

Modellselektion in Finite Mixture PLS-Modellen
Eine Simulationsstudie zur Messung der Performanz von Informationskriterien

Marko Sarstedt
André Salcher

Münchener Wirtschaftswissenschaftliche Beiträge 2007-02
März 2007



LMU
LUDWIG-MAXIMILIANS-UNIVERSITÄT MÜNCHEN
FAKULTÄT FÜR BETRIEBSWIRTSCHAFT

Online: <http://epub.ub.uni-muenchen.de/>

1. Einleitung und Problemstellung

Seit den achtziger Jahren hat sowohl in der Wissenschaft als auch in der Marktforschungspraxis die Verwendung von Strukturgleichungsmodellen mit latenten Variablen immer stärkere Verbreitung gefunden. Strukturgleichungsmodelle stellen mittlerweile einen Quasi-Standard in der Marketingforschung dar, um auf Basis eines theoretisch fundierten Hypothesensystems formulierte Ursache-Wirkungs-Beziehungen zwischen latenten Variablen zu untersuchen.

Neben der Kovarianzstrukturanalyse hat sich mit dem Verfahren der Partiellen Kleinsten Quadrate (Partial Least Squares, PLS) in den letzten Jahren eine weitere Methode zur Schätzung von Strukturgleichungsmodellen etablieren können (EBERL 2006a, S. 87), die vor allem im deutschsprachigen Raum zunehmend stärkere Verbreitung findet (FASSOT 2005, S. 22 ff.).

Eine wichtige Weiterentwicklung der PLS-Pfadmodellierung wurde von HAHN (2002) vorgestellt. Sie verbindet die Stärken der PLS-Methodik mit den Vorteilen der Maximum-Likelihood-Schätzung bei der Ableitung von Marktsegmenten mit Hilfe von Mischverteilungsmodellen.¹ Dieser so genannte Finite Mixture-PLS (FIMIX-PLS)-Ansatz ermöglicht eine simultane Schätzung der Modellparameter bei gleichzeitiger Ermittlung von Heterogenität in der Datenstruktur. Allgemein wird der Methodengruppe der Mischverteilungsmodelle eine hohe Relevanz hinsichtlich zukünftiger Anwendungen zur Marktsegmentierung zugesprochen (WEDEL/KAMAKURA 2000, S. 19). Im Kontext der Erfolgsfaktorenforschung stellen beispielsweise ALBERS und HILDEBRANDT fest: „Im Allgemeinen beobachtet man, dass sich Maßnahmen auf den Erfolg bei unterschiedlichen Unternehmen oder anderen Untersuchungseinheiten unterschiedlich auf den Erfolg auswirken, weil bestimmte situative Faktoren bestehen, für die es häufig schwer ist, Beobachtungen zu erhalten. Man muss im Regelfall davon ausgehen, dass unbeobachtete Heterogenität in den Daten des Samples gegeben ist. Die Parameterwerte für die Wirkungen der einzelnen Konstrukte auf den Erfolg sind deshalb unterschiedlich für unterschiedliche Segmente von Untersuchungseinheiten.“ (ALBERS/HILDEBRANDT 2006, S. 28) Das von HAHN entwickelte und nachfolgend von RINGLE ET AL. (2005, 2007) und RINGLE (2006) erweiterte FIMIX-PLS-Konzept stellt den ersten Ansatz dar, Latent-Class-Modelle für die Struktur zwischen den Konstrukten auf Grundlage von PLS zu schätzen.²

¹ Vgl. auch HAHN ET AL. (2005).

² Einen Ansatz zur segmentspezifischen Schätzung von kovarianzstrukturbasierten Strukturgleichungsmodellen stellen JEDIDI ET AL. (1997a, 1997b) vor.

Aufgrund der Einbeziehung unbeobachteter Heterogenität stellt dieser Ansatz eine flexible Möglichkeit der Anpassung theoretischer Verteilungen an reale Daten dar und bildet einen modelltheoretischen Rahmen in der Schätzung von Strukturgleichungsmodellen, welcher es dem Anwender ermöglicht, Segmentierungsstrategien auf Grundlage von Inferenzstatistiken zu formulieren. Hierdurch kann eine Gütebeurteilung mit Hilfe statistischer Kriterien vorgenommen werden.

Ein wesentliches Problem bei der Anwendung von Mischverteilungsmodellen ist die Bestimmung der Anzahl der zugrunde liegenden Segmente, welche a priori unbekannt ist. Dieses Problem ist äußerst bedeutend, konnte aber noch nicht zufriedenstellend gelöst werden (MCLACHLAN/PEEL 2000, S. 175; WEDEL/KAMAKURA 2000, S. 89). Neben diversen statistischen Testverfahren, die jedoch aufgrund methodischer Probleme und hoher Rechenintensität keinen Einzug in Softwareanwendungen gefunden haben (SARSTEDT 2006, S. 6 f.), wird zur Handhabung dieser Modellselektionsproblematik auf so genannte Informationskriterien zurückgegriffen. Dieser heuristische Ansatz ermöglicht den Vergleich von Modellen, die unter Zugrundelegung unterschiedlicher Segmentzahlen geschätzt wurden. Ziel ist es, das Modell auszuwählen, das die Kullback-Leibler-Entropie als Differenz zwischen der wahren und der geschätzten Dichtefunktion minimiert (MCLACHLAN/PEEL 2000, S. 202 f.). Neben der Anpassungsgüte des Modells in Form des mit minus zwei multiplizierten Log-Likelihoods wird ferner die Modellkomplexität in Form eines Korrekturfaktors berücksichtigt, dessen Ausgestaltung von der Art des Informationskriteriums abhängt. Neben der gewichteten Parameterzahl findet auch der (logarithmierte) Stichprobenumfang oder die geschätzte Fisher'sche Informationsmatrix bei einigen Kriterien Berücksichtigung.

Im Laufe der letzten Jahrzehnte wurde eine Vielzahl solcher Kriterien entwickelt. Aufgrund der unterschiedlichen Ausgestaltung des Korrekturfaktors weisen die Kriterien unterschiedliche statistische Eigenschaften und Eignungen zur Modellselektion auf. Um die Vorteilhaftigkeit der einzelnen Kriterien bei der Anwendung von Mischverteilungsmodellen zu untersuchen, wurden zahlreiche Simulationsstudien mit unterschiedlichen Modellprämissen initiiert. Der Fokus dieser Studien lag zunächst in der Evaluierung der Kriterien im Rahmen eines „klassischen“ Clustering-Ansatzes. Erst in den letzten Jahren hat sich der Fokus auf die Verknüpfungen des Mischverteilungsansatzes mit multivariaten Analysemethoden, wie beispielsweise Regressions- oder Logit-Modelle gerichtet. Die folgende Abbildung gibt einen Überblick über die Studien sowie deren Anwendungsgebiete hinsichtlich des eingesetzten Verfahrens:

Jahr	Autor(en)	Modell
1993	BOZDOGAN	Mixture Distribution
1993	CUTLER/WINDHAM	Mixture Distribution
1994	SOROMENHO	Mixture Distribution
1995	RUST ET AL.	Mixture Distribution
1996	CELEUX/SOROMENHO	Mixture Distribution
2000	McLACHLAN/NG	Mixture Distribution
2001	HAWKINS ET AL.	Mixture Regression
2003a	ANDREWS/CURRIM	Mixture Logit
2003b	ANDREWS/CURRIM	Mixture Regression
2006	BRAME ET AL.	Mixture Distribution
2006	NYLUND ET AL.	Growth Mixture
2006	OLIVEIRA-BROCHADO/MARTINS	Mixture Regression
2006	SARSTEDT	Mixture Regression
2006	YANG	Mixture Distribution
2007	TOFIGHI/ENDERS	Growth Mixture

Tabelle 1: Studien zur Modellselektion in Mischverteilungsmodellen

Bislang wurde keine Untersuchung für den FIMIX-PLS Ansatz oder vergleichbare „Finite Mixture“-Strukturgleichungsmodell-Ansätze initiiert.

