



Längsschnittanalysen mit Mplus



Agenda



I. Grundlagen

II. Cross-lagged panel

III. Latent Change Scores

IV. Latent Growth Curve Modeling

V. Multilevel Modeling

Zielsetzung: Empirischer Nachweis von Kausalität

- ☐ 1. Voraussetzung: Ursache (unabhängige Variable) liegt zeitlich vor dem Ereignis (Veränderung in der abhängigen Variable)
- ☐ 2. Voraussetzung: Veränderungen in der unabhängigen Variablen korrespondieren empirisch mit Änderungen in der abhängigen Variablen.
- ☐ 3. Voraussetzung: Alternative Erklärungen (andere Ursachen oder umgekehrte Beeinflussung) können systematisch ausgeschlossen werden.
- ☐ Längsschnittstudien zielen insbesondere auf die Erfüllung der ersten Voraussetzung ab.



Modellierung der
Autokorrelation und
statistische
Kontrolle der Fehler
über die Zeit durch
messzeitpunkt-
übergreifende
Korrelationen.

Wiederholte
Messung der
(unabhängigen und
abhängigen
Variablen

Analyse und
Vorhersage der
Veränderung in der
abhängigen
Variablen über die
Zeit.

**Merkmale
von Längs-
schnitt-
studien**

Grundlegende
Annahme: Über die
Kontrolle der
zeitlichen Stabilität
und Veränderung in
der abhängigen
Variablen werden
Drittvariableneinflüs-
se mitberücksichtigt.

In der Regel sind
die Zeitintervalle
zwischen den
Messungen gleich



Unterschied zum Experiment



- Bei Experimenten: Systematische Veränderung der unabhängigen Variablen und Messung der Veränderung in der abhängigen Variablen (bei kontrollierten Bedingungen)
- Bei Längsschnittstudien: Messung der „natürlichen“ Veränderungen in der unabhängigen und abhängigen Variablen über verschiedene Zeiträume
- Analyse von experimentellen Daten mittels Längsschnittdesigns möglich (bspw. bei Quasiexperimenten und Interventionen)
- Häufig sind im Unterschied zu Experimenten einflussnehmende Bedingungen (bspw. Umgebungsfaktoren, interne Validität, Dropout etc.) in Längsschnittstudien nicht kontrollierbar.





Unterschied zu Querschnittsstudien

- Bei Querschnittsstudien: Gleichzeitige oder zeitversetzte Messung der unabhängigen und abhängigen Variablen
- Bei Längsschnittstudien: Mehrfache Messung der abhängigen Variablen
- Querschnittsstudien lassen keine Rückschlüsse auf zeitliche Veränderungen zu, selbst wenn unabhängige und abhängige Variablen zu unterschiedlichen Zeiten erhoben wurden.
- In der Regeln erfordern Querschnittsstudien zahlreiche Kontrollvariablen, um konfundierende Einflüsse herauspartialisieren zu können.


- Bestimmte Vorhersage- und Analysemodelle beinhalten unterschiedliche Messzeitpunkte, aber gelten nicht als Längsschnittuntersuchung

1. Fall: Unabhängige und abhängige Variablen werden zu unterschiedlichen Zeitpunkten erfasst. Wenn die abhängige Variable nur einmal gemessen wurde, lässt sich deren Veränderung über die Zeit nicht vorhersagen.

2. Fall: Unabhängige und abhängige Variablen werden mehrfach an unterschiedlichen Messzeitpunkten gleichzeitig gemessen (bspw. Tagebuchstudien). Die Level-1-Zusammenhängen sind hierbei querschnittlich.



Agenda



I. Grundlagen

II. Cross-lagged panel

III. Latent Change Scores

IV. Latent Growth Curve Modeling

V. Multilevel Modeling

Cross-lagged panel

Panel- Design


Wiederholte Messung von unabhängigen und abhängigen Variablen

„Veränderungen“ in beiden Variablen werden aufeinander bezogen.


Kontrolle von potentiellen Drittvariablen (ohne deren Messung)

Analyse von reziproken und umgekehrten Vorhersagen (Reverse Causation)


Erhöhte statistische Teststärke im Vergleich zu Querschnittsstudien (deutlich mehr Daten)



Cross-lagged panel: Grundlegende Probleme



Cross-lagged panel: Vollständiges Mehrwellendesign



Spezifikation

Simultane Schätzung aller Zusammenhänge/Pfade zwischen latenten Variablen.

Analyse von multi-wave / multi-variable / multi-sample Modellen (including model comparisons)

Kontrolle von potentiellen Drittvariablen (ohne deren Messung)

Statistische Kontrolle der Autokorrelation über Stabilitätspfade und Korrelationen der Residuen für jeden Indikator


Vergleiche zwischen Modelle mit unterschiedlichen Pfadrichtungen

Cross-lagged panel: Beispiel

- Zwei Variablen:
 - job autonomy (JDS; Hackman & Oldham)
 - job satisfaction
- Zwei Messzeitpunkte, 6-monatiges Zeitintervall
- Befragung: 1000 TN; no missings

CORRELATION MATRIX

	AUTO1	AUTO2	SAT1	SAT2
AUTO1	1.00			
AUTO2	0.50	1.00		
SAT1	0.60	0.45	1.00	
SAT2	0.65	0.44	0.87	1.00



Cross-lagged panel: Beispiel

TITLE: SEM with Simultaneous Lagged Effects Among Sat & Aut;


DATA: File is AUT SAT2.txt;
TYPE is FULLCORR;
NOBSERVATIONS = 1000;

VARIABLE: NAMES ARE AUT1 AUT2 SAT1 SAT2;
USEVARIABLES ARE AUT1 AUT2 SAT1 SAT2;


ANALYSIS: ESTIMATOR=ML;
MODEL=NOCOVARIANCES;

MODEL: **! Measurement Models of Autonomy!**
AUT_1 by AUT1; AUT_2 by AUT2;
AUT1@0; AUT2@0;
! Measurement Models of Satisfaction !
SAT_1 by SAT1; SAT_2 by SAT2;
SAT1@0; SAT2@0;
! Correlations !
AUT_1 WITH SAT_1;
! STABILITY OF SAT and AUT !
SAT_2 ON SAT_1;
AUT_2 ON AUT_1;
! CAUSAL EFFECTS !
SAT_2 on AUT_1;
AUT_2 on SAT_1;

OUTPUT: SampStat Stand Tech1 Tech3;





Cross-lagged panel: Beispiel




Latente Moderatoreffekte im Längsschnitt

- Korrelativer Beziehungen zwischen zwei Variablen können als Funktion einer dritten (Moderator-)Variablen unterschiedlich ausfallen.
- Der Moderatoreffekt ist als statistische Wechselwirkung zu verstehen: Der Effekt der unabhängigen Variable auf die abhängige Variable ist von der Ausprägung der Moderatorvariablen abhängig




Latente Moderatoreffekte im Längsschnitt

**Amplifying
(moderator) effects**



**Buffering
(moderator) effects**




- Relationship between X and Y in the presence of **high** moderator values.
- - - Relationship between X and Y in the presence of **low** moderator values.

