



**AgEcon** SEARCH  
RESEARCH IN AGRICULTURAL & APPLIED ECONOMICS

*The World's Largest Open Access Agricultural & Applied Economics Digital Library*

**This document is discoverable and free to researchers across the globe due to the work of AgEcon Search.**

**Help ensure our sustainability.**

Give to AgEcon Search

AgEcon Search

<http://ageconsearch.umn.edu>

[aesearch@umn.edu](mailto:aesearch@umn.edu)

*Papers downloaded from **AgEcon Search** may be used for non-commercial purposes and personal study only. No other use, including posting to another Internet site, is permitted without permission from the copyright owner (not AgEcon Search), or as allowed under the provisions of Fair Use, U.S. Copyright Act, Title 17 U.S.C.*

---

Hartl, J.: Consumer Perception and Decision Behaviour Presentation of a Theoretical Model for Future Research. In: Bahrs, E., von Cramon-Taubadel, S., Spiller, A., Theuvsen, L., Zeller, M.: Unternehmen im Agrarbereich vor neuen Herausforderungen. Schriften der Gesellschaft für Wirtschafts- und Sozialwissenschaften des Landbaues e.V., Band 41, Münster-Hiltrup: Landwirtschaftsverlag (2006), S. 109-119.

---



## CONSUMER PERCEPTION AND DECISION BEHAVIOUR PRESENTATION OF A THEORETICAL MODEL FOR FUTURE RESEARCH

*Jochen Hartl*<sup>\*</sup>

### **Verbraucherwahrnehmung und Entscheidungsverhalten Präsentation eines theoretischen Modells für zukünftige Forschung**

#### **Zusammenfassung**

In der vorliegenden Arbeit wird ein ökonomisches Modell vorgestellt, mit dem Ziel den Means-End-Chain (MEC) Ansatz in die Discrete-Choice-Analyse zu integrieren. Im allgemeinen sind MEC-Daten aufgrund ihrer Komplexität schwierig in ökonomische Modelle zu verankern. Anhand von latenten Klassen könnten Verbraucher mit ähnlichen kognitiven Strukturen zu Segmenten zusammengefasst sowie der Einfluss solcher Segmente auf das Entscheidungsverhalten bestimmt werden. Aus Sicht des MEC-Theorie würde ein solcher Ansatz eine bisher fehlende Verbindung des MEC-Ansatzes mit dem Entscheidungsverhalten der Verbraucher herstellen. Aus Sicht der Discrete Choice Analyse würde ein solcher Ansatz eine bessere Identifikation und Interpretation latenter Klassen ermöglichen.

#### **Schlüsselwörter**

Entscheidungsverhalten, Heterogenität, Means-End-Chain Ansatz, Discrete Choice Analyse, Analyse latenter Klassen

### **Consumer Perception and Decision Behaviour Presentation of a Theoretical Model for Future Research**

#### **Abstract**

An economical model is presented that aims to integrate the means-end approach with the discrete choice analysis. In general means-end-data are difficult to integrate into economics models due to the complexity of these data. Therefore, a latent class approach is used to cluster consumers with similar cognitive structures into segments and to analyse the influence of these segments on the decision behaviour. From the perspective of the means-end theory, such a model would establish a so far missing link between means-end data and the decision behaviour of the consumers. From the perspective of the discrete choice analysis, such an approach would provide a better identification and interpretation of latent classes.

#### **Keywords**

Decision Behaviour, Heterogeneity, Means-End-Chain Approach, Discrete Choice Analysis, Latent Class Models

## **1 Einleitung**

Der Means-End-Chain (MEC) Ansatz, als eine Methode zur Identifizierung von werte- und nutzeninduzierten Verbrauchervünschen, hat sich sowohl in der akademischen als auch der praktischen Marktforschung fest etabliert. Das Anwendungsgebiet dieses Ansatzes hat sich

---

<sup>\*</sup> Jochen Hartl, Institut für Agrarpolitik und Marktforschung, Senckenbergstr. 3, 35390 Giessen, Jochen.Hartl@agrar.uni-giessen.de.

seit Mitte der 90er Jahre auch auf den Bereich der Agrar- und Ernährungswirtschaft erweitert, beispielsweise um den Beurteilungsprozess der Verbraucher von ökologisch erzeugten (ZANOLI und NASPETTI, 2002) oder genetisch veränderten Lebensmitteln (BREDAHL, 1999; GRUNERT et al., 2001) näher zu beleuchten. Der MEC-Ansatz liefert dabei ein differenziertes Bild der kognitiven Verbraucherstrukturen, das sich unmittelbar für kommunikationsstrategische Zwecke nutzen lässt.