Ziel dieses Beitrags ist es daher, im Rahmen einer Simulationsstudie herauszuarbeiten, welches Informationskriterium für die Modellselektion in FIMIX-PLS besonders geeignet ist. Dabei gilt es vor allem zu untersuchen, unter welchen Bedingungen welches Kriterium bessere Ergebnisse liefert als die Übrigen.

Hierbei werden zum einen die „klassischen“ Informationskriterien berücksichtigt, welche regelmäßig zur Modellselektion in Marketinganwendungen herangezogen werden (SARSTEDT 2006, S. 8). Zu dieser Gruppe sind die folgenden Kriterien zu zählen:

- Akaike's Information Criterion (AIC) (AKAIKE 1973)
- Bayesian Information Criteria (BIC) (SCHWARZ 1978)
- Consistent AIC (CAIC) (BOZDOGAN 1987)
- Modified AIC (AIC_3) (BOZDOGAN 1992)

Zum anderen werden die folgenden alternativen Informationskriterien herangezogen, die vor allem in der statistischen Literatur diskutiert werden:

- Minimum Description Length mit Faktor zwei bzw. fünf (MDL_2 , MDL_5) (LIANG 1992)
- Hannan-Quinn-Criterion (HQ) (HANNAN/QUINN 1979, S. 190 f.)
- Normalized Entropy Criterion (NEC) (CELEUX/SOROMENHO 1996)
- Classified Likelihood Criterion (CLC) (BIERNACKI/GOVAERT 1997)
- Integrated Completed Likelihood-BIC (ICL-BIC) (BIERNACKI ET AL. 2000)

Für eine Darstellung der Herleitung, Form und statistischen Eigenschaften der Kriterien sei auf die angeführten Quellen verwiesen.

2. Design der Simulationsstudie

Für die Spezifizierung des zu untersuchenden Modells werden insgesamt sieben Faktoren manipuliert. Die ersten sechs Faktoren und deren Ausprägungen orientieren sich dabei an den Studien von VRIENS ET AL. (1996, S. 77), ANDREWS ET AL. (2002, S. 480) und ANDREWS/CURRIM (2003a, S. 238). Faktor sieben wurde vor dem Hintergrund der in der Marketingforschung intensiv geführten Diskussion um die korrekte Spezifikation von Konstrukten einbezogen (vgl. BOLLEN/LENNOX 1991, DIAMANTOPOULOS/WINKLHOFER 2001, EBERL 2006b, ROSSITER 2002).

Faktor 1: Anzahl der Segmente: 2 oder 3

Faktor 2: Anzahl der Beobachtungen: 50, 100 oder 300

Faktor 3: Abstand der Pfadkoeffizienten γ : 0,2 oder 0,8

Faktor 4: Größe des kleinsten Segments: 15% oder 30%

Faktor 5 Varianz des Messfehlers der Indikatoren δ und ϵ bzw. der latenten exogenen Variablen ζ : 0,5 oder 1

Faktor 6: Modellkomplexität: *niedrig* oder *hoch*

Faktor 7: Messmodell der latenten exogenen Variablen: *reflektiv* oder *formativ*

Für jede mögliche Kombination der Faktorstufen werden Datensätze generiert. Da sechs Faktoren mit je zwei Faktorstufen, sowie ein Faktor mit drei Faktorstufen vorliegen, ergeben sich daraus $2^6 \cdot 3^1 = 192$ mögliche Faktorstufenkombinationen.

Es werden zwei verschiedene Modelle verwendet, wovon eines komplexer ist (27 manifeste Variablen (MV), 6 latente Variablen (LV)) als das andere (12 MV, 4 LV). In Ab-

hängigkeit der in Faktor 6 ausgedrückten Modellkomplexität variiert die Anzahl der freien Parameter des Modells. Die folgenden Abbildungen und Tabellen zeigen die Pfadmodelle der Simulationsstudie und deren Regressionsgleichungen in Matrixschreibweise.

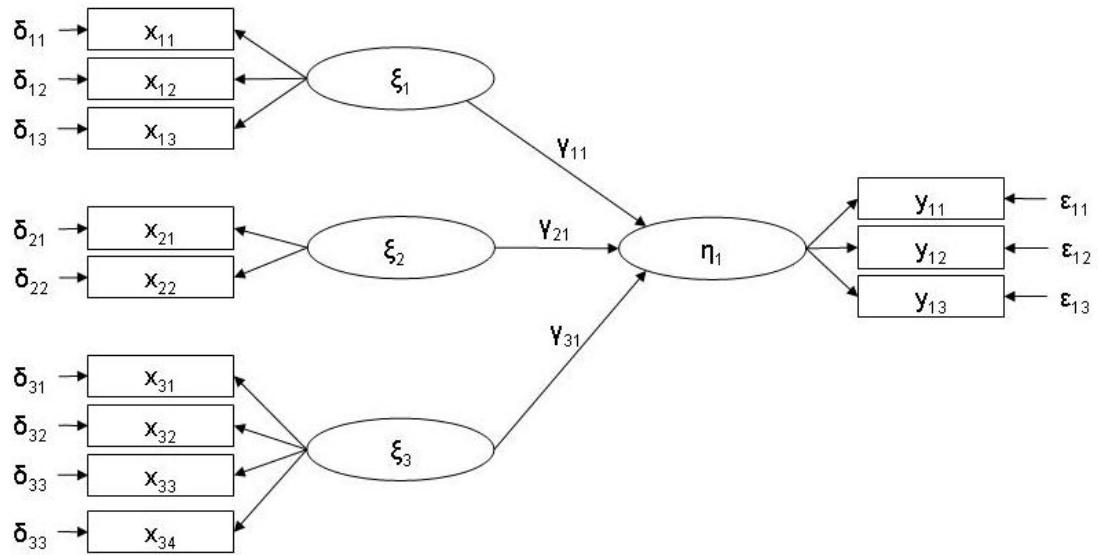


Abbildung 1: Einfaches Pfadmodell der Simulationsstudie: reflektive Modellspezifikation

Messmodell:					Strukturmodell:				
x_{11}	0,75	0	0	0	δ_{11}				
x_{12}	0,49	0	0	0	δ_{12}				
x_{13}	0,56	0	0	0	δ_{13}				
x_{21}	0	0,53	0	0	δ_{21}				
x_{22}	0	0,66	0	0	δ_{22}				
x_{31}	0	0	0,74	0	δ_{31}				
x_{32}	0	0	0,85	0	δ_{32}				
x_{33}	0	0	0,79	0	δ_{33}				
x_{34}	0	0	0,69	0	δ_{34}				
y_{11}	0	0	0	0,58	ϵ_{11}				
y_{12}	0	0	0	0,82	ϵ_{12}				
y_{13}	0	0	0	0,71	ϵ_{13}				
$=$					ξ_1	ξ_2	ξ_3	η_1	γ_{11}
					ξ_1	ξ_2	ξ_3	η_1	γ_{21}
					ξ_1	ξ_2	ξ_3	η_1	γ_{31}

Tabelle 2: Gleichungen des einfachen Pfadmodells in Matrixschreibweise: reflektive Modellspezifikation

