



Strukturgleichungsmodellierung

FoV „Methodenlehre“

FSU-Jena

Dipl.-Psych. Norman Rose



Parameterschätzung, Modelltest & Fit Indizes bei SEM

Forschungsorientierte Vertiefung - Methodenlehre

Dipl.-Psych. Norman Rose



Stichprobe

- Für Strukturgleichungsmodelle mit und ohne latente Variablen gilt:
 - Gilt das spezifizierte Modell sind wahre und wahre modellimplizierte Varianz-Kovarianzmatrix gleich: $\Sigma = \Sigma(\theta)$
 - Gilt das spezifizierte Modell sind wahre und wahre modellimplizierte Erwartungswertstruktur $\mu(\theta)$ gleich.
- **Stichprobenproblem**
 - Weder die wahre noch die wahre modellimplizierte Varianz-Kovarianzmatrix Σ und $\Sigma(\theta)$ sind in Anwendung gegeben.
 - Auch unter Gültigkeit des Modells in der Population sind zufällige Abweichungen in der Stichprobe möglich.
 - Modellparameter sind in Anwendung unbekannt.



Vorgehen bei SEM

- Praktisches Vorgehen:
 - Verwendung der Stichprobenschätzer:
 - Mittelwertsvektor der manifesten Variablen aus der Stichprobe als Schätzer des wahren Erwartungswertvektors $\mathbf{M} = \hat{\boldsymbol{\mu}}$
 - Empirische Varianz-Kovarianzmatrix \mathbf{S} als Schätzer der wahren Varianz-Kovarianzmatrix: $\mathbf{S} = \hat{\boldsymbol{\Sigma}}$
 - Schätzung der Modellparameter unter Annahme der Gültigkeit des spezifizierten Modells (Maximum Likelihood- oder Least Square Schätzungen)
 - Schätzer der wahren modellimplizierten Varianz-Kovarianzmatrix $\boldsymbol{\Sigma}(\hat{\boldsymbol{\theta}}) = \hat{\boldsymbol{\Sigma}}(\boldsymbol{\theta})$
 - Inferenzstatistischer Test auf Gleichheit von wahrer und wahrer modellimplizierter Varianz-Kovarianzmatrix aufgrund der stichprobenbasierten Schätzer



Modellidentifikation

- Die Modellparameter müssen aus den empirischen Varianzen, Kovarianzen und Mittelwerten der manifesten Variablen geschätzt werden.
 - ➔ Dementsprechend müssen alle zu schätzenden Parameter im Modell (Varianzen, Kovarianzen latenter Variablen, Intercepts und Regressionskoeffizienten) mit Hilfe empirischer Kennwerte darstellbar sein. Ist dies der Fall, so ist das Modell identifiziert!
- Die **Modellidentifikation** führt zur eindeutigen mathematischen Darstellung der zu schätzenden Modellparameter, ggf. unter Einführung bestimmter Restriktionen.



Modellidentifikation

- Mathematisch basierte Definition der Modellidentifikation:
 - Seien θ_1 und θ_2 Vektoren mit den Modellparametern eines Modells 1 und 2 zu den gleichen Variablen. Ein Modell gilt dann als identifiziert, wenn aus der Gleichheit der modellimplizierten Varianz-Kovarianzmatrizen $\Sigma(\theta_1)$ und $\Sigma(\theta_2)$ die Gleichheit der Parametervektoren θ_1 und θ_2 folgt.

$$\Sigma(\theta_1) = \Sigma(\theta_2) \iff \theta_1 = \theta_2$$



Modellidentifikation – *t*-Regel

- In Anwendung ist es nicht immer leicht zu entscheiden, ob ein Modell identifiziert ist oder nicht.
 - ➔ praktische Hilfen bieten Identifikationsregeln
- ***t*-Regel:**

Ein Modell ist nicht identifiziert, wenn die Zahl der zu schätzenden Modellparameter die Zahl der gegebenen Varianzen, Kovarianzen und Mittelwerte unterschreitet



Modellidentifikation – *t*-Regel

- Zahl der gegebenen Varianzen und Kovarianzen

$$\frac{1}{2}(p+q)(p+q+1)$$

- Zahl k der gegebenen Kennwerte (Varianzen, Kovarianzen und Mittelwerte) unter Einbeziehung der Erwartungswertstruktur

$$k = \left(\frac{1}{2}(p+q+1) + 1 \right) (p+q)$$

→ wobei: p ist die Anzahl der exogenen manifesten Variablen X und q ist die Zahl der endogenen manifesten Variablen Y .



Modellidentifikation – t -Regel

- Die Zahl t ist die Differenz $k - l$, wobei l die Zahl der zu schätzenden Modellparameter ist.
- Es gilt:
 - Ist $t < 0$, so ist das Modell nicht identifiziert.
 - Ist $t = 0$, so ist das Modell gerade identifiziert.
 - Ist $t > 0$, so ist das Modell überidentifiziert.
- Bei $t > 0$, entspricht t gerade der Zahl der Freiheitsgrade (df).