Obwohl intuitiv sehr ansprechend, wurde in der Literatur die theoretische und methodische Fundierung des Ansatzes kritisch beleuchtet (GRUNERT et al., 1995; ROSSITER und PERCY, 2001). U.a. bietet der Ansatz zwar ein Modell der kognitiven Strukturen, jedoch keine Theorie, die diese Strukturen mit dem Entscheidungsverhalten der Verbraucher verbindet. GRUNERT et al. (1995) fördern daher, den MEC-Ansatz durch eine Formulierung des Outputs auf ein breiteres Fundament zu stellen.

Ziel der vorliegenden Arbeit ist es, erstmals den Einfluss kognitiver Strukturen auf das Entscheidungsverhalten der Verbraucher zu modellieren. Zu diesem Zweck wird ein theoretisches Modell entwickelt, das den MEC-Ansatz mit der Discrete-Choice-Analyse verbindet. Methodisch würde diese Integration über Modelle latenter Klassen erfolgen. Dabei werden MEC-Daten zusammen mit dem beobachteten Entscheidungsverhalten der Verbraucher zur Identifikation latenter Verbrauchersegmente verwendet. Spezifisch für die jeweilig identifizierten Segmente kann das Entscheidungsverhalten modelliert werden.

Der Ansatz würde (a) einige der bisherigen Limitationen des MEC-Ansatzes umgehen, insbesondere eine Verbindung des MEC-Ansatzes zum Entscheidungsverhalten herstellen, (b) eine wirkungsvolle Segmentierung der Verbraucher auf Basis sowohl der kognitiven Strukturen als auch des Entscheidungsverhaltens darstellen sowie (c) aus Sicht der Discrete Choice Analyse eine bessere Identifikation und Interpretation latenter Klassen ermöglichen.

Der Aufbau der Arbeit ist wie folgt. In Abschnitt zwei wird zunächst ein Überblick über die MEC-Theorie sowie neuere Entwicklungen der Datenerhebung und -auswertung gegeben. Abschnitt 3 wendet sich dann der Discrete Choice Analyse zu. Im Mittelpunkt der Betrachtung soll dabei die Modellierung unbeobachteter Heterogenität in Form latenter Klassen stehen. Ein theoretischer Ansatz, der den MEC-Ansatz in die Discrete Choice Analyse integriert, wird in Abschnitt 4 präsentiert. Schließlich zeigt Abschnitt fünf empirische Herausforderungen hinsichtlich der Daten sowie der Schätzung des postulierten Modells auf. Abschnitt sechs fasst die Ergebnisse zusammen und gibt einen Ausblick auf zukünftige Forschung.

## **2 Die Means-End-Chain Analyse**

### **2.1 Methodische Grundlagen<sup>1</sup>**

Eine zunehmend auch in der Agrar- und Ernährungswirtschaft verwendete Methode, um den Beurteilungsprozess von Verbrauchern zu analysieren, ist der Means-End-Chain (MEC) Ansatz. Grundgedanke dieses Ansatzes ist, dass Individuen eine Vorstellung über die Tauglichkeit eines Gutes (Mittel bzw. „mean“) zur Erfüllung eines bestimmten Wunsches (Ziel bzw. „end“) entwickeln (HERRMANN, 1996). Der MEC-Ansatz unterscheidet zwischen drei Abstraktionsebenen: den Produktattributen, den Konsequenzen und den Werthaltungen. Diese drei Ebenen sind nach dem MEC-Ansatzes kausal miteinander verbunden, d.h. Produktattribute werden anhand ihrer Konsequenzen eingeschätzt, diese wiederum anhand von Werthaltungen beurteilt. Konsequenzen und Werte können somit als zunehmend abstraktere Kaufmotive der Verbraucher verstanden werden (OLSON, 1989).