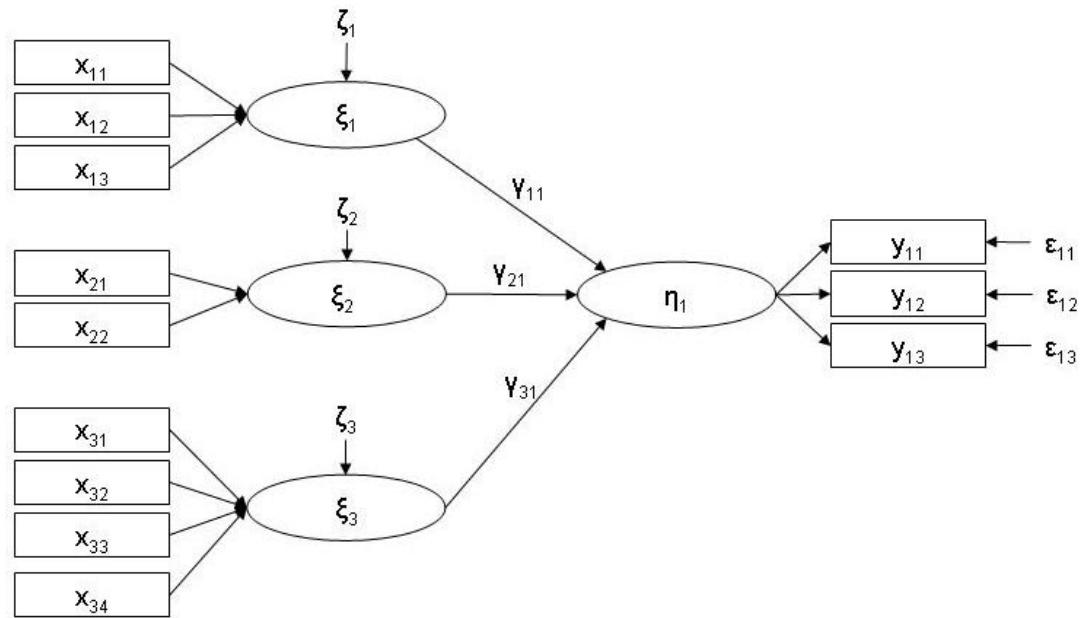


Abbildung 2: Einfaches Pfadmodell der Simulationsstudie: formative Modellspezifikation

Messmodell:

$$\begin{array}{c|cccccccccccc|c|c|c|c} \xi_1 & 0,75 & 0,49 & 0,56 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & \left| \begin{array}{c} x_{11} \\ x_{12} \\ x_{13} \end{array} \right. \\ \xi_2 & 0 & 0 & 0 & 0,53 & 0,66 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & \left| \begin{array}{c} x_{21} \\ x_{22} \\ x_{23} \end{array} \right. \\ \xi_3 & 0 & 0 & 0 & 0 & 0 & 0,74 & 0,85 & 0,79 & 0,69 & 0 & 0 & 0 & 0 & \left| \begin{array}{c} x_{31} \\ x_{32} \\ x_{33} \\ x_{34} \end{array} \right. \\ y_{11} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0,58 & 0 & 0 & 0 & \left| \begin{array}{c} \zeta_1 \\ \zeta_2 \\ \zeta_3 \end{array} \right. \\ y_{12} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0,82 & 0 & 0 & \left| \begin{array}{c} \varepsilon_{11} \\ \varepsilon_{12} \\ \varepsilon_{13} \end{array} \right. \\ y_{13} & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0,71 & 0 & \left| \begin{array}{c} \eta_1 \\ \eta_1 \\ \eta_1 \end{array} \right. \\ \hline \end{array} = \begin{array}{c} * \\ + \end{array}$$

Strukturmodell:

$$\begin{vmatrix} \eta_1 \end{vmatrix} = \begin{vmatrix} \xi_1 & \xi_2 & \xi_3 \end{vmatrix} * \begin{vmatrix} \gamma_{11} \\ \gamma_{21} \\ \gamma_{31} \end{vmatrix}$$

Tabelle 3: Gleichungen des einfachen Pfadmodells in Matrixschreibweise: formative Modellspezifikation

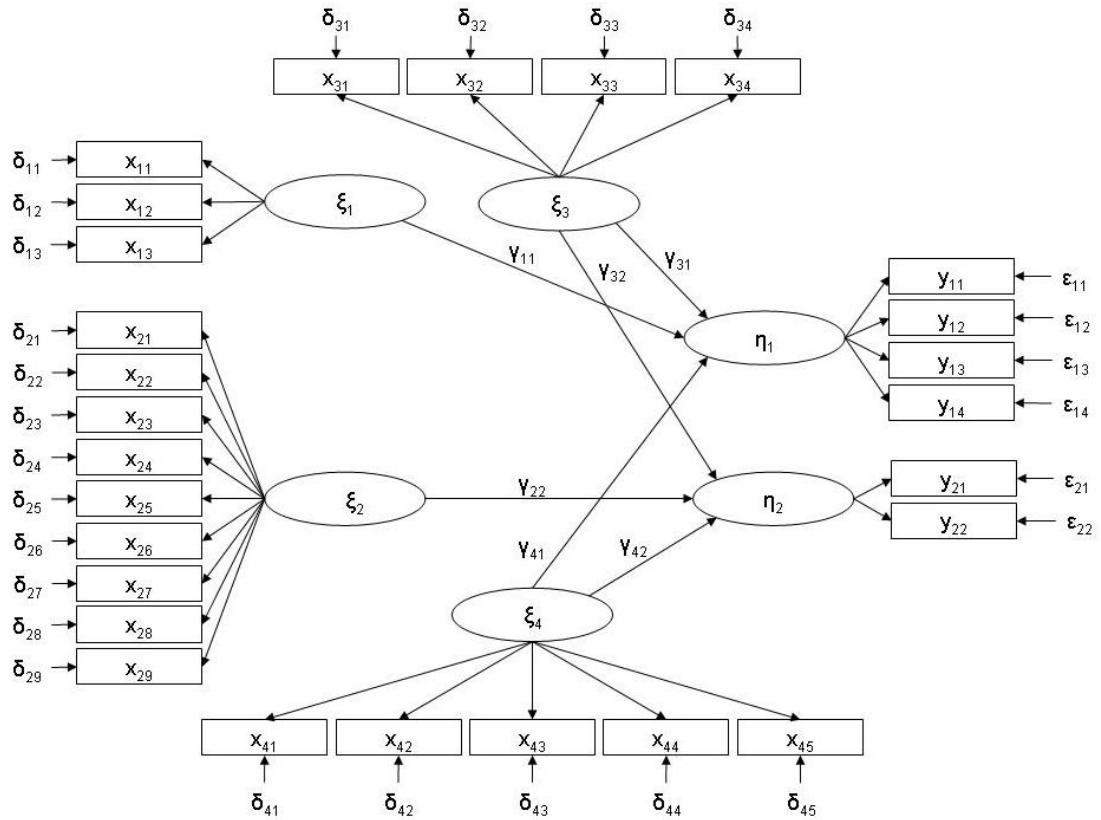


Abbildung 3: Komplexes Pfadmodell der Simulationsstudie: reflektive Modellspezifikation

