(0)   =     .
                                Prob > chi2    =     .

Log likelihood = -78482.726

```

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_cons	50.80271	.1748084	290.62	0.000	50.46009	51.14533

Random-effects Parameters		Estimate	Std. Err.	[95% Conf. Interval]	
id: Identity					
	var(_cons)	26.55735	1.363615	24.01479	29.3691
	var(Residual)	76.6162	.7551944	75.15025	78.11074

LR test vs. linear regression: chibar2(01) = 4430.18 Prob >= chibar2 = 0.0000

Totale Varianz des Nullmodells: $26,56 + 76,61 = 103,17$

(Anm.: Varianzen statt Standardabweichungen werden in **xtmixed** mit der **variance**-Option ausgegeben)

Bestimmung des Modellfit (R^2)

- Totales R^2 :

$$R^2 = \frac{(\hat{\sigma}_r^2 + \hat{\sigma}_{u0}^2)_{Baseline} - (\hat{\sigma}_r^2 + \hat{\sigma}_{u0}^2)_{Comparison}}{(\hat{\sigma}_r^2 + \hat{\sigma}_{u0}^2)_{Baseline}} = \frac{103,17 - 78,71}{103,17} = 0,237$$

- $\hat{\sigma}_r^2$ entspricht der unaufgeklärten Varianz innerhalb der Level-2-Einheiten und $\hat{\sigma}_{u0}^2$ entspricht der unaufgeklärten Varianz zwischen den Level-2-Einheiten, „Baseline“ = Nullmodell, „Comparison“ = Modell mit Kovariaten
- Die proportionale Reduzierung des Vorhersagefehlers durch die beiden Kovariaten beträgt 23,7%
- Im nächsten Schritt wird eine Variante zur Berechnung des R^2 getrennt nach Ebenen demonstriert

Bestimmung des Modellfit (R^2)

- Berechnung des Level-1- R^2 :

$$R_1^2 = \frac{\hat{\sigma}_{r_Base}^2 - \hat{\sigma}_{r_Comp}^2}{\hat{\sigma}_{r_Base}^2} = \frac{76,62 - 69,93}{76,62} = 0,087$$

- Die Vorhersagekraft des Vergleichsmodells (mit einem Level-1-Prädiktor) ist auf Level-1 um etwa 8,7% größer als im Nullmodell

Bestimmung des Modellfit (R^2)

- Berechnung des Level-2- R^2 :

$$R_2^2 = \frac{\hat{\sigma}_{u0_Base}^2 - \hat{\sigma}_{u0_Comp}^2}{\hat{\sigma}_{u0_Base}^2} = \frac{26,56 - 8,78}{26,56} = 0,669$$

- Die Vorhersagekraft des Vergleichsmodells (mit einem Level-2-Prädiktor) ist auf Level-2 um etwa 67% größer als im Nullmodell

Visualisierung und Diagnostik

- Zum besseren Verständnis und zur Diagnostik von Mehrebenenmodellen stehen in STATA Optionen zur Visualisierung zur Verfügung:

```
* Visualisierung der Random Intercepts

xtmixed math || id:, mle
predict ebi, reffects
egen pickone = tag(id)
histogram ebi if pickone==1, normal xtitle(Predicted random intercepts)

* Visualisierung des Effekts eines Level 1-Prädikators (ses)
* im Radom Intercept Modell und Random Slope Modell


xtmixed math ses || id:, mle
predict predi, fitted
xtmixed math ses || id: ses, covariance(unstructured) mle
predict preds, fitted

sort id ses
twoway (line preds ses, connect(ascending)), xtitle(ses) ///
yttitle(Empirical Bayes regression lines for random slope) saving(rs)
twoway (line predi ses, connect(ascending)), xtitle(ses) ///
yttitle(Empirical Bayes regression lines for random intercept) saving(ri)
graph combine rs.gph ri.gph
```

Visualisierung und Diagnostik

- Um Niveauunterschiede in der Matheleistung zwischen Schulen (Random Intercept) zu visualisieren, greifen wir auf das Nullmodell zurück
- Mit dem predict-Befehl wird der einzige Random Effect („reffects“) dieses Modells, der Random Intercept, nach der „Empirical Bayes“-Methode geschätzt und in der Variable „ebi“ gespeichert
- Durch Erzeugung der Variable „pickone“ wählen wir eine Beobachtung pro Level 2-Einheit (hier: Schule) aus
- „ebi“ wird dann per Histogramm dargestellt


Visualisierung und Diagnostik



Visualisierung und Diagnostik

- Um den Unterschied zwischen Modellen mit Random Intercept und Random Slope zu visualisieren, schätzen wir entsprechende Modelle mit der einzigen Level 1-Kovariate „ses“
- Die vorhergesagten Werte werden mit predict in den Variablen „predi“ und „preds“ gespeichert
- Der Effekt von ses auf die Matheleistung in den verschiedenen Schulen wird dann mit Hilfe von „Spaghetti-Plots“ dargestellt

Visualisierung und Diagnostik



Visualisierung und Diagnostik

- Voraussetzungen und Annahmen der bisher vorgestellten Modelle:
 - Mindestens 30 Level 2-Einheiten für Modelle mit Random Intercept, mindestens 50 Level 2-Einheiten für Modelle mit Random Slope
 - Bei einer geringeren Anzahl von Level 2-Einheiten kann ein „restricted maximum likelihood“-Schätzer (REML) verwendet werden (reml-Option in xtmixed)
 - Kovariaten und Level 1-Residuen korrelieren mit 0 („level-1 exogeneity“)
 - Level 1-Kovariaten und Random Intercept korrelieren mit 0 („level-2 exogeneity“)
 - Homoskedastizität der Level 1-Residuen
 - Symmetrische Verteilung der totalen Residuen

Visualisierung und Diagnostik

Mixed-effects ML regression
Group variable: id

Number of obs = 21580
Number of groups = 1003

Obs per group: min = 1
 avg = 21.5
 max = 67

Log likelihood = -77092.257

wald chi2(2) = 3439.77
Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ses	4.763394	.087467	54.46	0.000	4.591962	4.934826
pminor	-.7101004	.0515238	-13.78	0.000	-.8110852	-.6091155
_cons	53.15955	.1867613	284.64	0.000	52.7935	53.52559

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Identity				
sd(_cons)	2.963009	.0956041	2.781431	3.156442
sd(Residual)	8.362506	.0412718	8.282004	8.443789

LR test vs. linear regression: chibar2(01) = 1118.30 Prob >= chibar2 = 0.0000

Visualisierung und Diagnostik

```
* Test auf Homoskedastizität der Level 1-Residuen
```

```
estimates restore ri  
predict res1, residuals  
predict fit1, fitted  
twoway (scatter res1 fit1)
```