Auf individueller Ebene wird die kausale Verknüpfung der Abstraktionsebenen als Leiter (engl.: *ladder*) bezeichnet. Empirische Daten zur Konstruktion von Leitern werden in der Re-

---

1 Für eine detailliertere Darstellung der methodischen Grundlagen siehe z.B. Reynolds und Gutman (1988)

gel mit Hilfe von semi-strukturierten *Laddering*-Interviews erhoben. Von nachfragerelevanten Produktattributen ausgehend, wird dabei wiederholt gefragt: „*Warum ist dieses Attribut wichtig für Sie?*“ (BOTSCHEN und THELEN, 1998). Auf diese Weise erhobene Daten werden codiert und mit einer speziellen Software (*Laddermap*, *MECAnalyst*) ausgewertet. Dabei werden individuelle Leitern zu sogenannten Ketten (engl.: *chain*) aggregiert. Alle Kausalketten, deren Intensität einen bestimmten Cut-Off-Wert überschreiten, werden grafisch in einem Schaubild, der sogenannten *Hierarchical Value Map* (HVM), dargestellt. Diese illustriert die Häufigkeit der Nennung einzelner MEC-Elemente, aber auch die Stärke der Verknüpfung zwischen ihnen (REYNOLDS und GUTMAN, 1988).

## 2.2 Limitationen und Erweiterungen

Der MEC-Ansatz ist intuitiv sehr ansprechend. Jedoch wurde in der Literatur sowohl die methodische als auch theoretische Fundierung des Ansatzes kritisch beleuchtet (GRUNERT et al., 1995; ROSSITER und PERCY, 2001).

Auf methodischer Ebene wurden bestimmte Aspekte bei der Erhebung von Laddering-Daten, u.a. die qualitative Natur dieser Daten, bemängelt. Da Laddering-Interviews mit hohem Zeitaufwand und Kosten verbunden sind, ist es schwierig quantitativ ausreichende Stichproben zu erheben (GRUNERT et al., 1995; HOFSTEDE et al., 1998). Daneben wurde die relativ pragmatische Auswertungsmethodik kritisiert, die viele Ad-hoc-Lösungen bei der Festlegung eines geeigneten Cut-Off-Wertes sowie bei der Erstellung einer HVM bietet. Insbesondere wird bei der Erstellung einer HVM implizit angenommen, dass die zugrundeliegenden kognitiven Strukturen der Befragten homogen sind. Wenn heterogene Befragte in eine HVM integriert werden, kann dies jedoch zu verzerrten Ergebnissen führen (GRUNERT et al., 1995).

Auf theoretischer Ebene wurde kritisiert, dass der MEC-Ansatz nicht fest in bestehende kognitive Modelle eingebettet ist. Ferner bietet der Ansatz nur ein loses Modell der kognitiven Strukturen der Verbraucher, jedoch keine Theorie, die diese Strukturen mit dem Entscheidungsverhalten der Verbraucher verbindet (GRUNERT et al., 1995).

Der MEC-Ansatzes würde daher von folgenden Erweiterungen profitieren: (a) der Erhebung quantitativer MEC-Daten, (b) alternative Methoden der Datenauswertung, insbesondere der Modellierung von Heterogenität sowie (c) einer Formulierung des Outputs, d.h. der Verbindung von MEC-Daten mit dem Entscheidungsverhalten. Die verschiedenen Aspekte werden im Folgenden kurz diskutiert.

### 2.2.1 Quantitative Erhebung von MEC Daten

In der Literatur wurden bereits erste Ansätze entwickelt, um quantitativ MEC-Daten zu erheben. Dazu zählen insbesondere das Hard-Laddering sowie die Association Pattern Technique (APT).

Bei dem Hard-Laddering<sup>2</sup> müssen Befragte zunächst die drei wichtigsten Eigenschaften eines Produktes nennen und diese mit der für Sie wichtigsten Konsequenz und dem für Sie wichtigsten Wert zu einer Leiter vervollständigen (RUSSELL et al., 2004). Mit Hilfe einer beigelegten Anweisung kann die Methode auch in schriftlichen Befragungen verwendet werden.