Messmodell:							Strukturmodell:						
x_{11}	0,74	0	0	0	0	0	δ_{11}						
x_{12}	0,43	0	0	0	0	0	δ_{12}						
x_{13}	0,71	0	0	0	0	0	δ_{13}						
x_{21}	0	0,82	0	0	0	0	δ_{21}						
x_{22}	0	0,83	0	0	0	0	δ_{22}						
x_{23}	0	0,71	0	0	0	0	δ_{23}						
x_{24}	0	0,71	0	0	0	0	δ_{24}						
x_{25}	0	0,70	0	0	0	0	δ_{25}						
x_{26}	0	0,79	0	0	0	0	δ_{26}						
x_{27}	0	0,77	0	0	0	0	δ_{27}						
x_{28}	0	0,78	0	0	0	0	δ_{28}						
x_{29}	0	0,82	0	0	0	0	δ_{29}						
x_{31}	0	0	0,71	0	0	0	δ_{31}						
x_{32}	0	0	0,57	0	0	0	δ_{32}						
x_{33}	0	0	0,78	0	0	0	δ_{33}						
x_{34}	0	0	0,66	0	0	0	δ_{34}						
x_{41}	0	0	0	0,76	0	0	η_1						
x_{42}	0	0	0	0,68	0	0	η_2						
x_{43}	0	0	0	0,67	0	0	δ_{41}						
x_{44}	0	0	0	0,76	0	0	δ_{42}						
x_{45}	0	0	0	0,80	0	0	δ_{43}						
y_{11}	0	0	0	0	0,71	0	δ_{44}						
y_{12}	0	0	0	0	0,85	0	δ_{45}						
y_{13}	0	0	0	0	0,79	0	ϵ_{11}						
y_{14}	0	0	0	0	0,73	0	ϵ_{12}						
y_{21}	0	0	0	0	0	0,80	ϵ_{13}						
y_{22}	0	0	0	0	0	0,70	ϵ_{14}						
							ϵ_{21}						
							ϵ_{22}						

Tabelle 4: Gleichungen des komplexen Pfadmodells in Matrixschreibweise

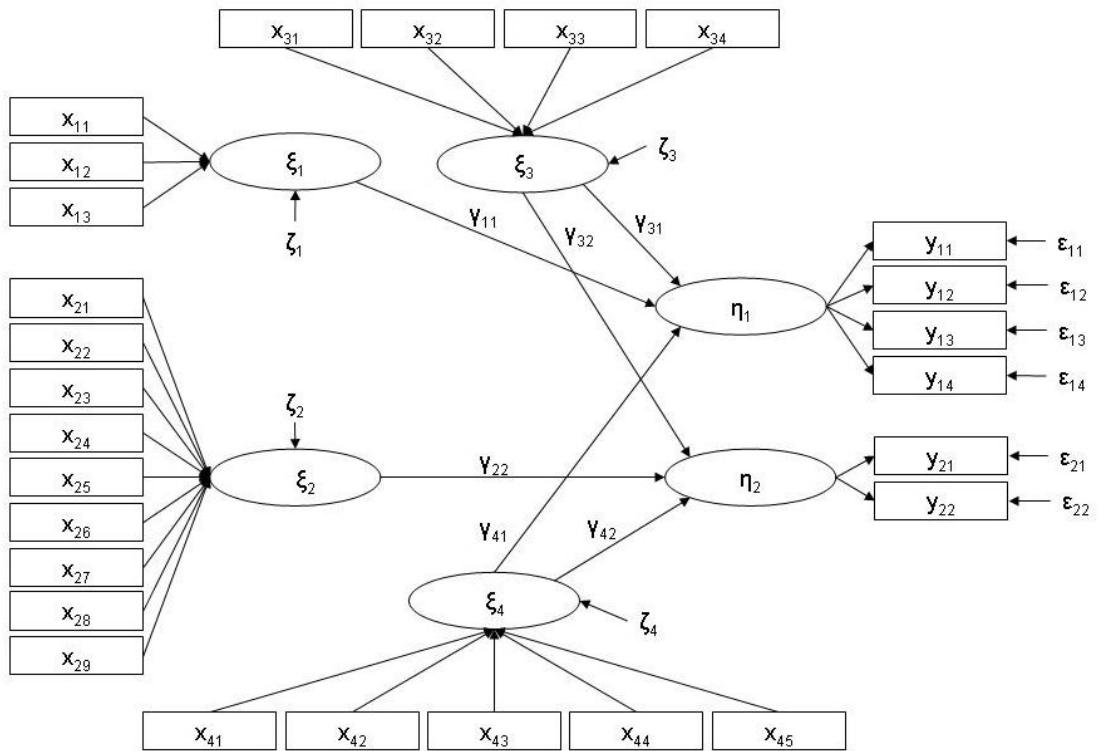


Abbildung 4: Komplexes Pfadmodell der Simulationsstudie: formative Modellspezifikation

Messmodell:

$$\begin{array}{c|c|c}
 \xi_1 & 0,74x_{11}+0,43x_{12}+0,71x_{13} & \zeta_1 \\
 \xi_2 & 0,82x_{21}+0,83x_{22}+0,71x_{23}+0,71x_{24}+0,70x_{25}+0,79x_{26}+0,77x_{27}+0,78x_{28}+0,82x_{29} & \zeta_2 \\
 \xi_3 & 0,71x_{31}+0,57x_{32}+0,78x_{33}+0,66x_{34} & \zeta_3 \\
 \xi_4 & 0,76x_{41}+0,68x_{42}+0,67x_{43}+0,76x_{44}+0,80x_{45} & \zeta_4 \\
 \hline
 y_{11} & 0,71\eta_1 & \varepsilon_{11} \\
 y_{12} & 0,85\eta_1 & \varepsilon_{12} \\
 y_{13} & 0,79\eta_1 & \varepsilon_{13} \\
 y_{14} & 0,73\eta_1 & \varepsilon_{14} \\
 y_{21} & 0,80\eta_2 & \varepsilon_{21} \\
 y_{22} & 0,70\eta_2 & \varepsilon_{22} \\
 \hline
 \end{array}$$

Strukturmodell:

$$\begin{array}{c|c}
 \eta_1 & = \begin{pmatrix} \gamma_{11} & 0 & \gamma_{31} & \gamma_{41} \\ 0 & \gamma_{22} & \gamma_{32} & \gamma_{42} \end{pmatrix} * \begin{pmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \\ \xi_4 \end{pmatrix} \\
 \eta_2 &
 \end{array}$$

Tabelle 5: Gleichungen des komplexen Pfadmodells in Matrixschreibweise

Die Pfadkoeffizienten der beiden Messmodelle wurden in Anlehnung an bereits durchgeführte PLS-Schätzungen festgelegt. Die Pfadkoeffizienten des Strukturmodells für das kleinste Segment mit 15% oder 30% Anteil am Datensatz (Faktor 4)³ wurden zufällig erzeugt. Die Pfadkoeffizienten des oder der anderen Segmente (Faktor 1) sind Abweichungen davon um 0,2 oder 0,8 (Faktor 3). In welche Richtung diese Abweichung geschieht, wurde ebenfalls zufällig entschieden, wobei sichergestellt wurde, dass die Ausprägungen der Pfadkoeffizienten stets im Intervall [-1;1] liegen. Zudem wurde die Anzahl der Beobachtungen über drei Stufen mit den Ausprägungen 50, 100 und 300 variiert (Faktor 2). Durch die Einbeziehung niedriger Stichprobenumfänge sollte dem häufig zitierten Vorteil von PLS-Schätzungen, auch bei Vorliegen niedriger Beobachtungszahlen eine hohe Ergebnisqualität zu liefern, Rechnung getragen werden (vgl. HOMBURG/KLARMANN 2006, S. 733 f.).