```
* Test auf Symmetrie der totalen Residuen
```

```
estimates restore ri  
predict fixed, xb  
gen totres = math - fixed  
histogram totres, normal xtitle(Predicted total-residuals)
```

Visualisierung und Diagnostik

- Um die Homoskedastizität der Level 1-Residuen für das Modell mit den Prädiktoren „ses“ und „pminor“ zu überprüfen, speichern wir mit predict die Residuen und die vorhergesagten Werte in den Variablen „res“ und „fit“
- Anschließend wird ein Scatterplot dieser Variablen erzeugt, in dem kein systematisches Muster (z.B. ein Trichter) erkennbar sein sollte


Visualisierung und Diagnostik



Visualisierung und Diagnostik

- Um die Symmetrie der Verteilung der totalen Residuen zu überprüfen, werden die Vorhersagewerte mit predict in der Variable „fixed“ gespeichert
- Anschließend werden die totalen Residuen als Differenz zwischen Vorhersagewerten („fixed“) und Beobachtungswerten („math“) gebildet (Variable „totres“)
- Diese Variable wird per Histogramm dargestellt; die Verteilung sollte symmetrisch und den zentralen Wert 0 sein

Visualisierung und Diagnostik



Visualisierung und Diagnostik

- Um einen „echten“ Level 1-Effekt zu identifizieren, sollte der Level 1-Prädiktor nicht mit dem Random Intercept korrelieren („level-2 exogeneity“)
- Ist diese Voraussetzung nicht erfüllt, kann der clusterspezifische Mittelwert des Level 1-Prädiktors als zusätzlicher Regressor aufgenommen werden
- Am Beispiel der Variable „ses“ kann der schulspezifische Mittelwert der individuellen sozialen Herkunft („ses_mean“) mit folgendem Befehl erzeugt werden: `egen ses_mean = mean(ses), by(id)`

Visualisierung und Diagnostik

Mixed-effects ML regression
Group variable: id

Number of obs = 21580
Number of groups = 1003
Obs per group: min = 1
 avg = 21.5
 max = 67

Log likelihood = -76956.73

wald chi2(3) = 4173.50
Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ses	4.216634	.0941995	44.76	0.000	4.032007	4.401262
ses_mean	3.954439	.2271654	17.41	0.000	3.509203	4.399675
pm1nor	-.4237252	.0482528	-8.78	0.000	-.5182989	-.3291515
_cons	52.50486	.1688981	310.87	0.000	52.17383	52.8359

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Identity				
sd(_cons)	2.464187	.0870663	2.299315	2.640882
sd(Residual)	8.358056	.0411981	8.277698	8.439194

LR test vs. linear regression: chibar2(01) = 746.47 Prob >= chibar2 = 0.0000

Zentrierung

Typ	Funktion
Zentrierung eines Prädiktors am Gesamtmittelwert bei „cross level interaction“	Interpretierbarkeit der konditionalen Haupteffekte
Zentrierung eines Prädiktors am Gesamtmittelwert	Interpretierbarkeit der festen Regressionskonstante (γ_{00})
Zentrierung eines Level 1-Prädiktors am Gruppenmittelwert	Differenzierung zwischen Level 1- und Level 2-Effekten (Binnenregression)

Zentrierung

- Im Unterschied zu konventionellen Modellen mit Festeffekten wird die Kontextvarianz (z.B. die Schulvarianz) durch den Random Intercept nicht vollständig, sondern nur teilweise kontrolliert
- Dadurch wird die Identifizierung von reinen Level 1-Effekten erschwert
- Abhilfe schafft eine Zentrierung des Level 1-Prädiktors am Gruppenmittelwert, am Beispiel der Variable „ses“ durch folgenden Befehl: `gen ses_gc = ses - ses_mean` („ses_mean“ wurde weiter oben bereits gebildet)
- Wird „ses_gc“ anstelle von „ses“ in das Modell aufgenommen, ist das Resultat eine Binnenregression innerhalb von Schulen:

Zentrierung

Mixed-effects ML regression
Group variable: id

Number of obs = 21580
Number of groups = 1003
Obs per group: min = 1
 avg = 21.5
 max = 67

Log likelihood = -77418.607

wald chi2(2) = 2244.42
Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ses_gc	4.216634	.094163	44.78	0.000	4.032078	4.40119
pminor	-1.112095	.0719114	-15.46	0.000	-1.253039	-.9711508
_cons	54.06114	.2627737	205.73	0.000	53.54611	54.57617

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Identity				
sd(_cons)	4.591989	.1197349	4.363208	4.832765
sd(Residual)	8.354819	.0411699	8.274516	8.435901

LR test vs. linear regression: chibar2(01) = 3861.08 Prob >= chibar2 = 0.0000

Zentrierung

- Wiederholung zum „grand mean centering“ bei „cross level interaction“
- Ist ein Interaktionseffekt eines Level 1- mit einem Level 2-Prädiktor im Modell (hier: $ses \times pminor$), gilt der Haupteffekt von „ses“ bei „pminor“ = 0 und der Haupteffekt von „pminor“ bei „ses“ = 0
- Indem „pminor“ an seinem Mittelwert zentriert wird, gilt der „ses“-Haupteffekt (4,74) für mittleren Minoritätenanteil
- Bei „ses“ handelt es sich um eine z-standardisierte Variable, die somit bereits zentriert ist
- Der Haupteffekt von „pminor“ (-0,78) gilt somit für Schüler mit mittlerem sozioökonomischen Status

Zentrierung

Mixed-effects ML regression
Group variable: id

Number of obs = 21580
Number of groups = 1003
Obs per group: min = 1
 avg = 21.5
 max = 67

Log likelihood = -77067.107

wald chi2(3) = 3152.73
Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ses	4.744627	.0920143	51.56	0.000	4.564282	4.924971
pminorc	-.7787827	.0528501	-14.74	0.000	-.8823671	-.6751984
pminor_ses	-.1899312	.0428567	-4.43	0.000	-.2739287	-.1059337
_cons	50.90841	.112466	452.66	0.000	50.68798	51.12884

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Unstructured				
sd(ses)	.8403691	.209818	.5151664	1.370858
sd(_cons)	2.952152	.0966734	2.768628	3.147841
corr(ses,_cons)	.6446315	.1688401	.197231	.8698022
sd(Residual)	8.344065	.0419751	8.262199	8.426741

LR test vs. linear regression: chi2(3) = 1162.66 Prob > chi2 = 0.0000

Anwendungsempfehlungen

- Modelle schrittweise aufbauen (erst Nullmodell, dann Random Intercept, dann Random Slope)
- Bei Modellen mit Random Slope:
 - Random Intercept muss vorhanden sein
 - Fester Slope muss vorhanden sein
 - Random Slopes nur für Level 1-Prädiktoren sinnvoll
 - Anzahl der Random Slopes pro Modell so gering wie möglich halten (und theoretisch fundiert begründen)
- Kontexteinheiten, die wenig Informationen für Modellparameter liefern (z.B. eine Schule mit nur einem Schüler im Datensatz) nicht löschen

Logistisches Mehrebenenmodell

- Logistische Mehrebenenmodelle kommen bei binären (dichotomen) abhängigen Variablen zum Einsatz
- In STATA stehen die Befehle `xtlogit` (äquivalent zu `xtreg`), `xtnlogit` (äquivalent zu `xtnmixed`) und `gllamm` zur Verfügung
- Wie bei metrischen AV, können mit `xtlogit` lediglich Modelle mit zwei Ebenen und Random Intercept geschätzt werden
- Für Modelle mit Random Slope oder mehr als zwei Ebenen kommt `xtnlogit` zum Einsatz (`gllamm` wird nicht mehr empfohlen)
- (eine multinomiale logistische Mehrebenenregression ist mit STATA derzeit nur über Umwege schätzbar: <http://www.stata.com/stata-news/news29-2/xtnlogit/>)

Logistisches Mehrebenenmodell

- Formal ist das logit_{ij} (i für Personen, j für Cluster) definiert als die logarithmierte Chance, dass die abhängige Variable den Wert 1 aufweist (→ Skript logistische Regression)
- Eine Chance ist das Verhältnis von zwei Wahrscheinlichkeiten: Wahrscheinlichkeit, dass die abhängige Variable den Wert 1 annimmt, π_{ij} , dividiert durch die Gegenwahrscheinlichkeit ($AV = 0$)

Logistisches Mehrebenenmodell

Klasse	Gleichungen
Logistisches Modell mit Random Intercept und Level 1-Prädiktor	Level 1: $\text{logit}_{ij} = \ln\left(\frac{\pi_{ij}}{1 - \pi_{ij}}\right) = \beta_{0j} + \beta_{1j}X_{ij}$ Level 2: $\beta_{0j} = \gamma_{00} + u_{0j}$ $\beta_{1j} = \gamma_{10}$

Logistisches Mehrebenenmodell

- Beispieldaten: PISA 2000 für die USA (2.069 15jährige Schüler in 148 Schulen, pisaUSA2000.dta)
- AV: Lesefertigkeit („pass_read“, dichotom, 0 oder 1)
- Unabhängige Variablen:
 - Geschlecht („female“)
 - International socioeconomic index („isei“)
 - Dummy: Höchstes Bildungsniveau eines Elternteils ist High School („high_school“)
 - Dummy: Höchstes Bildungsniveau eines Elternteils ist College („college“)
 - Dummy: Testsprache wird zu Hause gesprochen („test_lang“)
 - Dummy: Ein Elternteil nicht in USA geboren („one_for“)
 - Dummy: Beide Elternteile nicht in USA geboren („both_for“)

Logistisches Mehrebenenmodell

Random-effects logistic regression
Group variable: id_school

Number of obs = 2069
Number of groups = 148

Random effects u_i ~ Gaussian

Obs per group: min = 1
avg = 14.0
max = 28

Log likelihood = -1315.448

wald chi2(0) = .
Prob > chi2 = .

pass_read	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_cons	-.7058536	.0972925	-7.25	0.000	-.8965434	-.5151639
/lnsig2u	-.1933886	.2076942			-.6004617	.2136845
sigma_u	.9078335	.0942759			.7406472	1.112759
rho	.2003295	.0332721			.1429123	.2734551

Likelihood-ratio test of rho=0: chibar2(01) = 132.85 Prob >= chibar2 = 0.000

xtlogit pass_read, i(id_school) intpoints(30)

Logistisches Mehrebenenmodell

- Die Intraklassenkorrelation wird bei logistischen Mehrebenenmodellen wie folgt berechnet:

$$\rho = \frac{\sigma_{u_0}^2}{(\pi^2/3 + \sigma_{u_0}^2)} = \frac{0,908^2}{3,29 + 0,908^2} = 0,20$$

- $\sigma_{u_0}^2$ ist wiederum die Varianz des Random Intercept (Level 2-Varianz, geschätzt durch u_{0j}) und $\pi^2/3$ ist die Residualvarianz (Level 1) in der Logit-Funktion
- Der Likelihood-Ratio-Test in der letzten Zeile des Modelloutputs testet wiederum die Nullhypothese, dass die Varianz des Random Intercept 0 ist (abzulehnen, da $p < 0,000$)

Logistisches Mehrebenenmodell

Mixed-effects logistic regression
Group variable: id_school

Number of obs = 2069
Number of groups = 148
Obs per group: min = 1
 avg = 14.0
 max = 28

Integration points = 30
Log likelihood = -1315.448

wald chi2(0) = .
Prob > chi2 = .

pass_read	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_cons	-.7058538	.0972925	-7.25	0.000	-.8965436	-.515164

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id_school: Identity sd(_cons)	.9078336	.0942759	.7406473	1.112759

LR test vs. logistic regression: chibar2(01) = 132.85 Prob>=chibar2 = 0.0000

xtmelogit pass_read || id_school:, intpoints(30)

Logistisches Mehrebenenmodell

- Eine Alternative zum logistischen Mehrebenenmodell ist das konventionelle logistische Modell (logit) mit robusten Standardfehlern (cluster-Option, siehe nächste Folie)
- Die Standardfehler sind in beiden Fällen korrekt, die Koeffizienten geben aber inhaltlich verschiedene Aspekte wieder:
 - Obwohl im logistischen Mehrebenenmodell nicht die gesamte Level 2-Varianz (Schulvarianz) kontrolliert wird, handelt es sich um schülerspezifische (konditionale) Effekte innerhalb von Schulen
 - Die logistische Regression schätzt dagegen „population-averaged“ oder marginale Wahrscheinlichkeiten, in die beide Varianzquellen (innerhalb und zwischen Schulen) voll einfließen

Logistisches Mehrebenenmodell