Bei der APT-Methode<sup>3</sup> wird zwischen einer AC-Matrix (Attribut-Konsequenz Matrix) und einer CV-Matrix (Konsequenz-Wert Matrix) unterschieden. In der AC-Matrix werden a priori definierte Attribute und Konsequenzen in den entsprechenden Zeilen bzw. Spalten aufgelistet. Dadurch entsteht eine Tabelle mit allen möglichen Kombinationen zwischen Attributen und Konsequenzen. Analog dazu enthält die CV-Matrix alle möglichen Kombinationen zwischen Konsequenzen und Werten. Für jede Zeile in der AC-Matrix (CV-Matrix) geben die Be-

2 Für eine detailliertere Darstellung der Methode siehe z.B. Botschen und Thelen (1998).

3 Für eine detailliertere Darstellung der Methode siehe z.B. Hofstede et al. (1998).

fragten nun an, zu welchen Konsequenzen (zu welchen Werten) die Eigenschaft (Konsequenz) Ihrer Meinung nach führt (Hofstede et al., 1998).

### 2.2.2 Alternative Methoden der Datenauswertung und Segmentierung

Auf dem Gebiet der Datenauswertung waren es zum ersten mal VALETTE-FLORENCE und RAPACCHI (1991), welche die pragmatische Auswertungsmethodik der Software *Laddermap* bemängelten und die Auswertung von Laddering-Daten mittels der Graphentheorie und der Korrespondenzanalyse vorschlugen. Ein Nachteil deren Ansatzes ist, dass MEC-Elemente, jedoch nicht *Leitern*, als Basis der Analyse verwendet wurden. Damit liefert der Ansatz keine Information, wie die einzelnen Elemente innerhalb einer Gruppe verbunden sind.

AURIFELLE und VALETTE-FLORENCE (1995) schlagen eine alternative Methode auf Basis von Leitern vor. Ziel deren Ansatzes ist, dominante Ketten zu identifizieren, welche die individuellen Leitern am besten repräsentieren. Der Ansatz umgeht einige bisherige Ad-hoc-Lösungen, jedoch wurden immer noch potentiell heterogene kognitive Strukturen in eine HVM integriert.

HOFSTEDE (1999) verwendete erstmals das Rasch-Modell kombiniert mit dem Modell latenter Klassen, um MEC-Daten auszuwerten. Im Gegensatz zu bisherigen deterministischen handelt es sich dabei um einen stochastischen Ansatz. Der Ansatz erlaubt, Verbraucher mit ähnlichen kognitiven Strukturen zu Segmenten zusammenzufassen, d.h. er ermöglicht die Modellierung heterogener kognitiver Strukturen. So kann segmentspezifisch die Wahrscheinlichkeit bestimmt werden, dass eine bestimmte MEC-Verbindung auftritt.

### 2.2.3 Verbindung von MEC-Daten mit dem Entscheidungsverhalten

In der Literatur existieren bisher noch keine systematischen Ansätze, um den Einfluss von MEC-Daten auf das Verbraucherverhalten zu analysieren. Lediglich BAGOZZI und DABHOLKAR (1994) testeten mittels Regressionsanalyse Zusammenhänge zwischen dem Auftreten bestimmter MEC-Verbindungen und dem Verbraucherverhalten.

## 3 Die Discrete Choice Analyse

### 3.1 Methodische Grundlagen

Discrete Choice Modelle können mit Entscheidungssituationen umgehen, bei denen Wirtschaftssubjekte aus einer begrenzten Menge von Alternativen wählen. Das am meisten verbreitete Discrete Choice Modell ist das multinominale Logit (MNL) Modell, welches von McFADDEN (1974) in den siebziger Jahren entwickelt wurde. Die Beliebtheit des MNL-Modells liegt darin begründet, dass die Wahlwahrscheinlichkeiten der Alternativen eine geschlossene Form annehmen und daher relativ einfach zu schätzen und zu interpretieren sind.