Im Falle einer reflektiven Spezifikation des Messmodells der latent exogenen Variablen (Faktor 7), wurden zunächst die Ausprägungen der latent exogenen Variablen auf Grundlage einer Normalverteilung bestimmt. Die Werte der Indikatoren des Messmodells der latenten exogenen Variablen x_i von Individuum i setzen sich aus dem Wert der betreffenden latenten exogenen Variablen, multipliziert mit den Pfadkoeffizienten des Messmodells sowie einem normalverteilten Fehlerterm mit Varianz 0,5 oder 1 (Faktor 5) zusammen. Analog hierzu setzen sich die Werte der latenten endogenen Variablen aus der mit den Pfadkoeffizienten des Strukturmodells gewichteten Summe der Ausprägungen der latenten exogenen Variablen zusammen. Hieraus erfolgt die Berechnung der Ausprägungen der Indikatorvariablen y_i innerhalb des Messmodells der latent endogenen Variablen.

Bei Vorliegen einer formativen Modellspezifikation wurden zunächst die Indikatorwerte des Messmodells der latenten exogenen Variablen auf Grundlage einer Normalverteilung bestimmt und nachfolgend die Ausprägungen der latenten exogenen Variablen durch eine Linearkombination der zugehörigen Items bestimmt. Da bei einer formativen Modellspezifikation Fehlerterme nur auf Ebene der Latenten existieren (EBERL 2004, S.8), wurde auf die latenten exogenen Variablen ein normalverteilter Fehlerterm mit Varianz 0,5 oder 1 (Faktor 5) aufaddiert.⁴ Die Berechnung der Ausprägungen der latenten endogenen Variablen sowie der zugehörigen Indikatoren erfolgte analog zum reflektiven Modell.

³ Bei drei Segmenten sind die anderen beiden Segmente jeweils gleich groß, also entweder 42,5% oder 35%.

⁴ Ebenso wie im reflektiven Messmodell wurde der Fehlerterm der latenten endogenen Variablen auf Null gesetzt.

2.1. Modellschätzung

Die Modellberechnung erfolgte mit Hilfe von *smartpls* (RINGLE ET AL. 2005), dem ersten grafischen Anwendungsprogramm zur Schätzung von Strukturgleichungsmodellen, das sowohl den einfachen PLS-, als auch den FIMIX-Algorithmus abbildet.

Die Modellschätzung erfolgte für jeden Datensatz für $s = 1, \dots, 4$ Segmente. Um eine frühzeitige Konvergenz zu verhindern, wurde der FIMIX-Algorithmus erst dann abgebrochen, wenn entweder die Verbesserung ε des $\ln(L)$ unter dem Schwellenwert 0,001 lag oder die Maximalzahl von 1.000 Iterationen erreicht wurde. Fast ausschließlich wurde dabei das Maximum an Iterationen unterschritten, meist führte das ε - Kriterium zum Abbruch.

Aufgrund der Abhängigkeit des mit dem EM-Algorithmus gefundenen Optimums von der Startpartition wurde der Algorithmus entsprechend der Empfehlung von WU (1983, S. 102) mit einer von der geschätzten Segmentzahl abhängigen Anzahl von Replikationen durchlaufen. Für die Segmentzahlen $s = 2; 3$ wurden acht Replikationen, für die Segmentzahl $s = 4$ aufgrund der größeren Streuung des $\ln(L)$ zehn Replikationen gewählt. Der Beste dieser acht bzw. zehn $\ln(L)$ -Werte wurde übernommen. Aus diesen $\ln(L)$ -Werten wurden im Weiteren die Werte der Informationskriterien AIC, AIC₃, BIC, CAIC, MDL₂, MDL₅, HQ, NEC, CLC und ICL-BIC errechnet.

Die zur Berechnung der Informationskriterien benötigte Anzahl der freien Parameter k im FIMIX-PLS-Ansatz ergibt sich aus (HAHN ET AL. 2002, S. 254):

$$k = (K - 1) + K \cdot R + K \cdot Q \quad (1)$$

mit: K = Aktuelle Anzahl der Klassen

R = Anzahl der Prädiktorvariablen in den Regressionen des Strukturmodells

Q = Anzahl der endogenen Variablen

Daraus ergeben sich für die beiden Modelle folgende k :

		Anzahl der Klassen K				
		1	2	3	4	5
Einfaches Modell		4	9	14	19	24
Komplexes Modell		8	17	26	35	44

Tabelle 6: Anzahl der freien Parameter

2.2. Bewertung der Schätzer

Für jede Faktorstufe wird berechnet, in wie viel Prozent der Fälle ein Kriterium erfolgreich war bzw. unter- oder überschätzt hat. Die Performanz der Segmentierungskriterien wird anhand der Trefferquote gemessen. Bei der endgültigen Bewertung der Kriterien wird ein Unterschätzen der wahren Segmentzahl gegenüber einem Überschätzen bevorzugt. Grund dafür ist, dass die geschätzten Parameter beim Überschätzen größere Fehler aufweisen als beim Unterschätzen. Eine Erklärung dafür könnte sein, dass beim Überschätzen zeitweise extrem kleine Segmente mit instabilen Parametern gebildet werden (ANDREWS/CURRIM 2003a, S. 239). Dies gilt insbesondere für kleine Datensätze sowie schlecht getrennte Segmente (CUTLER/WINDHAM 1993, S. 154).

Das Ergebnis der Simulationsstudie ist in Tabelle 7 dargestellt. Die Werte stellen die Mittelwerte der prozentualen Trefferquoten bzw. der Quoten von Unter- und Überschätzung einer jeden Faktorstufe über alle möglichen Ausprägungen aller Stufen der übrigen Faktoren dar.⁵

Die höchste Erfolgsrate mit 46% weist das CAIC auf, gefolgt von BIC und ICL-BIC mit über 40% und AIC₃, MDL₂ sowie HQ mit Werten von 40%. Trefferquoten um die 30% und niedriger erzielen AIC und CLC. NEC und MDL₅ zeigen nur in knapp jedem fünften Fall das richtige Modell an und schneiden damit am schlechtesten ab.

Die beiden MDL-Kriterien weisen mit einer Underfittingquote von 74% (MDL₅) bzw. 54% (MDL₂) eine ausgeprägte Tendenz zum Unterschätzen der wahren Segmentzahl auf, gefolgt von den tendenziell ebenfalls stark unterschätzenden Kriterien CAIC und ICL-BIC mit jeweils knapp über 40%. Die geringsten Werte in diesem Bereich weisen die beiden Kriterien AIC und CLC auf.

Eine klare Tendenz zum Überschätzen der wahren Anzahl der Segmente weisen die drei Kriterien CLC, NEC und AIC mit Overfittingquoten von über 40% auf. Im Gegensatz hierzu resultiert die starke Overfitting-Tendenz der MDL-Kriterien in entsprechend geringen Overfittingquoten (MDL₂: 05% und MDL₅: 04%). Eine vergleichsweise geringe Tendenz zum Überschätzen weist zudem das Kriterium ICL-BIC auf (15%).

⁵ Aufgrund von Rundungen summieren sich nicht alle Werte auf 100 Prozent.