– The positive/negative relationship between X and Y is *amplified* as a function of the moderator.

- Relationship between X and Y in the presence of **high** moderator values.
- - - Relationship between X and Y in the presence of **low** moderator values.

– The positive/negative relationship between X and Y is *attenuated* as a function of the moderator.

Latente Moderatoreffekte im Längsschnitt



Abweichung von der (multivariaten) Normalverteilung


- Selbst wenn die unabhängigen Variablen normalverteilt sind, müssen Produktterm und abhängige Variable zwangsläufig nicht normalverteilt sein
- Voraussetzungen für Maximum-Likelihood-Schätzung (ML) sind verletzt
- Traditionelle ML-basierte Verfahren implizieren eine starke Unterschätzung der Standardfehler und verzerrte Chi-Quadratwerte

Latent Moderated SEM (Klein & Moosbrugger, 2000)

- Bildung von latenten Interaktionstermen auf der Grundlage von (endlichen) Mischverteilungen der beiden Prädiktoren: Keine Kreuzprodukte der Indikatoren erforderlich
- Iterative Parameterschätzung korrigiert die Abweichung von der multivariaten Normalverteilung
- Konsistente, (asymptotisch) unverzerrte, effiziente und normalverteilte Schätzung der Parameter: Robuste und unverzerrte Standardfehler


Anwendung und Testung

- Keine klassischen Fit-Indizes (RMSEA, CFI etc.)
- Loglikelihood-Differenztest ($\Delta 2LL$) wird für Modellvergleiche verwendet.




Latente Moderatoreffekte im Längsschnitt

- Grundlage ist ein Cross-lagged panel model mit mehreren Messzeitpunkten
- Die abhängige Variable zum 2. MZP ($t + 1$) wird mit den unabhängigen Variablen, die zum 1. MZP (t) gemessen wurden vorhergesagt
- Schätzung der zeitlichen Stabilität für die abhängige Variable.
- Interaktion aus beiden unabhängigen Variablen zum 1. MZP wird als weiterer Prädiktor spezifiziert.



Latente Moderatoreffekte im Längsschnitt: Beispiel



Latente Moderatoreffekte im Längsschnitt: Mplus (Input)

```
TITLE:      Interaction Emotional Dissonance and Cognitive Deficits;

DATA:      File is OFD_193.dat;

VARIABLE:  NAMES ARE    PersID time age sex ED1_1
                      ED2_1 ED1_2 ED2_2 CD1_1 CD2_1
                      CD3_1 CD1_2 CD2_2 CD3_2 EE1_1
                      EE2_1 EE3_1 DP1_1 DP2_1 EE1_2
                      EE2_2 EE3_2 DP1_2 DP2_2;

                      USEVARIABLES ARE    ED1_1 ED2_1 CD1_1 CD2_1 CD3_1
                      EE1_1 EE2_1 EE3_1 EE1_2 EE2_2
                      EE3_2;
```

```
ANALYSIS:  TYPE=RANDOM;
            ALGORITHM=INTEGRATION;
```

Parameterschätzung mittels LMS

```
MODEL:     ! Measurement Models of Predictors: Time 1 !
            EmoDis1 by  ED1_1 ED2_1;
            CogDef1 by  CD1_1 CD2_1 CD3_1;

            ! Measurement Models of Outcomes !
            EmoEx1 by  EE1_1 EE2_1 EE3_1;
            EmoEx2 by  EE1_2 EE2_2 EE3_2;
```

! Stability Effects !

```
EmoEx2 on EmoEx1;
EE1_1 with EE1_2;
EE2_1 with EE2_2;
EE3_1 with EE3_2;
```

Abhängige Variable:
Exhaustion

Spezifikation der Stabilitätspfade und
residuale Korrelationen für die Indikatoren.

! Main and Interactive Effects !

```
EmoEx2 on EmoDis1 CogDef1;
EDxCD | EmoDis1 xwith CogDef1;
EmoEx2 on EDxCD;
```

Latente Interaktion

Bildung des latenten Interaktionsterms
zwischen beiden unabhängigen (neue
Variable: xwith).

```
OUTPUT:    SampStat Tech1 Tech3;
```

Latente Moderatoreffekte im Längsschnitt: Mplus (Output)

MODEL RESULTS Parameter: t-Werte: Signifikanz:

	Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
EMODIS1 BY				
ED1_1	1.000	0.000	999.000	999.000
ED2_1	0.925	0.071	13.034	0.000
COGDEF1 BY				
CD1_1	1.000	0.000	999.000	999.000
CD2_1	0.731	0.122	5.989	0.000
CD3_1	0.808	0.096	8.435	0.000

Messmodell der
Prädiktoren
Prädiktoren zum 1. MZP


EMOEX1 BY				
EE1_1	1.000	0.000	999.000	999.000
EE2_1	0.953	0.070	13.608	0.000
EE3_1	0.914	0.081	11.318	0.000
EMOEX2 BY				
EE1_2	1.000	0.000	999.000	999.000
EE2_2	1.036	0.060	17.214	0.000
EE3_2	0.836	0.078	10.763	0.000

Messmodelle des
Kriteriums
zu beiden MZP.