```

Random-effects logistic regression           Number of obs   =   2069
Group variable: id_school                  Number of groups =   148

Random effects u_i ~ Gaussian              Obs per group:  min =    1
                                                avg   =   14.0
                                                max   =    28

Log likelihood = -1252.8108                Wald chi2(7)    =   116.85
                                                Prob > chi2     =    0.0000
    
```

pass_read	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
female	.5422158	.1031921	5.25	0.000	.339963	.7444687
isei	.0206763	.003284	6.30	0.000	.0142397	.0271129
high_school	.444795	.2565117	1.73	0.083	-.0579587	.9475486
college	.7968814	.2550522	3.12	0.002	.2969882	1.296775
one_for	.0112566	.2244283	0.05	0.960	-.4286149	.4511281
both_for	.1507841	.2376408	0.63	0.526	-.3149833	.6165514
test_lang	.7825109	.2834803	2.76	0.006	.2268997	1.338122
_cons	-3.279322	.3811213	-8.60	0.000	-4.026306	-2.532338
/lnsig2u	-.6666381	.2500984			-1.156822	-.1764541
sigma_u	.7165416	.089603			.5607888	.915553
rho	.1349964	.0292046			.0872512	.2030562

Likelihood-ratio test of rho=0: chibar2(01) = 58.35 Prob >= chibar2 = 0.000

xtlogit pass_read female isei high_school college one_for both_for test_lang, i(id_school) intpoints(30)

Logistisches Mehrebenenmodell

- Bei logistischen Regressionen können Logit-Koeffizienten, Odds-Ratios oder auch Average Marginal Effects (AME) interpretiert werden
- Um Odds-Ratios anstelle von Logit-Koeffizienten zu erhalten, wird bei `xtlogit` oder `xtnmelogit` die `or`-Option verwendet
- Average Marginal Effects lassen sich in STATA 12 mit dem Befehl `margins, dydx(varlist)` erzeugen
- Korrekte AME für Interaktionseffekte erzeugt der Befehl `inteff` (muss zunächst installiert werden)

Logistisches Mehrebenenmodell

```

Random-effects logistic regression      Number of obs   =      2069
Group variable: id_school              Number of groups =      148

Random effects u_i ~ Gaussian          Obs per group:  min =      1
                                          avg =     14.0
                                          max =      28

Log likelihood = -1252.8108            Wald chi2(7)    =     116.85
                                          Prob > chi2     =      0.0000
    