		AIC			AIC3			BIC			CAIC			MDL ₂			MDL ₅			HQ			NEC			CLC			ICL-BIC			Gesamt		
		U	F	O	U	F	O	U	F	O	U	F	O	U	F	O	U	F	O	U	F	O	U	F	O	U	F	O	U	F	O			
Faktor 1	2	30	41	29	34	46	19	41	46	13	44	47	09	52	43	05	68	28	04	34	47	19	00	31	69	27	32	42	45	44	10	37	41	22
	3	20	24	56	26	33	41	35	43	22	42	45	13	59	36	05	81	16	03	27	33	40	68	14	18	22	24	54	39	41	20	42	31	27
Faktor 2	50	16	25	59	25	31	44	33	36	31	42	38	20	61	28	11	84	09	07	21	31	48	36	25	39	13	15	73	37	34	30	37	27	36
	100	27	31	41	32	36	32	43	41	16	48	44	09	61	36	03	82	15	03	34	36	30	34	20	45	24	26	50	48	38	13	43	32	24
	300	32	41	27	34	52	14	38	57	05	39	57	04	45	55	01	57	42	01	37	53	10	31	23	46	36	44	20	41	55	03	39	48	13
Faktor 3	0,2	38	25	38	46	29	26	57	32	11	62	32	06	75	22	03	92	07	01	46	30	24	34	31	35	35	23	42	61	29	10	55	26	20
	0,8	13	40	47	15	51	34	19	57	24	24	60	16	36	57	07	57	37	06	15	51	35	33	15	52	14	33	54	23	56	20	25	46	30
Faktor 4	15%	22	38	40	28	44	28	33	48	18	40	48	11	52	43	05	72	23	05	28	45	27	32	19	48	21	32	46	38	47	16	37	39	24
	30%	28	28	45	32	35	32	43	41	17	46	44	10	59	36	05	77	21	03	33	35	32	35	26	39	27	24	49	47	38	15	43	33	25
Faktor 5	0,5	19	35	46	23	43	34	28	53	20	32	56	12	46	48	06	67	28	05	22	44	33	35	19	46	18	31	52	32	52	17	32	41	27
	1	31	30	39	38	37	26	48	36	15	54	36	10	65	31	04	81	16	03	39	36	26	32	27	41	31	26	44	53	33	14	47	31	22
Faktor 6	niedrig	40	28	32	45	30	25	51	32	17	53	34	13	63	33	04	82	17	02	44	32	24	32	27	41	41	26	34	55	31	15	51	29	21
	hoch	10	37	53	16	49	35	25	57	18	33	58	09	48	46	06	67	28	06	17	48	35	35	19	46	08	31	61	30	54	16	29	43	29
Faktor 7	reflektiv	16	34	49	19	45	35	27	52	22	29	55	16	41	52	08	61	32	07	20	46	34	36	16	48	13	27	60	28	51	21	29	41	30
	formativ	34	31	35	41	34	24	49	38	13	57	37	06	70	28	02	87	13	01	41	34	25	32	30	39	35	30	35	56	34	09	50	31	19
Gesamt		25	33	42	30	40	30	38	45	17	43	46	11	55	40	05	74	22	04	31	40	29	34	23	43	24	28	48	42	42	15	40	36	25

Tabelle 7: Treffer (F, fitting), Unterschätzung (U, underfitting) und Überschätzung (O, overfitting) der Informationskriterien in Abhängigkeit von den Faktorstufen in Prozent

Betrachtet man die Trefferquoten bezüglich der verschiedenen Faktorausprägungen, stellt man fest, dass die Trefferquote mit 41% im 2-Segmente-Fall höher war als im 3-Segmente Fall (31%) (Faktor 1). Während der Untersuchung hat sich gezeigt, dass insbesondere im komplexeren Modell bei wenigen Beobachtungen die wahre Segmentanzahl drei sehr oft überschätzt wird. Mit steigender Beobachtungszahl wird der wahre Wert zunehmend häufiger getroffen. Im Falle von zwei Segmenten ist diese Tendenz zwar auch erkennbar, es wird aber auch bei wenigen Beobachtungen schon oft getroffen. Dieser Eindruck lässt sich auch in den Quoten von Faktor 2 ablesen. Mit zunehmender Anzahl von Beobachtungen erhöht sich die Trefferquote von 27% auf 48% zu Lasten der Overfittingquote, die von 36% auf 13% zurückgeht. Die Underfittingquote, die in den Faktorstufen um die 40% schwankt, scheint weitgehend unabhängig von der Anzahl der Beobachtungen zu sein.

Wenig überraschend ist auch das Ergebnis von Faktor 3. Während bei einem großen Segmentabstand in etwa der Hälfte der Fälle richtig gewählt wird, geschieht dies bei kleinem Abstand nur in 26% der Fälle. Es überrascht nicht, dass der große Abstand zur Überschätzung neigt (30%), da die so geschaffene größere „Ausdehnung“ der Daten dazu führt, dass zwischen den – entfernten – wahren Segmenten weitere Segmente identifiziert werden. Analog dazu wird bei kleinem Abstand oft unterschätzt (55%), weil die nah beisammen liegenden segmentspezifischen Verteilungen als eine Verteilung angesehen werden.

Die Größe des kleinsten Segmentes (Faktor 4) scheint hingegen kaum einen Einfluss auf die Bewertungsqualität der Informationskriterien zu haben. Treffer- (~36%), Under- (~40%) und Overfittingquote (~24%) liegen jeweils nahezu gleich auf. Normalerweise wäre bei einem kleinen Segment ein Unterschätzen zu vermuten, da es aufgrund seiner geringen Größe nicht erkannt und in die anderen Segmente „eingegliedert“ wird.

Faktor 5 indessen bringt das erwartete Ergebnis. Ist die Fehlervarianz groß, können die Segmente nicht klar voneinander unterschieden werden, da sich die Werte zu sehr überlagern und somit häufig angenommen wird, dass sie einer Verteilung entstammen. Anstatt der richtigen Segmentanzahl (31%) wird wesentlich öfter eine zu kleine Segmentanzahl gewählt (47%). Bei einem geringen Fehler wird die wahre Anzahl an Segmenten häufig getroffen (41%). Kommt es zu einer Fehlschätzung, so resultiert diese eher in einer Unterschätzung (32%).

Die Ergebnisse bei Faktor 6 stehen im Zusammenhang mit der „Consistency at Large“, wonach eine latente Variable umso besser erklärt wird, je mehr erklärende Variablen ihr zur Verfügung stehen (WOLD 1982, S. 25). Entsprechend weist das komplexe Modell

mit 27 Indikatoren bessere Werte auf als das einfache Modell mit lediglich zwölf manifesten Variablen. Die Trefferquote des komplexen Modells liegt mit 43% über der des einfachen Modells (29%). Außerdem kann man erkennen, dass das Modell mit wenigen freien Parametern zur Unterschätzung (51%) tendiert.

Die Spezifikation des verwendeten Messmodells der latent exogenen Variablen (Faktor 7) hat einen deutlichen Einfluss auf die Performanz der Kriterien. Während im reflektiven Fall eine Trefferquote von 41% erreicht wurde, liegt diese im formativen Fall lediglich bei 31%.

Vor dem Hintergrund der Simulationsergebnisse scheint das MDL_5 -Kriterium aufgrund der schlechtesten Trefferquote und der höchsten Underfittingquote ungeeignet zur Bestimmung der Segmentzahl. Ebenso erscheinen die Kriterien NEC und CLC aufgrund der niedrigen Trefferquoten und ausgeglichenen Under- und Overfittingquoten als wenig vorteilhaft.

Ein Vorteil der beiden MDL-Kriterien liegt im enorm kleinen Überschätzungsrisiko, das mit gerade einmal knapp 5% mit Abstand am geringsten ist. Im Gegensatz zu MDL_5 weist MDL_2 mit 40% eine vergleichsweise hohe Trefferquote auf, so dass dieses Kriterium von Nutzen ist, wenn eine Überschätzung unter allen Umständen vermieden werden soll.

Die beiden Kriterien AIC_3 und HQ weisen eine sehr ähnliche Performanz auf. Treffer-, Under- und Overfittingquoten unterscheiden sich unabhängig vom Faktor um höchstens vier Prozentpunkte. Da die Kriterien zwar hohe Gesamttrefferquoten aufweisen (40%), aber auch hohe Überschätzungsquoten (~30%), sind auch diese beiden Kriterien nicht vorteilhaft zur Bestimmung der richtigen Segmentanzahl.