EMOEX2 ON				
EMOEX1	0.373	0.131	2.852	0.004
EMODIS1	0.221	0.094	2.356	0.018
COGDEF1	0.387	0.170	2.273	0.023
EDXCD	0.425	0.167	2.550	0.011

Stabilität
Haupteffekte
Interaktionseffekt


COGDEF1 WITH EMODIS1	0.289	0.051	5.606	0.000
EMOEX1 WITH EMODIS1	0.458	0.077	5.934	0.000
COGDEF1 WITH EMOEX1	0.411	0.067	6.168	0.000
EE1_1 WITH EE1_2	0.066	0.041	1.619	0.106
EE2_1 WITH EE2_2	0.095	0.034	2.750	0.006
EE3_1 WITH EE3_2	0.236	0.053	4.418	0.000



Latente Moderatoreffekte im Längsschnitt: Ergebnisse

	Emotional exhaustion t_2	
	β	(SE)
Stability (outcome t_1)	.37**	(.13)
R^2	.55	
Emotional dissonance t_1	.22*	(.09)
Cognitive control deficits t_1	.39*	(.17)
$R^2 (\Delta R^2)$	.61 (.06)	
ω : Interaction CD X ED t_1	.43*	(.17)
$R^2 (\Delta R^2)$	.69 (.08)	
Δ -2LL (df_{diff})	15.08 (1)**	

Note. CD = Cognitive control deficits;
ED = emotional dissonance;
 t_1 = time 1; t_2 = time 2;
* $p < .05$; ** $p < .01$; $N = 193$.



Latente Moderatoreffekte im Längsschnitt: Differenztest

1. Schritt: Analyse eines linearen Modells

```
TITLE:      Interaction Emotional Dissonance and Cognitive Deficits;

DATA:      File is OFD_193.dat;

VARIABLE:  NAMES ARE    PersID time age sex ED1_1
                      ED2_1 ED1_2 ED2_2 CD1_1 CD2_1
                      CD3_1 CD1_2 CD2_2 CD3_2 EE1_1
                      EE2_1 EE3_1 DP1_1 DP2_1 EE1_2
                      EE2_2 EE3_2 DP1_2 DP2_2;

          USEVARIABLES ARE  ED1_1 ED2_1 CD1_1 CD2_1 CD3_1
                      EE1_1 EE2_1 EE3_1 EE1_2 EE2_2
                      EE3_2;

ANALYSIS:  ESTIMATOR=MLR;

MODEL:    ! Measurement Models of Predictors: Time 1 !
          EmoDis1 by  ED1_1 ED2_1;
          CogDef1 by  CD1_1 CD2_1 CD3_1;

          ! Measurement Models of Outcomes !
          EmoEx1 by  EE1_1 EE2_1 EE3_1;
          EmoEx2 by  EE1_2 EE2_2 EE3_2;

          ! Stability Effects !
          EmoEx2 on EmoEx1;
          EE1_1 with EE1_2;
          EE2_1 with EE2_2;
          EE3_1 with EE3_2;

          ! Main Effects !
          EmoEx2 on EmoDis1 CogDef1;
```

Using Robust Maximum Likelihood
(Satorra & Bentler, 1988)

```
OUTPUT:    SampStat Stand Tech1 Tech3;
```

stand: R^2 -values

Latente Moderatoreffekte im Längsschnitt: Differenztest

2. Schritt: χ^2 -Difference-Test

For *nonlinear SEM*, it is not possible so far to obtain reliable chi-square statistics. However, it is possible to test single or multiple nonlinear effects by a standard likelihood-ratio test. The difference between the log-likelihood LL_0 of a more restrictive model (M_0) and the log-likelihood LL_1 of a less restrictive model (M_1) multiplied by -2 is chi-square distributed (Bollen, 1989; cf. Muthén & Muthén, 2006):

$$T_D = -2(LL_0 - LL_1). \quad (2)$$

The number of degrees of freedom for the difference statistic T_D is calculated by subtracting the number of estimated parameters of the more restrictive model (p_0) from the number of estimated parameters of the less restrictive model (p_1): $df_D = p_1 - p_0$. Thus, the likelihood-based difference test T_D compares the log-likelihoods of the nested models, with greater differences reducing the probability that the more restrictive M_0 model is retained.

$$\Delta-2LL = (-2*(-2371.54-(-2364.00)))$$

$$\Delta-2LL = \underline{\underline{15.08}} \text{ (df}_{\text{diff}} = 1; p < .01)$$

Linear model (H_0):

MODEL FIT INFORMATION

Number of Free Parameters 42

Loglikelihood

LL_0	H0 Value	-2371.535
	H0 Scaling Correction Factor for MLR	1.1677

Non-Linear model (H_1):

MODEL FIT INFORMATION

Number of Free Parameters 43

Loglikelihood

LL_1	H0 Value	-2363.996
	H0 Scaling Correction Factor for MLR	1.1638

Latente Moderatoreffekte im Längsschnitt: ΔR^2 -values

Linear model:

below Model results (unstandardized estimates):

Residual Variances				
ED1_1	0.109	0.073	1.489	0.137
ED2_1	0.212	0.056	3.791	0.000
CD1_1	0.211	0.068	3.106	0.002
CD2_1	0.318	0.053	6.034	0.000
CD3_1	0.463	0.079	5.863	0.000
EE1_1	0.334	0.054	6.195	0.000
EE2_1	0.279	0.058	4.827	0.000
EE3_1	0.688	0.082	8.366	0.000
EE1_2	0.347	0.067	5.141	0.000
EE2_2	0.321	0.063	5.112	0.000
EE3_2	0.535	0.064	8.304	0.000
EMOEX2	0.334	0.078	4.297	0.000

SS_r : Residual variance of the outcome (restricted)

below STD Standardization:

R-SQUARE				
Latent Variable	Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
EMOEX2	0.611	0.066	9.322	0.000

R^2_r : R^2 -value of the outcome (restricted)

Non-Linear model:

below Model results (unstandardized estimates):

Residual Variances				
ED1_1	0.137	0.056	2.464	0.014
ED2_1	0.193	0.048	4.046	0.000
CD1_1	0.213	0.056	3.819	0.000
CD2_1	0.336	0.051	6.622	0.000
CD3_1	0.449	0.075	5.985	0.000
EE1_1	0.338	0.054	6.213	0.000
EE2_1	0.278	0.058	4.823	0.000
EE3_1	0.683	0.083	8.276	0.000
EE1_2	0.350	0.067	5.244	0.000
EE2_2	0.318	0.061	5.178	0.000
EE3_2	0.534	0.063	8.460	0.000
EMOEX2	0.264	0.060	4.416	0.000

SS_f : Residual variance of the outcome (full)

$$SS_t = SS_r / (1 - R^2_r)$$

$$SS_t = 0.334 / (1 - 0.611) = 0.859$$

$$\Delta R^2 = (SS_r - SS_f) / SS_t$$

$$\Delta R^2 = (0.334 - 0.264) / 0.859$$

$$\Delta R^2 = 0.081$$

BERGISCHE
UNIVERSITÄT
WUPPERTAL

	C (interaction)	A (IV)	B (moderator)
C	0,028	0,008	0,016
A	0,008	0,009	0,005
B	0,016	0,005	0,029