```

pass_read	OR	Std. Err.	z	P> z	[95% Conf. Interval]	
female	1.719813	.1774712	5.25	0.000	1.404896	2.105323
isei	1.020892	.0033526	6.30	0.000	1.014342	1.027484
high_school	1.56017	.4002019	1.73	0.083	.9436889	2.579379
college	2.218611	.5658617	3.12	0.002	1.345799	3.657481
one_for	1.01132	.2269689	0.05	0.960	.6514108	1.570082
both_for	1.162746	.2763158	0.63	0.526	.7298011	1.852528
test_lang	2.186957	.6199591	2.76	0.006	1.254704	3.811878
/lnsig2u	-.6666381	.2500984			-1.156822	-.1764541
sigma_u	.7165416	.089603			.5607888	.915553
rho	.1349964	.0292046			.0872512	.2030562

Likelihood-ratio test of rho=0: chibar2(01) = 58.35 Prob >= chibar2 = 0.000

xtlogit pass_read female isei high_school college one_for both_for test_lang, i(id_school) intpoints(30) or


Logistisches Mehrebenenmodell

- Interpretationsbeispiel für den Effekt von „female“:
 - Die logarithmierte Chance, eine Lesefertigkeit zu besitzen, liegt bei weiblichen Schülern, verglichen mit männlichen Schülern, um 0,54 Einheiten höher (xtlogit-Modell mit Logit-Koeffizienten)
 - Die Chance, eine Lesefertigkeit zu besitzen, ist bei weiblichen Schülern 1,72 mal so hoch (oder 72% höher) als bei Männern (xtlogit-Modell mit Odds Ratios)
 - Die Wahrscheinlichkeit, eine Lesefertigkeit zu besitzen, ist bei weiblichen Schülern 54,2 Prozentpunkte höher als bei männlichen (Average Marginal Effect)
 - (gilt jeweils bei Kontrolle aller anderen Prädiktoren)

Logistisches Mehrebenenmodell

- Interpretationsbeispiel für den Effekt von „isei“:
 - Die logarithmierte Chance, eine Lesefertigkeit zu besitzen, erhöht sich pro Einheit Anstieg von „isei“ um 0,0207 (Logit)
 - Die Chance, eine Lesefertigkeit zu besitzen, erhöht sich pro Einheit Anstieg von „isei“ um 0,0209 (0,209%; Odds Ratio)
 - Die Wahrscheinlichkeit, eine Lesefertigkeit zu besitzen, erhöht sich pro Einheit Anstieg von „isei“ um durchschnittlich 0,0207 (etwa 2,1 Prozentpunkte; Average Marginal Effect)
 - Bei metrischen Prädiktoren zu beachten: Der Anstieg der Wahrscheinlichkeit über den Wertebereich eines metrischen Prädiktors verläuft in logistischen Modellen nicht linear (siehe die s-förmige logistische Funktion nächste Folie)

Logistisches Mehrebenenmodell



Panelanalyse: RE- und FE-Modelle

- **Paneldaten** = Hier werden (a) die Werte der gleichen Variablen (b) zu mehreren Zeitpunkten mit (c) einer identischen Stichprobe erhoben
- Paneldaten sind hierarchisch mit personenspezifischen Messzeitpunkten auf Ebene 1 und Personen auf Ebene 2
- Bei der modernen Panelanalyse werden z.B. die folgenden Varianten verwendet, die im Folgenden vorgestellt werden:
 - „Random Effects“ **(RE-)Modell** (ein Modell mit Random Intercept, erweiterbar um einen Random Slope zu sog. Wachstumskurven-modellen) für metrische AV und binäre AV
 - „Fixed Effects“ **(FE-)Modell** für metrische und binäre AV


Panelanalyse: RE- und FE-Modelle

- Zwei Variablenarten:
 - „**between person**“ (nur Level 2-Variation): Variablen, die sich zwischen Personen unterscheiden, über die Zeit aber nicht variieren (z.B. Geschlecht, Geburtskohorte)
 - „**within person**“ (Variation zwischen und innerhalb von Personen): alle zeitveränderlichen Merkmale wie Alter, Lebenszufriedenheit, Familienstand usw.
- Im RE-Modell können beide Variablenarten berücksichtigt werden, hier werden gleichzeitig die Variation zwischen und innerhalb von Personen analysiert
- Das FE-Modell berücksichtigt nur „within person“ Variablen, nur die Variation innerhalb von Personen über die Zeit wird analysiert

Panelanalyse: RE- und FE-Modelle

- Vereinfachtes Beispiel: Datensatz von 5, im Ausgangszustand ledigen Personen
- AV: Lebenszufriedenheit (10-fach abgestuft), UV: Heirat
- Auf der nächsten Folie ist die Entwicklung der Lebenszufriedenheit bei diesen 5 Personen über 4 Panelwellen dargestellt
- Die gestrichelten Linien stehen für Personen, die jeweils zwischen Welle 2 und 3 heiraten
- Die durchgezogenen Linien repräsentieren Personen, die innerhalb des Beobachtungszeitraums nicht heiraten

Panelanalyse: RE- und FE-Modelle



Selbstselektion: Personen, die heiraten, sind bereits vor der Heirat zufriedener

Positiver Effekt der Heirat

— Keine Heirat

- - - Heirat zwischen Welle 2 und 3

Panelanalyse: RE- und FE-Modelle

- Die Abbildung deutet auf das Vorliegen von drei Effekten hin:
 - Erstens gibt es einen schwachen, negativen Alters- bzw. Periodeneffekt, da die Lebenszufriedenheit über die Zeit hinweg tendenziell abfällt
 - Zweitens finden sich Hinweise auf eine Selbstselektion: Diejenigen Personen, die heiraten, sind im Durchschnitt schon vor der Heirat zufriedener als die Personen, die nicht heiraten
 - Drittens zeigt sich ein kausaler (positiver) Effekt der Heirat auf die Zufriedenheit. Diese erhöht sich im Anschluss an die Heirat zwischen den Wellen 2 und 3 deutlich; in der Kontrollgruppe ohne Heirat zeigt sich dieser Effekt nicht

Panelanalyse: RE- und FE-Modelle

- Beispieldaten: Panel Study of Income Dynamics (returns_wide.dta; 595 Haushaltsvorstände im Alter von 18-65 Jahren im Jahr 1976 und Erwerbseinkommen im Beobachtungszeitraum der Jahre 1976-1982)
- Abhängige Variable: Logarithmierter Stundenlohn in Dollar („lwage“)
- Unabhängige Variablen:
 - Berufserfahrung (Vollzeitjahre, „exp“)
 - Arbeitswochen („wks“)
 - Dummy: Blue-Collar-Beruf („occ“)
 - Dummy: Arbeit in produzierender Industrie („ind“)
 - Dummy: Wohnort Süden der USA („south“)
 - Dummy: Wohnort in „standard metropolitan statistical area“ („smsa“)
 - Dummy: verheiratet („ms“)
 - Dummy: In einer Partnerschaft („union“)
 - Weiblich („fem“)
 - Bildungsjahre („ed“)
 - Schwarz („blk“)

Panelanalyse: RE- und FE-Modelle

- Bei Paneldaten müssen die Daten ab drei Wellen vom Wide- in das Long-Format umstrukturiert werden, um entsprechende Regressionsverfahren wie xtreg anwenden zu können
- Im Wide-Format entspricht jede Zeile einem logischen Fall (z.B. einer Person) und jede Spalte einer Variablen (siehe nächste Folie)
- Bei Paneldaten sind dabei wellenspezifische Variablenausprägungen in verschiedenen Variablen codiert (z.B. „occ1976“ und „occ1977“)

Panelanalyse: RE- und FE-Modelle

	nr	exp1976	wks1976	occ1976
1	1	3	32	0
2	2	30	34	1
3	3	6	50	1
4	4	31	52	1
5	5	10	50	1
6	6	26	44	1
7	7	15	46	1
8	8	23	51	1
9	9	3	50	0
10	10	3	49	0
11	11	24	47	1
12	12	21	47	1
13	13	26	48	1
14	14	15	45	0
15	15	9	50	0
16	16	16	50	1
17	17	16	49	0
18	18	25	47	0
19	19	40	37	1
20	20	25	50	0

[...]

exp1978	wks1978	occ1978
5	40	0
32	33	1
8	50	1
33	46	1
12	40	1
28	47	1
17	49	1
25	50	1
5	50	0
5	46	0
26	45	1
23	47	1
28	50	1
17	45	0
11	48	0
18	48	1
18	49	0
27	47	0
42	50	1
27	49	0

...

Panelanalyse: RE- und FE-Modelle

- Mit dem folgenden Befehl werden Daten vom Wide- ins Long-Formst umstrukturiert:

```
reshape long [stubnames], i[varname] j[varname]
```

- Die unter "i" angegebene Variable identifiziert den jeweiligen logischen Fall, z.B. eine Person
- Die unter „j“ angegebene Variable wird neu gebildet und entspricht der Nummer der fallpezifischen Beobachtung (z.B. Panelwelle)

Panelanalyse: RE- und FE-Modelle

- Um die (zeitliche) Ordnung der fallspezifischen Beobachtungen festzulegen, müssen die Variablen der Variablenliste im Wide-Format aufsteigende Nummern am Ende des Variablennamens haben (z.B. „ind1977“, „ind1978“)
- „stubname“ bedeutet dabei, dass die Zahlen nicht mit angegeben werden (geschrieben wird im Beispiel „ind“ anstelle von „ind1977“, „ind1978“ usw.)
- Für das Beispiel erzeugt der folgende Befehl das Long-Format:

```
reshape long exp wks occ ind south smsa ms fem union ed blk lwage, i(nr) j(year)
```

Panelanalyse: RE- und FE-Modelle