Als nächstes bietet sich ein Vergleich der drei Kriterien BIC, CAIC und ICL-BIC an, die eine vergleichsweise hohe Trefferquote und relativ niedrige Overfittingquoten (< 20%) aufweisen. Doch vor allem durch die bessere Trefferquote bei kleinen Stichproben sowie der besten aller Gesamttrefferquoten (46%) ist das CAIC gegenüber den anderen Kriterien zu bevorzugen.

Doch welche Empfehlungen lassen sich daraus für die Praxis ableiten? Ein Problem ist, dass lediglich zwei der Faktoren durch den Anwender beeinflusst bzw. beobachtet werden können. Zum einen kann er die Stichprobengröße bestimmen und zum anderen kennt er die Komplexität des zugrunde liegenden Pfadmodells.

Hinsichtlich dieser beiden Faktoren ist ersichtlich, dass sowohl über die Faktorstufenkombinationen von Faktor 2 („Anzahl der Beobachtungen“) als auch Faktor 6 („Modellkomplexität“) das CAIC-Kriterium die höchsten Trefferquoten aufweist.

3. Fazit

Im Rahmen der durchgeführten Simulationsstudie konnte mit dem CAIC ein Kriterium identifiziert werden, das die übrigen Kriterien in nahezu allen Faktorstufenkombinationen dominiert. Als vorteilhaft erweist sich dieses Kriterium insbesondere auch bei der Verwendung von Modellen mit geringen Beobachtungszahlen sowie formativen Messmodellen, bei deren Schätzung der PLS-Ansatz als vorteilhaft angesehen wird bzw. eine Schätzung erst ermöglicht.

Die Studie ist damit sowohl aus forschungstheoretischer, als auch praktischer Sicht von Relevanz da die Ergebnisse dem Anwender eine konkrete Entscheidungshilfe bereitstellen. Hierdurch konnte die Anwendbarkeit des Ansatzes verbessert werden.

Gleichwohl muss festgehalten werden, dass die durchschnittliche Trefferquote mit 46%, sowie einem Minimum von 32% und einem Maximum von 57% über alle Faktorstufen eher schwach zu bewerten ist. Liegen dem Anwender a priori Informationen hinsichtlich konkurrierender bzw. zu erwartender Modelle vor, so kann je nach Einschätzung der jeweiligen Modellwahrscheinlichkeiten eine Abkehr von einer datengetriebenen Modellselektion sinnvoll sein.⁶

Weitere Forschungsarbeit wird sich auf die Analyse der Auswirkungen der verschiedenen Faktorstufen auf die Performanz der Kriterien konzentrieren. Durch die Durchführung einer binären logistischen Regression, deren abhängige Variable den Modellselektionserfolg abbildet, soll der Einfluss der Faktorstufen auf die Modellselektion mit Hilfe inferenzstatistischer Methoden genauer beleuchtet werden.

⁶ Für eine Darstellung der Verwendung von Chance Models zur Bewertung von Trefferquoten von Modellselektionskriterien bei Vorliegen von a priori Informationen, vgl. SARSTEDT (2006, S. 13 f.).

4. Literaturverzeichnis

AKAIKE, H. (1973): Information Theory and an Extension of the Maximum Likelihood Principle, in: KOTZ, S.; JOHNSON, N. L. [Hrsg.]: *Breakthroughs in Statistics 1*, Springer Verlag, New York 1992, S. 610-624.

ALBERS, S.; HILDEBRANDT, L. (2006): Methodische Probleme bei der Erfolgsfaktorenforschung – Messfehler, formative versus reflektive Indikatoren und die Wahl des Strukturgleichungs-Modells, in: *Zeitschrift für betriebswirtschaftliche Forschung*, Ausgabe 58, Februar 2006, S. 2-33.

ANDREWS, R.; CURRIM, I. (2003a): A Comparison of Segment Retention Criteria for Finite Mixture Logit Models, in: *Journal of Marketing Research*, Vol. 40, S. 235-243.

ANDREWS, R.; CURRIM, I. (2003b): Retention of Latent Segments in Regression-based Marketing Models, in: *International Journal of Research in Marketing*, Vol. 20, S. 315-321.

ANDREWS, R. L.; AINSLE, A.; CURRIM, I. S. (2002): An Empirical Comparison of Logit Choice Models with Discrete Versus Continuous Representations of Heterogeneity, in: *Journal of Marketing Research*, Vol. 39, November 2002, No. 4, S. 479-487.

BIERNACKI, C.; GOVAERT, G. (1997): Using the classification likelihood to choose the number of clusters, in: *Computing Science and Statistics*, Vol. 29, 1997, No. 2, S. 451-457.

BIERNACKI, C.; CELEUX, G.; GOVAERT, G. (2000): Assessing a Mixture Model for Clustering with the Integrated Completed Likelihood, in: *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 22, 2000, No. 7, S. 719-725.

BOLLEN, K. A.; LENNOX, R. (1991): Conventional Wisdom in Measurement: A Structural Equation Perspective, in: *Psychological Bulletin*, Vol. 110, No. 4, 1991, S. 375-384.

BOZDOGAN, H. (1987): Model selection and Akaike's Information Criterion (AIC): The general theory and its analytical extensions, in: *Psychometrika*, Vol. 52, 1987, No. 3, S. 345-370.

BOZDOGAN, H. (1992): Choosing the Number of Component Clusters in the Mixture-Model Using a New Informational Complexity Criterion of the Inverse-Fisher Information Matrix, in: OPITZ, O.; LAUSEN, B.; KLAR, R. [Hrsg.]: *Information and Classification: Concepts, Methods and Applications*, Springer Verlag, Berlin, Heidelberg 1993.

BOZDOGAN, H. (1993): Choosing the Number of Component Clusters in the Mixture-Model using a New Information Complexity Criterion of the Inverse-Fisher Information Matrix, in: OPITZ, O.; KLAR, R. [Hrsg.]: *Information and Classification*, Heidelberg, S. 40-54.

BRAME, R.; NAGIN, D. S.; WASSERMAN, L. (2006): Exploring Some Analytical Characteristics of Finite Mixture Models, in: *Journal of Quantitative Criminology*, Vol. 22, S. 31-59.

CELEUX, G.; SOROMENHO, G. (1996): An Entropy Criterion for Assessing the Number of Clusters in a Mixture Model, in: *Journal of Classification*, Vol. 13, 1996, S. 195-212.

CUTLER, A.; WINDHAM, M. P. (1993): Information-based Validity Functionals for Mixture Analysis, in: BOZDOGAN, H. [Hrsg.]: *Proceedings of the first US-Japan Conference on Frontiers of Statistical Modelling*, Amsterdam, S. 149-170.

DIAMANTOPOULOS, A.; WINKLHOFER, H. M. (2001): Index Construction with Formative Indicators: An Alternative to Scale Development, in: *Journal of Marketing Research*, Vol. 38, No. 2, S. 269-277.

EBERL, M. (2004): Formative und reflektive Indikatoren im Forschungsprozess: Entscheidungsregeln und die Dominanz des reflektiven Modells, in: *Schriften zur Empirischen Forschung und Quantitativen Unternehmensplanung*, Heft 19 / 2004.

EBERL, M. (2006a): Unternehmensreputation und Kaufverhalten. Methodische Aspekte komplexer Strukturmodelle, Wiesbaden 2006.

EBERL, M. (2006b): Formative und reflektive Konstrukte und die Wahl des Strukturgleichungsverfahrens. Eine statistische Entscheidungshilfe, in: *Die Betriebswirtschaft (DBW)*, 66. Jg., Heft 6, S. 651-668.