Latente Moderatoreffekte im Längsschnitt: Simple Slopes

2. Schritt: Bestimmung der Parameter für niedrige und hohe Moderatorwerte

		Estimate
EMOEX2 ON		
EMOEX1		0.373
EMODIS1		0.221
COGDEF1		0.387
EDXCD		0.425
Variances		
EMODIS1		0.769
COGDEF1		0.440
EMOEX1		0.787

→ Lagged main effects (β_{12}/β_{13})

→ Lagged interaction effects (ω)

→ Variances of the IV (ψ_2/ψ_3)

	C (interaction)	A (IV)	B (moderator)
C	0.028	0.008	0.016
A	0.008	0.009	0.005
B	0.016	0.005	0.029

Low CD (- 1SD): $t = \beta / \text{S.E.} = -0.065 / 0.10$
 $t = -0.65$ (n.s.)


High CD (+ 1SD): $t = \beta / \text{S.E.} = 0.505 / 0.179$
 $t = 2.82$ ($p < .01$)

Low CD (- 1SD): $\beta = \beta_{12} - (\omega * \sqrt{\psi_3})$
 $\beta = 0.22 - (0.43 * \sqrt{0.44})$
 $\beta = -0.065$

High CD (+ 1SD): $\beta = \beta_{12} + (\omega * \sqrt{\psi_3})$
 $\beta = 0.22 + (0.43 * \sqrt{0.44})$
 $\beta = 0.505$


Low CD (- 1SD): $\text{S.E.} = \sqrt{\{A * A - (2 * \sqrt{\psi_3} * A * C) + (\psi_3 * C * C)\}}$
 $\text{S.E.} = \sqrt{\{0.009 - (2 * 0.66 * 0.008) + (0.44 * 0.028)\}}$
 $\text{S.E.} = 0.10$

High CD (+ 1SD): $\text{S.E.} = \sqrt{\{A * A + (2 * \sqrt{\psi_3} * A * C) + (\psi_3 * C * C)\}}$
 $\text{S.E.} = \sqrt{\{0.009 + (2 * 0.66 * 0.008) + (0.44 * 0.028)\}}$
 $\text{S.E.} = 0.179$




Latente Moderatoreffekte im Längsschnitt: Simple Slopes

3. Schritt: Grafische Visualisierung der Interaktionsmuster



Agenda



I. Grundlagen

II. Cross-lagged panel

III. Latent Change Scores

IV. Latent Growth Curve Modeling

V. Multilevel Modeling

Latent Difference Scores






FIGURE 3 A latent difference score (LDS) model for maternal depressive symptoms, maternal sensitivity, and child problem behavior.

- „true change“: Direkte Schätzung der intraindividuellen Veränderung über die Zeit: Die Zu- und Abnahme wird für jedes Stichprobenelement quantifiziert.
- Der neugebildete Change-Faktor wird vorhergesagt (eigentliche unabhängige oder abhängige Variable).
- Change-Scores können auch in komplexen Moderator- und Mediatormodelle integriert werden.
- Grundlegende (theoretische) Voraussetzung: Die Veränderung in der entsprechenden Variable ist linear (nicht-lineare Trends lassen sich nicht modellieren).
- LDS liefert im Vergleich zu Cross-lagged panel designs validere Ergebnisse.
- Die Change-Score können auch über manifeste Variablen gebildet werden.

BERGISCHE
UNIVERSITÄT
WUPPERTAL



Latent Difference Scores: Voraussetzung



1. Partielle metrische Invarianz

- mindestens zwei Ladungen der an mehreren Messzeitpunkten gemessenen latenten Variablen sind gleich

2. Partielle skalare Invarianz

- Zusätzlich zu 1.: Mindestens zwei Intercepts der an mehreren Messzeitpunkten gemessenen latenten Variablen sind gleich

3. Partielle Invarianz der Residuen

- Zusätzlich zu 1. und 2.: Mindestens zwei Residuen der an mehreren Messzeitpunkten gemessenen latenten Variablen sind gleich

Über Modellvergleiche und Differenztests werden die Modellverbesserungen von 1. zu 3. überprüft: Es dürfen keine signifikanten Unterschiede auftreten.

Latent Difference Scores

MODEL:

!MEASUREMENT MODELS: LAMBDA

DEP1 BY Depr1_1@1
Depr1_2(1)
Depr1_3(2);
DEP2 BY Depr2_1@1
Depr2_2(1)
Depr2_3(2);
EE1 BY Exhau1_1@1
Exhau1_2(3)
Exhau1_3(4);
EE2 BY Exhau2_1@1
Exhau2_2(3)
Exhau2_3(4);

Messmodell für Depression

Messmodell für Erschöpfung

!TIME-RELATED CORRELATIONS: THETA

Depr1_1*; Depr1_2*; Depr1_3*;
Depr2_1*; Depr2_2*; Depr2_3*;
Depr2_1 with Depr1_1*; Depr2_2 with Depr1_2*;
Depr2_3 with Depr1_3*;
Exhau1_1*; Exhau1_2*; Exhau1_3*;
Exhau2_1*; Exhau2_2*; Exhau2_3*;
Exhau2_1 with Exhau1_1*; Exhau2_2 with Exhau1_2*;
Exhau2_3 with Exhau1_3*;

!LATENT OUTCOMES (Exhaustion, Depressive Symptoms: Latent Difference Scores)

!BETA


DEP2 ON DEP1 @1;
DEPDIFF BY DEP2 @1;
DEPDIFF ON DEP1* EE1 ;
!PSI
DEP1*; DEP2@0; DEPDIFF*;

Change Score für Depression


!BETA

EE2 ON EE1 @1;
EE2DIFF BY EE2 @1;
EE2DIFF ON EE1* DEP1 ;
!PSI
EE1*; EE2@0; EE2DIFF*;