```
. reshape long exp wks occ ind south smsa ms fem union ed blk lwage, i(nr) j(year)
(note: j = 1976 1977 1978 1979 1980 1981 1982)
```

Data	wide	->	long
Number of obs.	595	->	4165
Number of variables	85	->	14
j variable (7 values)		->	year
xij variables:			
exp1976 exp1977 ... exp1982		->	exp
wks1976 wks1977 ... wks1982		->	wks
occ1976 occ1977 ... occ1982		->	occ
ind1976 ind1977 ... ind1982		->	ind
south1976 south1977 ... south1982		->	south
smsa1976 smsa1977 ... smsa1982		->	smsa
ms1976 ms1977 ... ms1982		->	ms
fem1976 fem1977 ... fem1982		->	fem
union1976 union1977 ... union1982		->	union
ed1976 ed1977 ... ed1982		->	ed
blk1976 blk1977 ... blk1982		->	blk
lwage1976 lwage1977 ... lwage1982		->	lwage

Panelanalyse: RE- und FE-Modelle

	nr	year	exp	wks	occ	ind	south
1	1	1976	3	32	0	0	1
2	1	1977	4	43	0	0	1
3	1	1978	5	40	0	0	1
4	1	1979	6	39	0	0	1
5	1	1980	7	42	0	1	1
6	1	1981	8	35	0	1	1
7	1	1982	9	32	0	1	1
8	2	1976	30	34	1	0	0
9	2	1977	31	27	1	0	0
10	2	1978	32	33	1	1	0
11	2	1979	33	30	1	1	0
12	2	1980	34	30	1	1	0
13	2	1981	35	37	1	1	0
14	2	1982	36	30	1	1	0
15	3	1976	6	50	1	1	0
16	3	1977	7	51	1	1	0
17	3	1978	8	50	1	1	0
18	3	1979	9	52	1	1	0
19	3	1980	10	52	1	1	0
20	3	1981	11	52	1	1	0

Panelanalyse: RE- und FE-Modelle

- Bei Benutzung von xtreg kann der Datensatz mit xtset zum Paneldatensatz erklärt werden, wobei zunächst die Variable angegeben wird, welche die Untersuchungseinheit identifiziert und dann die Variable, welche den Messzeitpunkt definiert:

```
. xtset nr year
      panel variable:  nr (strongly balanced)
      time variable:  year, 1976 to 1982
      delta: 1 unit
```

- STATA merkt sich diese Struktur für alle weiteren Befehle

Panelanalyse: RE- und FE-Modelle

- Mit `xtdescribe` erhält man einen Überblick darüber, ob der Paneldatensatz balanciert ist (jede Untersuchungseinheit ist zu jedem Messzeitpunkt vertreten) oder welche Muster im unbalancierten Datensatz auftreten:

```
. xtdescribe
```

```

nr: 1, 2, ..., 595
year: 1976, 1977, ..., 1982
Delta(year) = 1 unit
Span(year) = 7 periods
(nr*year uniquely identifies each observation)
n = 595
T = 7

```

```
Distribution of T_i:  min      5%      25%      50%      75%      95%      max
                    7        7        7        7        7        7
```

Freq.	Percent	Cum.	Pattern
595	100.00	100.00	1111111
595	100.00		xxxxxxx

Panelanalyse: RE- und FE-Modelle

- Bei Paneldaten sind Messzeitpunkte (Level 1) in Personen (Level 2) geschachtelt
- Die Intraklassenkorrelation (ICC; $\rho = 0,68$) sagt daher aus, dass 68% der Varianz in den Daten durch Unterschiede zwischen Personen zustande kommen und 32% durch Unterschiede innerhalb von Personen, also Veränderungen des Einkommens
- Je höher der ICC bei Paneldaten, desto zeitlich stabiler ist das Merkmal

Panelanalyse: RE- und FE-Modelle

```
. xtreg lwage, mle
Iteration 0: log likelihood = -1120.3668
Iteration 1: log likelihood = -1120.3661
```

```
Random-effects ML regression           Number of obs   =   4165
Group variable: nr                    Number of groups =    595

Random effects u_i ~ Gaussian         Obs per group: min =    7
                                       avg =   7.0
                                       max =    7

Log likelihood = -1120.3661           wald chi2(0)   =   0.00
                                       Prob > chi2     =    .
```

lwage	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_cons	6.676346	.0161486	413.43	0.000	6.644696	6.707997
/sigma_u	.3814879	.0117943			.3590579	.4053191
/sigma_e	.259633	.0030726			.2536801	.2657256
rho	.6834387	.0144449			.6546137	.7111905

Likelihood-ratio test of sigma_u=0: chibar2(01)= 3136.88 Prob>=chibar2 = 0.000

Panelanalyse: RE- und FE-Modelle

```

Random-effects ML regression          Number of obs   =       4165
Group variable: nr                   Number of groups =        595

Random effects u_i ~ Gaussian        Obs per group:  min =         7
                                       avg =        7.0
                                       max =         7

Log likelihood = 307.87331           LR chi2(12)     =    2856.48
                                       Prob > chi2      =     0.0000
    
```

lwage	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
exp	.1072079	.0024832	43.17	0.000	.102341	.1120748
expq	-.0005146	.0000545	-9.44	0.000	-.0006214	-.0004077
wks	.0008401	.0006039	1.39	0.164	-.0003435	.0020237
occ	-.0251183	.0137761	-1.82	0.068	-.0521189	.0018822
ind	.0137957	.0152879	0.90	0.367	-.0161681	.0437595
south	.0057702	.0315859	0.18	0.855	-.0561369	.0676774
smsa	-.0474777	.018957	-2.50	0.012	-.0846327	-.0103227
ms	-.0413826	.0189917	-2.18	0.029	-.0786056	-.0041596
fem	-.1756221	.1130883	-1.55	0.120	-.3972711	.046027
union	.0387287	.0148103	2.61	0.009	.009701	.0677565
ed	.1356154	.0126737	10.70	0.000	.1107754	.1604554
blk	-.2612074	.1374601	-1.90	0.057	-.5306244	.0082095
_cons	3.126217	.1775977	17.60	0.000	2.778132	3.474302
/sigma_u	.8394941	.0276607			.7869936	.8954969
/sigma_e	.1533452	.0018566			.1497493	.1570276
rho	.9677113	.0022638			.9630158	.9719034

Likelihood-ratio test of sigma_u=0: chibar2(01)= 3662.25 Prob>=chibar2 = 0.000

Panelanalyse: RE- und FE-Modelle

- „fem“, „ed“ und „blk“ sind Level 2-Variablen, tragen also ausschließlich zu zeitkonstanten Unterschieden zwischen Personen bei
- Alle anderen Variablen können sich prinzipiell verändern und zu Level 1-Varianz beitragen
- Die Varianz zwischen Personen wird durch den Random Intercept nur teilweise kontrolliert, in den Effekten zeitveränderlicher Variablen ist auch Level 2-Varianz zwischen Personen enthalten
- Das Modell ist daher anfällig für Selbstselektion
- Beispiel: Haben Personen, die heiraten, mehr Einkommen (Selektion) oder führt eine Heirat zu Veränderungen des Einkommens (Kausalität)?

Panelanalyse: RE- und FE-Modelle

- Zur Bestimmung von kausalen Effekten von zeitveränderlichen Variablen (z.B. Ereignisse wie die Heirat) empfiehlt es sich daher explizit nicht, das konventionelle Mehrebenenmodell zu verwenden
- Alternative Möglichkeiten:
 - a. Test auf signifikante Effekt-Unterschiede zwischen RE- und FE-Modell mit dem Hausman-Test
 - b. Berechnung eines Modells mit Fixed Effects, das ausschließlich Veränderungen innerhalb von Personen berücksichtigt (xtreg mit fe-Option)
 - c. Berechnung eines **Hybrid-Modells** (xtreg mit Random Intercept), bei dem bei zeitveränderlichen Variablen eine Zentrierung um den Personenmittelwert vorgenommen wird

Panelanalyse: RE- und FE-Modelle

- Der **Hausman-Test** vergleicht die standardisierte Differenz der Parameterschätzer eines FE- und RE-Modells
- Nullhypothese: Die Schätzer beider Modelle sind identisch
- Im Beispiel wird der Heiratseffekt zwischen FE- und RE-Modell verglichen (nächste Folie)
- Da $p < 0,0000$, ist die Nullhypothese abzulehnen, beide Schätzer weichen signifikant voneinander ab und das FE-Modell (bzw. ein Hybrid-Modell) ist dem RE-Modell vorzuziehen

Panelanalyse: RE- und FE-Modelle