FASSOTT, G. (2005): Die PLS-Pfadmodellierung: Entwicklungsrichtungen, Möglichkeiten, Grenzen, in: BLIEMEL, F.; EGGERT, A.; FASSOTT, G.; HENSELER, J. [Hrsg.]: Handbuch PLS-Pfadmodellierung: Methode, Anwendung, Praxisbeispiele, Verlag Schäffer-Poeschel, Stuttgart 2005, S. 19-29.

HAHN, C. (2002): Segmentspezifische Kundenzufriedenheitsanalyse: Neue Ansätze zur Segmentierung von Märkten, Deutscher Universitäts-Verlag, Wiesbaden 2002.

HAHN, C.; JOHNSON, M.D.; HERRMANN, A.; HUBER, F. (2002): Capturing Customer Heterogeneity using a Finite Mixture PLS Approach, in: *Schmalenbach Business Review*, Vol. 54, Juli 2002, S. 243-269.

HAHN, C.; JOHNSON, M. D.; HERRMANN, A.; HUBER, F. (2005): Capturing Customer Heterogeneity using a Finite Mixture PLS Approach, in: BLIEMEL, F.; EGGERT, A.; FASSOTT, G.; HENSELER, J. [Hrsg.]: Handbuch PLS-Pfadmodellierung: Methode, Anwendung, Praxisbeispiele, Verlag Schäffer-Poeschel, Stuttgart 2005, S. 161-180.

HANNAN, E. J.; QUINN, B. G. (1979): The Determination of the Order of an Autoregression, in: *Journal of the Royal Statistical Society. Series B*, Vol. 41, S. 255-284.

HAWKINS, D. S.; ALLEN, D. M.; STROMBERG, A. J. (2001): Determining the Number of Components in Mixtures of Linear Models, in: *Computational Statistics & Data Analysis*, Vol. 38, S. 15-48.

HOMBURG, C.; KLARMANN, M. (2006): Die Kausalanalyse in der empirischen betriebswirtschaftlichen Forschung - Problemfelder und Anwendungsempfehlungen, in: *Die Betriebswirtschaft (DBW)*, 66. Jg., Heft 6, S. 727-748.

JEDIDI, K.; JAGPAL, H. S.; DESARBO, W. S. (1997a): Finite-Mixture Structural Equation Models for Response-Based Segmentation and Unobserved Heterogeneity, in: *Marketing Science*, Vol. 16, 1997, No.1, S. 39-59.

JEDIDI, K.; JAGPAL, H. S.; DESARBO, W. S. (1997b): STEMM: A General Finite Mixture Structural Equation Model, in: *Journal of Classification*, Vol. 14, 1997, S. 23-50.

LIANG, Z. (1992): Parameter estimation of finite mixture using the EM-Algorithm and information criteria with applications to medical image processing, in: *IEEE: Nuclear Science*, Vol. 39, 1992, No. 4, S. 11-26.

MCLACHLAN, G. J.; NG, S. K. (2000): A Comparison of some Information Criteria for the Number of Components in a Mixture Model, Technical Report, Brisbane Department of Mathematics, University of Queensland.

MCLACHLAN, G. J.; PEEL, D. (2000): Finite Mixture Models, John Wiley & Sons, New York et al. 2000.

NYLUND, K. L.; ASPAROUHOV, T.; MUTHÉN, B. O. (2006): Deciding on the Number of Classes in Latent Class Analysis and Growth Mixture Modeling: A Monte Carlo Simulation Study, *White Paper*, elektronisch veröffentlicht. [URL]:
http://www.statmodel.com/download/LCA_tech11_nylund_v83.pdf [Stand: 18. März 2007].

OLIVEIRA-BROCHADO, A.; MARTINS, F. V. (2006): Examining the Segment Retention Problem for the “Group Satellite” Case, *FEP Working Papers*, No. 220, elektronisch veröffentlicht. [URL]:
http://www.fep.up.pt/investigacao/workingpapers/06.07.04_WP220_brochadomartins.pdf [Stand: 18. März 2007].

RINGLE, C. M.; WENDE, S.; WILL, A. (2005): SmartPLS 2.0 (M3) beta:
www.smartpls.de.

RINGLE, C. M.; WENDE, S.; WILL, A. (2005): Customer segmentation with FIMIX-PLS, in: ALUJA, T.; CASANOVAS, J.; VINZI, V. E.; MORRINEAU, A.; TENENHAUS, M. [Hrsg.]: *Proceedings of the 4th International Symposium on PLS and Related Methods*, Decisia, Paris, S. 507-514.

RINGLE, C. M. (2006): Segmentation for Path models and Unobserved Heterogeneity: The Finite Mixture Partial Least Squares Approach, *Research Papers on Marketing and Retailing*, No. 35, elektronisch veröffentlicht [URL]: <http://www.ibl-unihh.de/RP035.pdf> [Stand: 18. März 2007].

RINGLE, C. M.; WENDE, S.; WILL, A. (2007): The finite mixture partial least squares approach, in: VINZI, V. E.; CHIN, W. W.; HENSELER, J.; WANG, H. [Hrsg.]: *Handbook of Partial Least Squares: Concepts, Methods and Applications in Marketing and Related Fields*, SPRINGER, Berlin et al., erscheint demnächst.

ROSSITER, J. R. (2002): The C-OAR-SE Procedure for Scale Development in Marketing, in: *International Journal of Research in Marketing*, Vol. 19, No. 4, 2002, S. 305-335.

RUST, R. T.; SIMESTER, D.; BRODIE, R. J.; NILIKANT, V. (1995): Model Selection Criteria: An Investigation of Relative Accuracy, Posterior Probabilities and Combinations of Criteria, in: *Management Science*, Vol. 41, No. 2, S. 322-333.

SARSTEDT, M. (2006): Sample- and Segment-size specific Model Selection in Mixture Regression Analysis. A Monte Carlo Simulation study, in: *LMU Discussion Papers*, 2006-08, elektronisch veröffentlicht. [URL]: http://epub.ub.uni-muenchen.de/archive/0001252/01/2006_08_ÖMU_sarstedt.pdf [Stand: 18. März 2007].

SOROMENHO, G. (1994): Comparing Approaches for Testing the Number of Components in a Finite Mixture Model, in: *Computational Statistics*, Vol. 9, S. 65-78.

TOFIGHI, D.; ENDERS, C. K. (2007): Identifying the Correct Number of Classes in Growth Mixture Models, in: HANCOCK, G. R.; SAMUELSON, K. M. [Hrsg.]: *Advances in Latent Variable Mixture Models*, Greenwich, im Druck.

VRIENS, M.; WEDEL, M.; WILMS, T. (1996): Metric Conjoint Segmentation Methods: A Monte Carlo Comparison, in: *Journal of Marketing Research*, Vol. 33, Februar 1996, No. 1, S. 73-85.

WEDEL, M.; KAMAKURA, W. A. (2000): Market Segmentation: Conceptual and Methodological Foundations, Kluwer Academic Publishers, 2. Auflage, Boston et al. 2000.

WOLD, H. (1982): Soft Modeling: The Basic Design and Some Extensions, in: JÖRESKOG, K. G.; WOLD, H. [Hrsg.]: Systems under indirect observation: Causality – Structure – Prediction, Part II, North-Holland Publishing, Amsterdam et al. 1982, S. 1-54.

YANG, C. (2006): Evaluating Latent Class Analysis in Qualitative Phenotype Identification, in: *Computational Statistics & Data Analysis*, Vol. 50, S. 1090-1104.