Mathematisch kann das MNL-Modell wie folgt beschrieben werden. Angenommen, einem Entscheidungsträger stehen  $J$  Alternativen ( $i = 1, \dots, J$ ) zur Wahl. Der Nutzen, den Individuum  $q$  aus der Wahl der Alternative  $i$  zieht, kann nach der Zufallsnutzentheorie in eine deterministische Komponente  $V_{qi}$  und eine stochastische Komponente  $\varepsilon_{qi}$  zerlegt werden.  $V_{qi}$  ist eine Funktion des Vektors  $x_{qi}$  bestehend aus den Produktattributen sowie den individuellen Charakteristika (z.B. soziodemographische Charakteristika). Unter der Annahme einer linearen, additiven Form für  $V_{qi}$ , entspricht der Nutzen des Individuums  $q$  für die Alternative  $i$ :

$$U_q(i) = \lambda \beta x_{qi} + \varepsilon_{qi}, \quad (1)$$

wobei  $\lambda$  einen Skalierungs-Parameter und  $\beta$  den zu schätzenden Parameter-Vektor bezeichnet. Die Annahme, dass die stochastische Komponente  $\varepsilon_{qi}$  des Nutzens unabhängig identisch ex-

tremwertverteilt ist, führt zu folgender wohlbekannten Struktur der Wahlwahrscheinlichkeiten<sup>4</sup>:

$$P_q(i) = \frac{\exp(\lambda\beta x_{qi})}{\sum_j \exp(\lambda\beta x_{qj})}. \quad (2)$$

Dieses Modell ist einfach mittels des Maximum-Likelihood-Verfahrens zu schätzen, zeichnet sich aber auch durch eine Reihe von Limitationen und Annahmen aus. Dazu zählt - neben bestimmten Annahmen über die Substitutionsbeziehungen der Alternativen -, dass nur *beobachtete* Heterogenität der Entscheidungsträger abgebildet werden kann, d.h. Heterogenität die systematisch mit den erklärenden Variablen variiert<sup>5</sup>. In der Regel werden jedoch auch Entscheidungsträger, mit denselben beobachteten Charakteristika, aufgrund (a) unbeobachteter Entscheidungsregeln, (b) unbeobachteter Choice-Sets (Alternativen, die in die Entscheidungsfindung einbezogen werden) sowie (c) unbeobachteter Präferenzen (Wert  $\beta$ , der den Eigenschaften der Alternativen beigemessen wird), unterschiedliche Wahlentscheidungen treffen. Das MNL-Modell kann solche *unbeobachtete*, d.h. zufällige, Heterogenität der Entscheidungsträger nicht abbilden (CHESHER und SANTOS SILVA, 2002). Wenn unbeobachtete Heterogenität existiert, wäre das MNL-Modell folglich eine Fehlspezifikation (TRAIN, 2002).

### 3.2 Choice Modell latenter Klassen (LCCM)

Eine wesentliche Verbesserung von Discrete Choice Modellen zielt nun darauf ab, unbeobachtete *Präferenzen* der Verbraucher zu modellieren<sup>6</sup>. In der Literatur werden verschiedene Ansätze vorgeschlagen, um solche unbeobachtete Heterogenität abzubilden<sup>7</sup>. Ein weitverbreiteter Ansatz ist das Choice Modell latenter Klassen (engl.: *Latent Class Choice Modell, LCCM*). Das Prinzip von LCCM-Modellen kann anhand von Abbildung 1 verdeutlicht werden. Das LCCM-Modell setzt voraus, dass Daten hinsichtlich der Wahlindikatoren  $i$ , der individuellen Charakteristika  $S_q$  sowie der Eigenschaften der Alternativen  $Z_{qi}$  verfügbar sind. Ziel ist die *simultane* Identifizierung von diskreten Verbrauchersegmenten (d.h. latenten Klassen, die durch ähnliche Präferenzen charakterisiert sind), sowie die Erklärung des Wahlverhaltens für ein bestimmtes Segment (d.h. das Choice Modell ist für die jeweiligen Klassen unterschiedlich spezifiziert). Dabei kann, in Abhängigkeit der individuellen Charakteristika und Präferenzen, jedes Individuum stochastisch einer latenten Klasse zugeweiht werden.

<sup>4</sup> Für eine detaillierte Herleitung der Wahlwahrscheinlichkeiten siehe Train (2002).