Parameterschätzung in SEM

- **Verschiedene Schätzverfahren:**
 - ➔ 2 große Gruppen können unterschieden werden

- 1. **Maximum Likelihood Schätzer (ML)**

- 2. **Least Square Schätzer**
 - **Weighted Least Square (WLS; „verteilungsfreies Verfahren“)**
 - **Generalized Least Square (GLS)**
 - **Diagonally Weighted Least Square (DWLS)**
 - **Unweighted Least Square (ULS)**



Parameterschätzung in SEM

- Allen Schätzverfahren ist gemeinsam, dass sie die Parameter so schätzen dass die Elemente der Residualmatrix R_S möglichst klein sind.

$$R_S = S - \Sigma(\hat{\theta})$$

- Wird auch die Erwartungswertstruktur mitmodelliert, so werden außerdem die Elemente des Residualvektors R_M minimiert.

$$R_M = M - \mu(\hat{\theta})$$



Maximum-Likelihood-Schätzung

● Prinzip:

- Modellparameter werden so geschätzt, dass die empirischen Daten maximal wahrscheinlich sind.
 - ➔ mathematisch: Die gemeinsame Wahrscheinlichkeitsfunktion wird maximiert!
- **In SEM: Die Diskrepanzfunktion wird minimiert!**
 - ➔ Die Diskrepanzfunktion der ML-Schätzung:

$$F_{ML} = \underbrace{\log |\boldsymbol{\Sigma}(\hat{\boldsymbol{\theta}})| + \text{tr}[\mathbf{S}\boldsymbol{\Sigma}^{-1}(\hat{\boldsymbol{\theta}})] - \log |\mathbf{S}| - (p + q)}_{\text{Varianz-Kovarianzstruktur}} + \underbrace{\left[\mathbf{M} - \boldsymbol{\mu}(\hat{\boldsymbol{\theta}}) \right]' \hat{\boldsymbol{\Sigma}}^{-1} \left[\mathbf{M} - \boldsymbol{\mu}(\hat{\boldsymbol{\theta}}) \right]}_{\text{Erwartungswertstruktur}}$$

Varianz-Kovarianzstruktur

Erwartungswertstruktur



Maximum-Likelihood-Schätzung

- ML-Schätzer sind konsistente und effiziente Schätzer, bei hinreichend großen Stichproben!
- Voraussetzung: **Multivariate Normalverteilung** der Variablen Y_i und X_j .
- Der Funktionswert der Diskrepanzfunktion ist mit $(N - 1)$ multipliziert χ^2 -verteilt, und dient zum Modelltest.

$$(N - 1)F_{ML} \rightarrow \chi^2$$



Modelltest – χ^2 -Test

- **Nullhypothese: $\Sigma = \Sigma(\theta)$**

➔ wahre und wahre modellimplizierte Varianz-Kovarianzmatrix sind gleich

- **Alternativhypothese: $\Sigma \neq \Sigma(\theta)$**

➔ wahre und wahre modellimplizierte Varianz-Kovarianzmatrix sind nicht gleich!

- **Beachte: Nullhypothese ist Wunschhypothese!**



Modelltest – χ^2 -Test

- **Interpretation:**

steigende χ^2 -Werte → schlechtere Modellpassung → niedrigerer p -Wert
(bei gegebenen Freiheitsgraden!)

p -Wert gibt an, wie groß die Wahrscheinlichkeit ist, dass ein solcher oder noch größerer χ^2 -Wert auftritt, gegeben die Nullhypothese gilt.

- **Problem:**

Bei zunehmender Stichprobengröße (wachsender Power des Tests) werden auch kleinste („irrelevante“) Modellabweichungen signifikant!

- **Alternative: Deskriptive Fit-Indizes**



Deskriptive Goodness-of-Fit-Indizes

- Vielzahl von GoF-Indizes entwickelt worden:
 1. GoF-Indizes des „Overall Modelfit“
 - Root Mean Square Error of Approximation (RMSEA)
 - Standardized Root Mean Square Residual (SRMR)
 2. Inkrementelle GoF-Indizes
 - Nonnormed Fit Index (NNFI) und Normed Fit Index (NFI)
 - Comparative Fit Index (CFI)
 3. Absolute GoF-Indizes
 - Goodness of Fit Index (GFI)
 - Adjusted Goodness of Fit Index (AGFI)
 4. Prädiktive GoF-Indizes / Informationskriterien
 - Akaikes Informationskriterium (AIC)
 - Bayes Informationskriterium (BIC)
 - Expected Cross Validation Index (ECVI)



Root Mean Square Error of Approximation (RMSEA)

- Diskrepanzen:

Diskrepanz zwischen Σ und $\Sigma(\hat{\theta})$: Diskrepanz bezogen auf den Gesamtfehler

Diskrepanz zwischen Σ und $\Sigma(\theta)$: Diskrepanz bezogen auf die Approximation

Diskrepanz zwischen $\Sigma(\theta)$ und $\Sigma(\hat{\theta})$: Diskrepanz bezogen auf die Schätzung

- Beziehung zwischen den Diskrepanzen:

$$\underbrace{\Sigma - \Sigma(\hat{\theta})}_{\text{Diskrepanz due to overall error}} = \underbrace{[\Sigma - \Sigma(\theta)]}_{\text{Diskrepanz due to approximation}} + \underbrace{[\Sigma(\theta) - \Sigma(\hat{\theta})]}_{\text{Diskrepanz due to estimation}}$$

- Von theoretischem Interesse ist vor allem die Diskrepanz aufgrund der Approximation!