Change Score für Erschöpfung



Latent Difference Scores



Two-Tailed
Estimate S.E. Est./S.E. P-Value

DEP1 BY				
DEPR1_1	1.000	0.000	999.000	999.000
DEPR1_2	1.067	0.048	22.144	0.000
DEPR1_3	0.927	0.052	17.978	0.000

DEP2 BY				
DEPR2_1	1.000	0.000	999.000	999.000
DEPR2_2	1.067	0.048	22.144	0.000
DEPR2_3	0.927	0.052	17.978	0.000

EE1 BY				
EXHAU1_1	1.000	0.000	999.000	999.000
EXHAU1_2	1.061	0.033	31.983	0.000
EXHAU1_3	0.996	0.043	22.988	0.000

EE2 BY				
EXHAU2_1	1.000	0.000	999.000	999.000
EXHAU2_2	1.061	0.033	31.983	0.000
EXHAU2_3	0.996	0.043	22.988	0.000

DEPDIFF BY				
DEP2	1.000	0.000	999.000	999.000

EEDIFF BY				
EE2	1.000	0.000	999.000	999.000


DEP2 ON				
DEP1	1.000	0.000	999.000	999.000

DEPDIFF ON				
DEP1	-0.462	0.097	-4.749	0.000
EE1	0.191	0.078	2.448	0.014

EE2 ON				
EE1	1.000	0.000	999.000	999.000

EEDIFF ON				
EE1	-0.262	0.095	-2.755	0.006
DEP1	-0.092	0.102	-0.897	0.370

Agenda



I. Grundlagen


II. Cross-lagged panel

III. Latent Change Scores

IV. Latent Growth Curve Modeling


V. Multilevel Modeling

Latent Growth Curve Modeling



- „Change as a latent construct“: Analyse der Eigenschaften der Veränderung in einem Konstrukt über die Zeit.
- Eigenschaften der Veränderung:
 - Form der Veränderung (linear oder nicht-linear)
 - Veränderungsrate (um wieviel verändert sich das Konstrukt über jedes Intervall?)
 - Zusammenhang zwischen Ausgangsniveau zum 1. Messzeitpunkt und Veränderungsrate
- Voraussetzung: Mindestens vier Messungen eines Konstrukts mit gleichen Zeitintervallen.
- Ausnahme: bei einem (nachweislich) linearen Anstieg können auch drei Messzeitpunkte ausreichen.

Latent Growth Curve Modeling



Spezifikation

Prinzip: Die Entwicklungsverläufe (trajectories) werden über zwei Faktoren identifiziert (Intercept und Slope)


Die wiederholt gemessene Variable (X) wird ganz ähnlich wie bei Konfirmatorischen Faktorenanalysen als Indikatoren von zwei latenten Variablen spezifiziert (Intercept und Slope)

Intercept: Ausgangsniveau zu Messzeitpunkt 1 des sich über die Zeit verändernden Konstrukts (alle Ladungen werden auf 1 gesetzt, da es sich um die Konstante handelt)


Slope: Ausmaß des (linearen oder nicht-linearen) Anstiegs im Konstrukt über den gesamten Untersuchungszeitraum (erste Ladung: 0; dann: 1,2,3,4 (linear) oder 1,4,9,16 (quadratisch))

Slope und Intercept werden miteinander korreliert.

Latent Growth Curve Modeling: Interpretation der Parameter



Latent Growth Curve Modeling: Strong Factorial Invariance



1. Metrische Invarianz


- Alle Ladungen der an mehreren Messzeitpunkten gemessenen latenten Variablen sind gleich

2. Skalare Invarianz

- Alle Intercepts der an mehreren Messzeitpunkten gemessenen latenten Variablen sind gleich


- Über Modellvergleiche und Differenztests wird die Modellverbesserung zu einem Messmodell mit keinen Restriktionen überprüft: Es dürfen keine signifikanten Unterschiede auftreten.
- Bei Latenten Wachstumskurvenmodellen umfassen die Messmodelle mindestens vier Messungen der Variablen X.

Latent Growth Curve Modeling: Parallele Verläufe



- Für zwei Variablen werden separate Wachstumskurvenmodelle spezifiziert.
- Die Slopes sind für beide Modelle spezifisch: Während Variable X quadratisch ansteigt, weist Variable Y eine lineare Zunahme über die Zeit auf.
- Die Zusammenhänge zwischen Intercepts und Slopes verweisen auf Abhängigkeit in den Ausgangsniveaus sowie Verläufen zwischen beiden Variablen:
 - Negative Korrelation zwischen Intercept_X und Intercept_Y: Personen mit hohem X tendieren zu niedrigen Ausgangswerten in Y
 - Positive Korrelation zwischen Intercept_X und Slope_Y: Personen mit hohem X haben einen stärkeren Anstieg in Y
 - Positive Korrelation zwischen beiden Slopes: Hoher Anstieg X geht mit hohem Anstieg in Y einher
 - Negative Korrelation zwischen Slope_X² und Slope_Y: Hoher Anstieg in Y sagt einen flacheren quadratischen Verlauf in X vorher.

Latent Growth Curve Modeling: Einfaches Beispiel



TITLE: linear growth model for a continuous outcome

DATA: FILE IS ex6.1.dat;

VARIABLE: NAMES ARE y11-y14;

MODEL: `i s | y11@0 y12@1 y13@2 y14@3;`

OUTPUT: STAND;

Spezifikation eines linearen Trends:


i = Intercept

s = slope

Für den Intercept werden die Ladungen automatisch auf 0 gesetzt.

Für den Slope: Veränderungsrate wird über die Notation @0 @1 @2 ... spezifiziert.

Latent Growth Curve Modeling: Einfaches Beispiel



	Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
I				
Y11	1.000	0.000	999.000	999.000
Y12	1.000	0.000	999.000	999.000
Y13	1.000	0.000	999.000	999.000
Y14	1.000	0.000	999.000	999.000

S				
Y11	0.000	0.000	999.000	999.000
Y12	1.000	0.000	999.000	999.000
Y13	2.000	0.000	999.000	999.000
Y14	3.000	0.000	999.000	999.000

S WITH I	0.133	0.032	4.100	0.000
----------	-------	-------	-------	-------

Kovarianz zwischen
Intercept und Slope

Means				
I	0.523	0.051	10.152	0.000
S	1.026	0.025	40.264	0.000

Signifikanter linearer Anstieg


Intercepts				
Y11	0.000	0.000	999.000	999.000
Y12	0.000	0.000	999.000	999.000
Y13	0.000	0.000	999.000	999.000
Y14	0.000	0.000	999.000	999.000

Variances				
I	0.989	0.088	11.178	0.000
S	0.224	0.022	10.068	0.000

Signifikante Unterschiede
im Anstieg: Hinweis auf
potentiell relevante Prädiktoren

Residual Variances				
Y11	0.475	0.058	8.122	0.000
Y12	0.482	0.040	11.980	0.000
Y13	0.473	0.047	10.080	0.000
Y14	0.545	0.083	6.593	0.000