```
xtreg lwage ms
estimates store random
```

```
xtreg lwage ms, fe
estimates store fixed
```

```
hausman fixed random
```

```
. hausman fixed random
```

	Coefficients		(b-B) Difference	sqrt(diag(V_b-V_B)) S.E.
	(b) fixed	(B) random		
ms	-.0833546	.0983045	-.1816592	.0196869

b = consistent under Ho and Ha; obtained from xtreg
 B = inconsistent under Ha, efficient under Ho; obtained from xtreg

Test: Ho: difference in coefficients not systematic

chi2(1) = (b-B)'[(V_b-V_B)^(-1)](b-B)
 = 85.15
 Prob>chi2 = 0.0000

Panelanalyse: RE- und FE-Modelle

Klasse	Gleichungen
Panelmodell mit Fixed Effects und Level 1-Prädiktor	$Y_{it} - \bar{Y}_i = \beta_1 (X_{it} - \bar{X}_i) + r_{it} - \bar{r}_i$ <p>$i = 1, 2, \dots, n$ Level 2-Einheiten (z.B. Personen) $t = 1, 2, \dots, m$ Level 1-Einheiten (Messzeitpunkte)</p>

Panelanalyse: RE- und FE-Modelle

```

Fixed-effects (within) regression
Group variable: nr
Number of obs   =   4165
Number of groups =    595

R-sq:  within = 0.6581
       between = 0.0261
       overall = 0.0461

Obs per group: min =    7
                avg  =   7.0
                max  =    7

corr(u_i, xb) = -0.9100

F(9, 3561)      =   761.75
Prob > F        =   0.0000
    
```

lwage	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
exp	.1132083	.002471	45.81	0.000	.1083635	.1180531
expq	-.0004184	.0000546	-7.66	0.000	-.0005254	-.0003113
wks	.0008359	.0005997	1.39	0.163	-.0003398	.0020117
occ	-.0214765	.0137837	-1.56	0.119	-.0485012	.0055482
ind	.0192101	.0154463	1.24	0.214	-.0110744	.0494946
south	-.0018612	.0342993	-0.05	0.957	-.0691094	.065387
smsa	-.0424691	.0194284	-2.19	0.029	-.080561	-.0043773
ms	-.0297259	.0189836	-1.57	0.117	-.0669456	.0074939
fem	(omitted)					
union	.0327849	.0149229	2.20	0.028	.0035266	.0620431
ed	(omitted)					
blk	(omitted)					
_cons	4.648767	.046022	101.01	0.000	4.558535	4.738999
sigma_u	1.0338102					
sigma_e	.15199444					
rho	.97884144	(fraction of variance due to u_i)				

F test that all u_i=0: F(594, 3561) = 30.93 Prob > F = 0.0000

Panelanalyse: RE- und FE-Modelle

- Berechnung des Personenmittelwertes jeder Variablen und Zentrierung zeitveränderlicher Variablen um diesen Personenmittelwert:

```
egen mexp = mean(exp), by(nr)
gen dexp = exp-mexp

egen mexpq = mean(expq), by(nr)
gen dexpq = expq-mexpq

egen mwks = mean(wks), by(nr)
gen dwks = wks-mwks

egen mocc = mean(occ), by(nr)
gen docc = occ-mocc

egen mind = mean(ind), by(nr)
gen dind = ind-mind

egen msouth = mean(south), by(nr)
gen dsouth = south-msouth

egen msmsa = mean(smsa), by(nr)
gen dsmsa = smsa-msmsa

egen mms = mean(ms), by(nr)
gen dms = ms-mms

egen munion = mean(union), by(nr)
gen dunion = union-munion
```

Panelanalyse: RE- und FE-Modelle

```

Random-effects ML regression      Number of obs   =   4165
Group variable: nr              Number of groups =    595

Random effects u_i ~ Gaussian    Obs per group:  min =    7
                                   avg =   7.0
                                   max =    7

Log likelihood = 1029.4087        LR chi2(21)     =  4299.55
                                   Prob > chi2      =   0.0000
    
```

lwage	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
fem	-.3170612	.0541241	-5.86	0.000	-.4231426	-.2109798
ed	.051436	.0054935	9.36	0.000	.0406688	.0622031
blk	-.1578043	.0445174	-3.54	0.000	-.2450569	-.0705517
mexp	.0319011	.0047244	6.75	0.000	.0226415	.0411608
dexp	.1132083	.0024679	45.87	0.000	.1083712	.1180453
mexpq	-.0005656	.0001037	-5.45	0.000	-.0007689	-.0003624
dexpq	-.0004184	.0000545	-7.67	0.000	-.0005252	-.0003115
mwks	.0091891	.0035648	2.58	0.010	.0022022	.016176
dwks	.0008359	.0005989	1.40	0.163	-.0003379	.0020098
mocc	-.1676197	.0334452	-5.01	0.000	-.2331711	-.1020683
docc	-.0214765	.0137663	-1.56	0.119	-.0484579	.0055049
mind	.0579175	.0252607	2.29	0.022	.0084076	.1074275
dind	.0192101	.0154268	1.25	0.213	-.0110259	.0494461
msouth	-.0570535	.0256826	-2.22	0.026	-.1073905	-.0067166
dsouth	-.0018612	.034256	-0.05	0.957	-.0690017	.0652794
msmsa	.1757753	.0254739	6.90	0.000	.1258475	.2257032
dsmsa	-.0424691	.0194038	-2.19	0.029	-.0805	-.0044383
mms	.1147817	.0471736	2.43	0.015	.0223232	.2072401
dms	-.0297259	.0189596	-1.57	0.117	-.066886	.0074343
munion	.1090687	.0289107	3.77	0.000	.0524046	.1657327
dunion	.0327849	.014904	2.20	0.028	.0035735	.0619962
_cons	5.121431	.2020057	25.35	0.000	4.725507	5.517355
/sigma_u	.2596501	.0078958			.2446267	.2755962
/sigma_e	.1518027	.0017965			.1483221	.155365
rho	.7452632	.0124691			.7202244	.7690758

Likelihood-ratio test of sigma_u=0: chibar2(01)= 3870.82 Prob>=chibar2 = 0.000

Panelanalyse: RE- und FE-Modelle

- Interpretationsbeispiel für den Heiratseffekt im Hybrid-Modell:
 - Effekt von „mms“ (= 0,115, sig.): Personen, die heiraten, haben signifikant mehr Einkommen als andere Personen, die nicht heiraten (Varianz zwischen Personen)
 - Effekt von „dms“ (= -0,03, n.s.): Dieselben Personen haben nach der Heirat weniger Einkommen als vor der Heirat (Varianz innerhalb von Personen); diese Veränderung ist jedoch insignifikant
 - Effekt von „dms“ identisch mit dem Fixed-Effects-Modell (s.o.)

Panelanalyse: RE- und FE-Modelle

- Beim binären logistischen FE-Modell wird die Wahrscheinlichkeit für $y=1$ (für Person i zum Zeitpunkt t ; symbolisiert mit π_{it}) durch zeitveränderliche Prädiktoren vorhergesagt
- Zeitkonstante unbeobachtete Heterogenität ist auch hier kontrolliert
- Das Modell setzt voraus, dass sich die binäre AV bei einer Person im Beobachtungszeitraum mindestens einmal verändert
- Zum Beispiel werden bei vier Messzeitpunkten Beobachtungssequenzen $[1,1,1,1]$ oder $[0,0,0,0]$ nicht berücksichtigt

Panelanalyse: RE- und FE-Modelle

Klasse	Gleichungen
--------	-------------

Logistisches FE-Modell

$$\text{logit}_{it} = \ln \left(\frac{\pi_{it} | X; v_i}{1 - \pi_{it} | X; v_i} \right) = v_i + \beta_1 (X_{it} - \bar{X}_i)$$

- Der Term v_i erfasst zeitkonstante unbeobachtete Heterogenität, konkret die personenspezifische Anzahl der Einsen im Beobachtungszeitraum
- Durch zeitveränderliche Prädiktoren wird erklärt, „wann“ diese Einsen im Zeitverlauf eintreten

Panelanalyse: RE- und FE-Modelle

- Beispieldaten: Sozio-oekonomisches Panel (Wellen 1990, 1997, 2003, 2007; N = 34.536 Personen, soep_konfession.dta)
- Abhängige Variable: Mitglied in einer Religionsgemeinschaft (ja/nein; „konfess“)
- Unabhängige Variablen:
 - „Index1“ (Jahre seit 1990) bzw. „periodeln“ (logarithmierte Jahre seit 1990)
 - Geschlechtsdummy („mann“)
 - Aktueller Wohnort in neuen Bundesländern („ost“)
 - Auf das 17. Lebensjahr zentriertes und quadriertes Alter („alterz17“, „alterq17“)

Panelanalyse: RE- und FE-Modelle

- Im Beispiel erfasst v_i die „Basisneigung“ einer Person, Kirchenmitglied zu sein, z.B. kann eine Person bei vier Wellen (und mindestens einem Wechsel) 1-3 Einsen aufweisen
- Im FE-Logit-Modell werden die Abweichungen von dieser Basisneigung durch zeitveränderliche Prädiktoren (z.B. Alter) vorhergesagt
- Beispiel: Gegeben, eine Person ist bei drei von vier Beobachtungszeitpunkten (1997, 2003 und 2007) Kirchenmitglied, im Jahr 1990 jedoch nicht
- Im FE-Modell wird untersucht, ob die Veränderung von unabhängigen Merkmalen mit dieser Veränderung der AV kovariiert

Panelanalyse: RE- und FE-Modelle