Root Mean Square Error of Approximation (RMSEA)

- Der RMSEA ist ein deskriptiver Kennwert der die Diskrepanz bezogen auf die Approximation („Error of Approximation“) schätzt.

$$RMSEA = \sqrt{\max \left\{ \frac{F[\mathbf{S}, \boldsymbol{\Sigma}(\hat{\boldsymbol{\theta}})]}{df} - \frac{1}{N-1}, 0 \right\}} = \sqrt{\max \left\{ \frac{\chi^2 - df}{df(N-1)}, 0 \right\}}$$

- **Interpretation:**

- $RMSEA < 0.05$ gute Modellpassung
- $0.05 < RMSEA < 0.08$ adäquate/mäßige Modellpassung
- $RMSEA > 0.08$ schlechte Modellpassung



Root Mean Square Error of Approximation (RMSEA)

- Üblicherweise wird das 90%-Konfidenzintervall für den RMSEA angegeben!
- Sog. „Test of close fit“:
 - Nullhypothese: $RMSEA \leq 0.05$
 - ➔ Nullhypothese kann beibehalten werden, wenn die untere Intervallgrenze des 90%-Konfidenzintervalls kleiner als 0.05 ist.



Standardized Root Mean Square Residual (SRMR)

- SRMR entspricht approximativ dem mittleren absoluten Residuum der Residualkorrelationen.

$$SRMR = \sqrt{\frac{\sum_{i=1}^p \sum_{j=1}^p \left[\frac{\sigma_{ij} - \sigma_{ij}(\hat{\theta})}{\sqrt{\hat{\sigma}_i} \sqrt{\sigma_j}} \right]^2}{(p+q)(p+q+1)}} = \sqrt{\frac{\sum_{i=1}^p \sum_{j=1}^p \left[Kor_{ij} - \frac{\sigma_{ij}(\hat{\theta})}{\sqrt{\hat{\sigma}_i} \sqrt{\hat{\sigma}_j}} \right]^2}{(p+q)(p+q+1)}}$$

- Interpretation:
 - SRMR = 0 → perfekte Modellpassung
 - SRMR < 0.05 → gute Modellpassung
 - 0.05 < SRMR < 0.10 → adäquate/mäßige Modellpassung



Nonnormed Fit Index (NNFI)

- **Nonnormed Fit Index (NNFI)** oder sog. Tucker-Lewis Index (TLI) ist eine inkrementeller Fit-Index!
- **Prinzip der inkrementellen Fit-Indizes:**
 - Basieren auf dem Modellvergleich zwischen dem theoretisch spezifizierten Modell und dem Basismodell!
 - Das gewählte Basismodell ist meist das sog. Unabhängigkeitsmodell das von unkorrelierten manifesten Variablen ausgeht (Annahme, dass Σ eine Diagonalmatrix ist!).
 - Berechnung der χ^2 -Werte für das theoretisch spezifizierten Modell und das Basismodell χ_b^2



Nonnormed Fit Index (NNFI)

- Berechnung:

$$NNFI = \left(\frac{\chi_b^2}{df_b} - \frac{\chi^2}{df} \right) : \left(\frac{\chi^2}{df} - 1 \right)$$

- Interpretation:

- $NNFI > 0.97 \rightarrow$ gute Modellpassung
- $0.95 < NNFI < 0.97 \rightarrow$ adäquate/mäßige Modellpassung
- $NNFI = 1.0 \rightarrow$ perfekte Modellpassung
- $NNFI > 1.0 \rightarrow$ „Overfitting“ im Modell sind mehr Parameter spezifiziert als nötig



Goodness of Fit Index (GFI)

- Goodness of Fit Index (GFI) ist ein absoluter GoF-Index
- **Prinzip der absoluten Fit-Indizes:**
 - Geben den relativen Anteil der Varianzen und Kovarianzen aller manifesten Variablen an, die durch das Modell erklärt wird.

- **Berechnung:**

$$GFI = 1 - \frac{\chi^2}{\chi_b^2}$$

- **Interpretation:**

- $GFI = 1.0 \rightarrow$ perfekte Modellpassung
- $GFI > 0.95 \rightarrow$ gute Modellpassung
- $0.90 < GFI < 0.95 \rightarrow$ adäquate/mäßige Modellpassung
- $GFI < 0.90 \rightarrow$ schlechte Modellpassung