Latent Growth Curve Modeling: Einfaches Beispiel



UNIVARIATE HIGHER-ORDER MOMENT DESCRIPTIVE STATISTICS

Variable/ Sample Size		Mean/ Variance	Skewness/ Kurtosis	Minimum/ Maximum	% with Min/Max	Percentiles		
						20%/60%	40%/80%	Median
Y11	500.000	0.514	-0.170	-2.693	0.20%	-0.493	0.237	0.558
Y12		1.449	-0.354	3.598	0.20%	0.813	1.610	
Y12	500.000	1.566	-0.077	-3.062	0.20%	0.443	1.283	1.560
Y13		1.974	0.003	5.964	0.20%	1.869	2.761	
Y13	500.000	2.568	-0.031	-2.745	0.20%	1.013	2.106	2.520
Y14		2.931	-0.252	8.428	0.20%	3.051	4.144	
Y14	500.000	3.601	-0.091	-2.360	0.20%	1.832	3.056	3.612
		4.298	-0.121	9.182	0.20%	4.164	5.335	

Latent Growth Curve Modeling: Beispiel für quadratischen Anstieg



TITLE: quadratic growth model for a continuous outcome

DATA: FILE IS ex6.9.dat;

VARIABLE: NAMES ARE y11-y14;

MODEL: `i s q | y11@0 y12@1 y13@2 y14@3;`

OUTPUT: STAND;

Spezifikation eines linearen Trends:

i = Intercept


s = Linearer slope

q = Quadratischer slope

Für den Intercept werden die Ladungen automatisch auf 0 gesetzt.

Für den Slope: Veränderungsrate wird über die Notation @0 @1 @2 ... spezifiziert, die auch den quadratischen Slope festlegt.


Latent Growth Curve Modeling: Beispiel für quadratischen Anstieg



	Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
Q				
Y11	0.000	0.000	999.000	999.000
Y12	1.000	0.000	999.000	999.000
Y13	4.000	0.000	999.000	999.000
Y14	9.000	0.000	999.000	999.000
S WITH				
I	-0.173	0.300	-0.578	0.564
Q WITH				
I	0.101	0.080	1.269	0.204
S	-0.179	0.117	-1.524	0.127
Means				
I	0.521	0.062	8.442	0.000
S	1.035	0.077	13.455	0.000
Q	0.512	0.031	16.441	0.000
Intercepts				
Y11	0.000	0.000	999.000	999.000
Y12	0.000	0.000	999.000	999.000
Y13	0.000	0.000	999.000	999.000
Y14	0.000	0.000	999.000	999.000
Variances				
I	1.246	0.273	4.569	0.000
S	0.998	0.358	2.787	0.005
Q	0.282	0.060	4.666	0.000
Residual Variances				
Y11	0.685	0.265	2.589	0.010
Y12	0.882	0.115	7.705	0.000
Y13	0.946	0.183	5.178	0.000
Y14	0.738	0.945	0.781	0.435

Signifikanter quadratischer Anstieg

Latent Growth Curve Modeling: Vorhersage durch andere Prädiktoren



TITLE: LGM with time-varying covariates

DATA: FILE IS ex6.10.dat;

VARIABLE: NAMES ARE y11-y14 x1 x2 a31-a34;

MODEL: i s | y11@0 y12@1 y13@2 y14@3;

i s ON x1 x2;

Vorhersage von Intercept und Slope
durch zwei Prädiktoren

y11 ON a31;

y12 ON a32;


y13 ON a33;

y14 ON a34;

Zeitlich synchronisierte Vorhersage
der Variable Y durch einen zeitlich
variierenden Prädiktor

OUTPUT: STAND;

Latent Growth Curve Modeling: Vorhersage durch andere Prädiktoren




		Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
I	ON				
	X1	0.557	0.054	10.278	0.000
	X2	0.718	0.055	12.950	0.000
S	ON				
	X1	0.264	0.025	10.543	0.000
	X2	0.473	0.026	18.401	0.000
Y11	ON				
	A31	0.190	0.044	4.294	0.000
Y12	ON				
	A32	0.323	0.038	8.429	0.000
Y13	ON				
	A33	0.344	0.038	8.985	0.000
Y14	ON				
	A34	0.303	0.050	6.002	0.000
S	WITH				
I		0.055	0.035	1.570	0.117

Vorhersage des Intercepts durch
X1 und X2

Vorhersage des Slopes durch
X1 und X2: Je höher die Werte,
umso stärker der lineare Anstieg

Zeitlich synchronisierte
Zusammenhänge zwischen
Y und A an jedem Messzeit-
punkt

Agenda



I. Grundlagen


II. Cross-lagged panel

III. Latent Change Scores

IV. Latent Growth Curve Modeling

V. Multilevel Modeling


Multilevel Path Modeling: Longitudinal Studies




- Bei Multilevel Path Modeling werden Pfadmodelle auf zwei (oder mehreren) Ebenen spezifiziert: Die Grundlage bildet die Kovarianzstrukturanalyse, bei der die Varianzen und Kovarianzen in within und between-Anteile zerlegt werden
- Erlaubt die Integration unterschiedlicher Methoden der Längsschnittanalyse: Growth-Curve-Modeling, Cross-lagged Panel und Latent Change Scores
- Random-Slope: Cross-level interaction effects

Multilevel Path Modeling: Geschachtelte/genestete Datensätze


Level 3:
Organisationsebene



Level 2:
Arbeitsgruppen-
ebene




Level 1:
Individualebene




Eine Vielzahl von Untersuchungsfeldern ist durch eine geschachtelte Mehrebenenstruktur gekennzeichnet:

- Personen sind innerhalb sozialer Einheiten eingebettet
- Soziale Einheiten stellen Kontexte dar, die spezifische Bedingungen haben
- Diese Bedingungen können auf individuelles Verhalten und Erleben wirken

Multilevel Path Modeling: Tagebuchstudie als Beispiel



Multilevel Path Modeling: Random Intercept



- Die Regressionskonstanten (β_{0j}) variieren in Abhängigkeit der Level-2-Einheiten (Gruppenzugehörigkeit)
- Dabei können kontextspezifische Effekte (Level 2-Variablen) die Varianz der intercepts bedingen: ICC(1)

Wenn sich die Varianz der intercepts auf Unterschiede in den Level 2-Variablen zurückführen lässt, so müssen sich die intercepts mittels einer linearen Funktion aus gewichteten Level 2-Prädiktoren direkt vorhersagen lassen.