```
. xtlogit konfess alterz17 alterq17 periodeln mann ost, fe
note: multiple positive outcomes within groups encountered.
note: 32394 groups (63324 obs) dropped because of all positive or
      all negative outcomes.
note: mann omitted because of no within-group variance.
```

```
Iteration 0:  log likelihood = -2077.0842
Iteration 1:  log likelihood = -2052.3789
Iteration 2:  log likelihood = -2052.2931
Iteration 3:  log likelihood = -2052.2931
```

```
Conditional fixed-effects logistic regression   Number of obs   =   6361
Group variable: PERSNR                        Number of groups =   2142

Obs per group: min =   2
                avg =   3.0
                max =   4

LR chi2(4) =   544.05
Prob > chi2 =   0.0000

Log likelihood = -2052.2931
```

konfess	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
alterz17	-.1249547	.016037	-7.79	0.000	-.1563866	-.0935227
alterq17	.0020391	.0001712	11.91	0.000	.0017034	.0023747
periodeln	-.4826298	.0682164	-7.07	0.000	-.6163316	-.3489281
mann	0	(omitted)				
ost	-1.055544	.2867947	-3.68	0.000	-1.617652	-.493437

Panelanalyse: RE- und FE-Modelle

- Die Analyse basiert lediglich auf $N = 2.142$ Personen (6,2% der Ausgangsstichprobe), die Veränderungen bei der AV aufweisen, d.h. entweder aus der Kirche ein- oder austreten
- Interpretationsbeispiel für den Periodeneffekt ($b = -0,483$): Mit fortschreitender historischer Zeit sinkt für eine individuelle Person die Wahrscheinlichkeit, dass sich die AV von 0 auf 1 verändert (Kircheneintritt) bzw. steigt die Wahrscheinlichkeit für den Wechsel 1 auf 0 (Austritt)
- Interpretationsbeispiel für „ost“ ($b = -1,06$): Ein Wohnortwechsel in die neuen Bundesländer (0 auf 1) senkt für eine individuelle Person die Wahrscheinlichkeit für einen Wechsel von 0 auf 1 (bzw. erhöht sich die Wahrscheinlichkeit für den Wechsel 1 auf 0)

Panelanalyse: RE- und FE-Modelle

- Zum Vergleich ein RE-Logit-Modell für die gleichen Kovariaten:
 - Dieses Modell basiert auf der vollen Stichprobe und berücksichtigt sowohl Unterschiede zwischen Personen als auch innerhalb von Personen
 - Effekte zeitkonstanter Variablen („mann“) sind schätzbar
 - Der Effekt von „ost“ speist sich hier aus zwei Quellen:
 - Personen in den neuen Bundesländern sind seltener Kirchenmitglied als in den alten (Varianz zwischen Personen)
 - Die Wahrscheinlichkeit einer Kirchenmitgliedschaft verändert sich im Zuge von Ost-West-Umzügen (Varianz innerhalb von Personen)

Panelanalyse: RE- und FE-Modelle

```

Random-effects logistic regression          Number of obs      =      69685
Group variable: PERSNR                    Number of groups   =      34536

Random effects u_i ~ Gaussian             Obs per group: min =          1
                                           avg =          2.0
                                           max =          4

Log likelihood = -24074.7                  Wald chi2(5)       =    13990.94
                                           Prob > chi2        =          0.0000
    
```

konfess	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
alterz17	-.1257505	.0071787	-17.52	0.000	-.1398205	-.1116806
alterq17	.0026615	.0001261	21.11	0.000	.0024144	.0029086
periodeln	-.7459793	.027727	-26.90	0.000	-.8003232	-.6916353
mann	-1.093768	.0770945	-14.19	0.000	-1.244871	-.9426659
ost	-12.41158	.1064485	-116.60	0.000	-12.62021	-12.20294
_cons	10.48529	.1269319	82.61	0.000	10.2365	10.73407
/lnsig2u	4.01281	.0191425			3.975291	4.050328
sigma_u	7.436534	.0711769			7.298331	7.577355
rho	.9438512	.0010145			.9418294	.9458067

Likelihood-ratio test of rho=0: chibar2(01) = 1.7e+04 Prob >= chibar2 = 0.000


Wachstumskurvenmodell

- Wird für die Zeitvariable ein Random Slope geschätzt, spricht man von **Wachstumskurvenmodellen** („growth-curve models“)
- Der Effekt der Zeit als Level 1-Merkmal (z.B. lineare oder u-förmige zeitliche Trends) kann somit über die Level 2-Einheiten variieren, dadurch wird z.B. für jede Person ein individueller Zeittrend geschätzt
- Wird die Zeit mit Level 1- oder Level 2-Prädiktoren (z.B. dem Geschlecht) interagiert, kann erklärt werden, warum sich Personen mit bestimmten Merkmalen über die Zeit unterschiedlich entwickeln

Wachstumskurvenmodell

- Beispieldaten: National Longitudinal Survey of Youth (reading.dta, 1.677 Schüler und 2,676 Beobachtungen)
- Abhängige Variable: Prozent korrekt gelöster Aufgaben im Mathematiktest von Grade 0 (Vorschule) bis zur 3. Klasse („math“)
- Unabhängige Variablen:
 - „Grade“ (0 bis 3)
 - Dummy „Minority“

Wachstumskurvenmodell



Wachstumskurvenmodell

- Nach dem grafischen Plot der beobachteten Verläufe (vorherige Folie) scheint sich die Leistung in den beiden Gruppen auseinanderzuentwickeln
- Wir schätzen mit `xtmixed` ein Wachstumskurvenmodell, um dies zu überprüfen:

```
xtmixed math minority grade || id: grade, cov(unstr) mle variance residual(independent, by(grade))
```

- Für „grade“, die Zeitvariable, wird dabei ein Random Slope geschätzt, die lineare Entwicklung der Mathematikleistung der Schüler variiert also um den mittleren linearen Effekt von „grade“ (= 9,46)
- `residual(independent, by(grade))` bewirkt, dass die Varianz der Level 1-Residuen zwischen den Klassenstufen variieren kann

Wachstumskurvenmodell

Mixed-effects ML regression
Group variable: id

Number of obs = 2676
Number of groups = 1677

Obs per group: min = 1
 avg = 1.6
 max = 3

Log likelihood = -9398.376

wald chi2(2) = 5031.78
Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
minority	-3.900027	.3268483	-11.93	0.000	-4.540637	-3.259416
grade	9.456502	.1349087	70.10	0.000	9.192086	9.720919
_cons	19.21837	.2375353	80.91	0.000	18.75281	19.68393

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Unstructured				
var(grade)	6.234922	1.878139	3.454813	11.2522
var(_cons)	9.594744	5.153797	3.348206	27.49505
cov(grade,_cons)	2.400331	2.491834	-2.483573	7.284236
Residual: Independent, by grade				
0: var(e)	25.56483	5.388368	16.91348	38.64141
1: var(e)	56.30586	4.115893	48.79011	64.97937
2: var(e)	65.796	6.17096	54.74771	79.07389
3: var(e)	26.36953	10.44715	12.13029	57.32362

LR test vs. linear regression: chi2(6) = 388.33 Prob > chi2 = 0.0000

Wachstumskurvenmodell

- Nun wollen wir überprüfen, ob sich die Mathematikleistung in den beiden Gruppen tatsächlich signifikant auseinanderentwickelt
- Dazu wird ein Interaktionseffekt „minority x grade“ in das Modell aufgenommen
- Der Haupteffekt von „minority“ ($= -3,26$) bezieht sich nun auf grade = 0 und der mittlere Effekt von „grade“ ($= 9,92$) auf minority = 0
- Der signifikante, negative Interaktionseffekt ($= -0,96$) bestätigt, dass der positive lineare Trend in der Entwicklung der Mathematikleistung bei Schülerinnen und Schülern einer Minorität schwächer ist als in der Referenzgruppe
- Ein Plot der Vorhersagewerte dieses Modells (nächste Folie) zeigt entsprechend eine sich öffnende Schere

Wachstumskurvenmodell

Mixed-effects ML regression
Group variable: id

Number of obs = 2676
Number of groups = 1677
Obs per group: min = 1
 avg = 1.6
 max = 3

Log likelihood = -9392.0728


Wald chi2(3) = 5073.56
Prob > chi2 = 0.0000

math	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
minority	-3.264258	.370711	-8.81	0.000	-3.990838	-2.537678
grade	9.92356	.1865226	53.20	0.000	9.557982	10.28914
minxgrade	-.9612353	.2694297	-3.57	0.000	-1.489308	-.4331628
_cons	18.91507	.2507758	75.43	0.000	18.42355	19.40658

Random-effects Parameters	Estimate	Std. Err.	[95% Conf. Interval]	
id: Unstructured				
var(grade)	6.385401	1.864027	3.603341	11.31543
var(_cons)	10.82042	5.141814	4.263411	27.46194
cov(grade,_cons)	1.940919	2.481932	-2.923579	6.805417
Residual: Independent, by grade				
0: var(e)	24.07509	5.351783	15.57219	37.22084
1: var(e)	55.91734	4.096936	48.43741	64.55236
2: var(e)	65.02605	6.125149	54.064	78.21077
3: var(e)	26.52265	10.41648	12.28335	57.26866

LR test vs. linear regression: chi2(6) = 394.89 Prob > chi2 = 0.0000

Wachstumskurvenmodell



Wachstumskurvenmodell

- Alternativ besteht die Möglichkeit, ein FE-Wachstumskurvenmodell mit xtreg und fe-Option zu berechnen (nächste Folie)
- Der Effekt der Wechselwirkung „grade*minority“ („gradxmin“) ist wie im Random Slope-Modell negativ, signifikant und von ähnlicher Größenordnung
- Das FE-Modell ist, gegenüber dem Random Slope-Modell, nicht nur einfacher, sondern auch robuster gegenüber von Selektionseffekten, die von zeitkonstanter unbeobachteter Heterogenität verursacht werden
- Es ist angesichts dieser Vorteile des FE-Modells erstaunlich, wie unkritisch häufig RE-Wachstumskurvenmodelle empfohlen werden

Wachstumskurvenmodell

```
. xtreg math grade gradxmin, fe i(id)
```

```
Fixed-effects (within) regression      Number of obs      =      2676
Group variable: id                    Number of groups   =      1677

R-sq:  within = 0.7826                Obs per group: min =          1
      between = 0.4379                avg =              1.6
      overall  = 0.5747                max =              3

corr(u_i, Xb) = -0.0981                F(2, 997)          =      1794.04
                                          Prob > F           =       0.0000
```

math	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
grade	10.2621	.2335592	43.94	0.000	9.803779	10.72043
gradxmin	-.8117975	.3292869	-2.47	0.014	-1.457972	-.1656225
_cons	16.80083	.2556207	65.73	0.000	16.29921	17.30244
sigma_u	8.0624699					
sigma_e	7.3059626					
rho	.54910577	(fraction of variance due to u_i)				

```
F test that all u_i=0:      F(1676, 997) =      1.72      Prob > F = 0.0000
```

Literaturempfehlungen

Einführende und weiterführende Literatur zu Mehrebenenmodellen

- Luke, D. A. (2004): Multilevel modeling. Sage University paper series in quantitative applications in the social sciences; 143. Thousand Oaks: Sage
- Ditton, H. (1998): Mehrebenenanalyse. Grundlagen und Anwendungen des Hierarchisch Linearen Modells. Weinheim: Juventa.
- Bryk, A. S. & Raudenbush, S. W. (1992): Hierarchical linear models: Applications and data analysis methods. Newbury Park, CA: Sage..
- Kreft, I. G. G. & de Leeuw, J. (1998): Introducing multilevel modeling. Newbury Park, CA: Sage.
- Langer, W. (2004): Mehrebenenanalyse: Eine Einführung für Forschung und Praxis. Wiesbaden: VS-Verlag.
- Snijders, T. & Bosker, R. (2012): Multilevel analysis. An introduction to basic and advanced multilevel modeling. London: Sage.

Logistisches Mehrebenenmodell

- Guo, Z. & Zhao, H. (2000): Multilevel modeling for binary data. In: Annual Review of Sociology 26: 441-462.

Umsetzung der Mehrebenenanalyse in STATA

- Rabe-Hesketh, S. & Skrondal, A. (2012): Multilevel and longitudinal modeling using Stata (Volume 1 und 2). Texas: Stata Press.

Literaturempfehlungen

Logik der Panelanalyse (Einführungen)

- Brüderl, J. (2010): Kausalanalyse mit Paneldaten. In: Handbuch sozialwissenschaftliche Datenanalyse, Hrsg. Best, Henning & Christoph Wolf, 963–994. Wiesbaden: VS Verlag.
- Allison, P.D. (1994): Using panel data to estimate the effects of events. *Sociological Methods & Research*, 23, 174-199.
- Halaby, C. (2004): Panel models in sociological research. *Annual Review of Sociology*, 30, 507-544.

Mathematisch-technische Grundlagen

- Wooldridge, J. (2013): *Introductory econometrics: A modern approach*. Cengage Learning.
- Giesselmann/Winzio (2012): *Regressionsmodelle zur Analyse von Paneldaten*. Wiesbaden: Springer VS.

Fixed-Effects-Ansatz

- Allison, P.D. (2009): *Fixed effects regression models*. Sage University paper series in quantitative applications in the social sciences; 160. Thousand Oaks: Sage

Wachstumskurven:

- Singer, J. D. & Willett, J.B. (2003): *Applied longitudinal data analysis*. Oxford: Oxford University Press.