Multilevel Path Modeling: Random Intercept

$$Y_{ij} = \beta_{0j} + \beta_{1j} \cdot X_{ij} + r_{ij}$$
$$\beta_{0j} = \gamma_{00} + \gamma_{01} \cdot Z_j + u_{0j}$$

Index i = Einzelnes Untersuchungselement (Level 1)

Index j = Gruppenzugehörigkeit (Level 2)

Z_j = Level 2-Prädiktor (Level 2)

γ = Parameter der Gruppenebene (Level 2)

u = Residuum der Gruppenebene

Gruppen-
ebene

Level 2 -
Prädiktor: Z_1

$$\beta_{0j} = \gamma_{00} + \gamma_{01} \cdot Z_j$$


Individual-
ebene

Level 1 -
Prädiktor: X_1

$$\beta_{1j} \cdot X_{1j}$$

Kriterium: Y

Multilevel Path Modeling: Random Slope



- Die Steigungskoeffizienten (β_{1j}) variieren in ihrer Ausprägung und Richtung in Abhängigkeit der Level 2-Einheiten
- Hier können ebenfalls kontextspezifische Effekte (Level 2-Variablen) die Varianz der slopes in Richtung und Stärke bedingen

Im Falle einer Cross-Level Interaktion, bei der die Wirkung eines Level 1-Prädiktors in Abhängigkeit von der Ausprägung von Level 2-Prädiktoren unterschiedlich ausfällt, müssen sich die slopes durch eine gewichtete Summe aus Level 2-Prädiktoren vorhersagen lassen.

Multilevel Path Modeling: Random Slope

$$Y_{ij} = \beta_{0j} + \beta_{1j} \cdot X_{ij} + r_{ij}$$
$$\beta_{0j} = \gamma_{00} + \gamma_{01} \cdot Z_j + u_{0j}$$
$$\beta_{1j} = \gamma_{10} + \gamma_{11} \cdot Z_j + u_{1j}$$

Index i = Einzelnes Untersuchungselement (Level 1)

Index j = Gruppenzugehörigkeit (Level 2)

Z_j = Level 2-Prädiktor (Level 2)

γ = Parameter der Gruppenebene (Level 2)

u = Residuum der Gruppenebene

Gruppen-
ebene

Level 2 -
Prädiktor: Z_1

$$\beta_{1j} = \gamma_{10} + \gamma_{11} \cdot Z_j$$

$$\beta_{0j} = \gamma_{00} + \gamma_{01} \cdot Z_j$$

Individual-
ebene

Level 1 -
Prädiktor: X_1

$$\beta_{1j} \cdot X_{1j}$$

Kriterium: Y

Multilevel Path Modeling: Schätzalgorithmen

1. full information maximum likelihood (FIML):

- Maximiert die Likelihood-Funktion für feste Effekte (γ) und Varianzkomponenten (τ, σ) simultan
- Die festen Effekte werden bei der Varianzkomponentenschätzung als bekannt vorausgesetzt: Dabei werden die Freiheitsgrade überschätzt
- Folge: Verzerrungen (bias) bei der Schätzung von Varianzkomponenten in kleinen Stichproben
- Anpassung des gesamten Modells: Für Random-Intercept-Modelle geeignet

2. restricted maximum likelihood (REML):

- Maximiert die Likelihood-Funktion der Residuen
- Dabei werden nur die Varianzkomponenten als unbekannte Parameter angesehen
- Anpassung der zufälligen Effekte: Für Random-Slope-Modell geeignet

Multilevel Path Modeling: Zentrierung

Hintergrund

- **Statistisch:** Vermeidung von Multikollinearität und verzerrten Schätzungen bei Moderatormodellen
- **Inhaltlich:** Erhöhung der Interpretierbarkeit des intercepts
 - Die Ausprägung Null im zentrierten Level 1-Prädiktor repräsentiert den Durchschnitt entweder der Gruppe oder der Gesamtstichprobe

Verschiedene Skalierungsmöglichkeiten:

1. Zentrierung am Gesamtmittelwert ($X_{ij} - \bar{X}$ - grand mean)
2. Zentrierung am Gruppenmittelwert ($X_{ij} - \bar{X}_j$ - group mean)
3. Zentrierung an einem inhaltlich relevanten Wert (Populations-mittelwert)
4. Keine Zentrierung (wird nicht empfohlen; Hofmann & Gavin, 1998; Raudenbush & Bryk, 2002)




Multilevel Path Modeling: Zentrierung

Wahl der
Zentrierung hat
Einfluss auf

1. Schätzung der festen Level 1-Koeffizienten
 2. Zerlegung von Personen- und Gruppeneffekten
 - group-mean: Level 1-Prädiktoren klären nur Varianz **innerhalb** der Gruppen auf
 - grand-mean: Level 1-Prädiktoren klären auch Varianz **zwischen** den Gruppen auf
 3. Schätzung der Level 2-Effekte bei Kontrolle von Level 1-Kovariaten
 4. Schätzung der Varianz von Level 1-Koeffizienten (slopes)
 - Hier sollte group-mean-Zentrierung gewählt werden, da grand-mean-Zentrierung zu einer Unterschätzung der Varianz in den slopes führt
- random-intercept
Modelle

Multilevel Path Modeling: Zentrierung

random-intercept
Modelle



$X_{ij} - \bar{X}$
Grand-Mean



$X_{ij} - \bar{X}_j$
Group-Mean



*Nur wenn die Level 2-
Variable das Aggregat eines
Level 1-Prädiktors ist




Multilevel Path Modeling: Beispiel für Random-Intercept

TITLE: two-level regression model with random intercept

DATA: FILE = ex9.1a.dat;

VARIABLE: NAMES = y x w xm clus;



WITHIN = x;
BETWEEN = w xm;
CLUSTER = clus;

Zuordnung der Variablen:

WITHIN: Variablen auf Level 1

BETWEEN: Variablen auf Level 2

CLUSTER: Gruppen- bzw. Zugehörigkeit

DEFINE: CENTER x (GROUPMEAN);

Zentrierungsbefehl:

Groupmean oder Grandmean

ANALYSIS: TYPE = TWOLEVEL;

Analysotyp:

Mehrebenenanalyse

MODEL: %WITHIN%
y ON x;


Level 1

%BETWEEN%
y ON w xm;

Level 2

OUTPUT: STAND;

Multilevel Path Modeling: Beispiel für Random-Intercept



		Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
Within Level					
Y	ON				
X		0.728	0.033	22.276	0.000
Residual Variances					
Y		1.022	0.041	25.091	0.000
Between Level					
Y	ON				
W		0.576	0.105	5.486	0.000
XM		0.886	0.156	5.671	0.000
Intercepts					
Y		1.990	0.081	24.590	0.000
Residual Variances					
Y		0.580	0.094	6.168	0.000

Level 1


Level 2

Multilevel Path Modeling: Beispiel für Random-Slope

TITLE: two-level regression model with random slope

DATA: FILE = ex9.2a.dat;

VARIABLE: NAMES = y x w xm clus;



WITHIN = x;
BETWEEN = w xm;
CLUSTER = clus;

Zuordnung der Variablen:

WITHIN: Variablen auf Level 1

BETWEEN: Variablen auf Level 2

CLUSTER: Gruppen- bzw. Zugehörigkeit

DEFINE: CENTER x (GROUPMEAN);

Zentrierungsbefehl:

Groupmean oder Grandmean

ANALYSIS: TYPE = TWOLEVEL;

Analysotyp:

Mehrebenenanalyse

MODEL: %WITHIN%
s | y ON x;

Level 1:

„s | y on x;“ Random Slope für den within-Pfad X → Y


%BETWEEN%
y s ON w xm;
y WITH s;

Level 2:

„s ON w xm“: Cross-level interaction

OUTPUT: STAND;

Multilevel Path Modeling: Beispiel für Random-Slope




	Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
Within Level				
Residual Variances				
Y	1.035	0.047	21.915	0.000
Between Level				
S ON				
W	0.412	0.097	4.236	0.000
XM	0.526	0.133	3.969	0.000
Y ON				
W	0.968	0.127	7.603	0.000
XM	1.231	0.179	6.872	0.000
Y WITH				
S	0.308	0.063	4.856	0.000
Intercepts				
Y	2.134	0.099	21.599	0.000
S	1.039	0.076	13.620	0.000
Residual Variances				
Y	0.728	0.111	6.568	0.000
S	0.336	0.061	5.535	0.000

Cross-level interaction:
W und XM moderieren den within-Pfad s

Pfad X → Y


Level 2-Varianz im Slope

Multilevel Path Modeling: Cross-Lagged Panel



- Längsschnittanalyse im Multilevel-design würde bedeuten, dass
 - (1) innerhalb der Level 1-Einheiten zeitliche Veränderungen in der abhängigen Variable modelliert werden,
 - (2) innerhalb der Level 2-Einheiten zeitliche Veränderungen in der abhängigen Variable modelliert werden und/oder
 - (3) die Messwiederholung der unabhängigen/abhängigen Variablen auf Level 1 oder Level 2 selber für die Modellierung der Veränderung zu Grunde legen
- Im einfachsten Fall würde man die Ausgangswerte am vorherigen Messzeitpunkt als Prädiktor miteinbeziehen (für (1). und (2).).
- Alternativ wären auch Latent Difference Scores für den Fall (1). und (3). möglich.
- Multilevel Latent Growth Curve Modeling ist die Lösung für den Fall (3).

Multilevel Path Modeling: Latent Growth Curve Modeling



DEFINE: CENTER a1-a4 x (GROUPMEAN);

ANALYSIS: TYPE = TWOLEVEL RANDOM;
ALGORITHM = INTEGRATION;
INTEGRATION = 10;

MODEL: %WITHIN%

iw sw | y1@0 y2@1 y3@2 y4@3;

LGM auf Level 1

y1-y4 (1);

iw sw ON x;

Vorhersage durch den
within-Prädiktor x

s* | y1 ON a1;

s* | y2 ON a2;

s* | y3 ON a3;

s* | y4 ON a4;

Repeated Random Slope:
Within-Pfade werden
gleichgesetzt

%BETWEEN%

ib sb | y1@0 y2@1 y3@2 y4@3;

LGM auf Level 2


y1-y4@0;

ib sb s ON w;

Vorhersage des Random
Slope

OUTPUT: TECH1 TECH8;

Multilevel Path Modeling: Latent Growth Curve Modeling




		Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
Within Level					
IW					
Y1		1.000	0.000	999.000	999.000
Y2		1.000	0.000	999.000	999.000
Y3		1.000	0.000	999.000	999.000
Y4		1.000	0.000	999.000	999.000
SW					
Y1		0.000	0.000	999.000	999.000
Y2		1.000	0.000	999.000	999.000
Y3		2.000	0.000	999.000	999.000
Y4		3.000	0.000	999.000	999.000
IW	ON				
X		0.997	0.070	14.319	0.000
SW	ON				
X		0.244	0.049	5.012	0.000
SW	WITH				
IW		0.140	0.058	2.435	0.015
Variances					
S		0.602	0.066	9.171	0.000
Residual Variances					
Y1		0.932	0.086	10.837	0.000
Y2		0.932	0.086	10.837	0.000
Y3		0.932	0.086	10.837	0.000
Y4		0.932	0.086	10.837	0.000
IW		0.594	0.094	6.342	0.000
SW		0.503	0.051	9.943	0.000

Vorhersage von der
Intercepts und Slopes
auf within-Level

Varianz in s (repeated
random slope)

Multilevel Path Modeling: Latent Growth Curve Modeling



		Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
Between Level					
IB					
Y1		1.000	0.000	999.000	999.000
Y2		1.000	0.000	999.000	999.000
Y3		1.000	0.000	999.000	999.000
Y4		1.000	0.000	999.000	999.000
SB					
Y1		0.000	0.000	999.000	999.000
Y2		1.000	0.000	999.000	999.000
Y3		2.000	0.000	999.000	999.000
Y4		3.000	0.000	999.000	999.000
IB	ON				
W		0.420	0.164	2.561	0.010
SB	ON				
W		0.309	0.070	4.422	0.000
S	ON				
W		0.628	0.070	8.927	0.000
SB	WITH				
IB		-0.090	0.097	-0.919	0.358
Intercepts					
Y1		0.000	0.000	999.000	999.000
Y2		0.000	0.000	999.000	999.000
Y3		0.000	0.000	999.000	999.000
Y4		0.000	0.000	999.000	999.000
IB		1.028	0.137	7.499	0.000
SB		0.606	0.073	8.280	0.000
S		1.073	0.075	14.272	0.000

Vorhersage von der
Intercepts und Slopes
auf between-Level

Moderation von s (Cross-
level interaction)