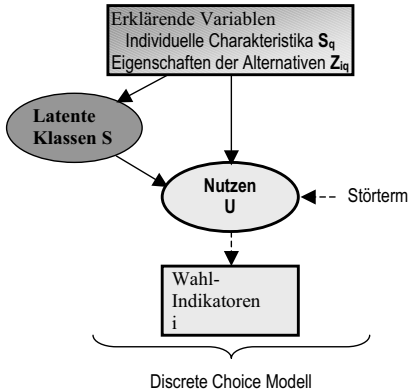
<sup>5</sup> Um beobachtete Heterogenität in MNL-Modelle zu integrieren, werden z.B. demographische Charakteristika in die deterministische Komponente der Nutzenfunktion aufgenommen. Beispielsweise könnte die Größe eines Autos wichtiger sein für Haushalte mit vielen Mitgliedern als für kleine Haushalte (Train, 2002).

<sup>6</sup> In der Literatur gibt es auch Ansätze, unbeobachtete Entscheidungsregeln sowie unbeobachtete Choice Sets zu modellieren, die an dieser Stelle aber nicht weiter vertieft werden sollen (Gopinath, 1995).

<sup>7</sup> Unbeobachtete Heterogenität kann entweder kontinuierlich in Form von Mixed Logit Modellen oder diskret in Form von Modellen latenter Klassen modelliert werden (Gopinath, 1995).



**Abbildung 1: Latent Class Choice Model**



Quelle: Eigene Darstellung

Mathematisch kann das LCCM-Modell nun folgendermaßen dargestellt werden.  $W_q(s)$  bezeichnet die Wahrscheinlichkeit eines Individuums  $q$  einer Klasse  $s$  anzugehören und  $P_q(i|s)$  die bedingte Wahrscheinlichkeit, dass Individuum  $q$  die Alternative  $i$  wählt, wenn es der latenten Klasse  $s$  angehört. Die Wahrscheinlichkeit, dass ein Individuum  $q$  die Alternative  $i$  wählt, entspricht dann:

$$P_q(i) = \sum_{s=1}^S P_q(i|s) \cdot W_q(s), \quad (3)$$

wobei  $S$  der Anzahl der latenten Klassen entspricht.

Je nach Annahmen und Komplexität gibt es verschiedene Möglichkeiten  $P_q(i|s)$  und  $W_q(s)$  zu spezifizieren. Im Folgenden wird eine einfache logistische Spezifikation gewählt, jedoch sind generell auch komplexere Spezifikationen denkbar<sup>8</sup>.

Die Nutzenfunktion für ein Individuum  $q$ , das der Klasse  $s$  angehört, kann analog zu Gleichung 1 wie folgt formuliert werden:

$$U_q(i) = \lambda_s \beta_s x_{qi} + \varepsilon_q(i|s), \quad (4)$$

wobei  $\lambda_s$  einen Skalierungs-Parameter und  $\beta_s$  den Parameter-Vektor jeweils in Abhängigkeit der latenten Klasse  $s$  darstellen. Unter der Annahme, dass die unbeobachtete Komponente  $\varepsilon_q(i|s)$  in Gleichung (4) unabhängig identisch extremwertverteilt ist, ergibt sich für  $P_q(i|s)$  analog zu Gleichung (2),

$$P_q(i|s) = \frac{\exp(\lambda_s \beta_s x_{qi})}{\sum_j \exp(\lambda_s \beta_s x_{qj})}. \quad (5)$$

Daneben muss noch  $W_q(s)$  spezifiziert werden. Die Wahrscheinlichkeit, dass Individuum  $q$  zur Klasse  $s$  gehört, kann in Abhängigkeit der individuellen Charakteristika  $S_q$  modelliert werden. In der Form ähnlich wie Gleichung (5) ergibt sich (WEDEL und KAMAKURA, 2000):

$$W_q(s) = \frac{\exp(\mu \alpha_s S_q)}{\sum_{k=1}^S \exp(\mu \alpha_k S_q)}, \quad (6)$$

<sup>8</sup> Für einen Überblick siehe z.B. Ben-Akiva et al. (1997)

wobei  $\mu$  einen Skalierungs-Parameter,  $\alpha_s$  den zu schätzenden Parameter-Vektor und  $S_q$  die individuellen Charakteristika bezeichnet.

Setzt man Gleichung (5) und (6) in Gleichung (3) ein, so erhält man:

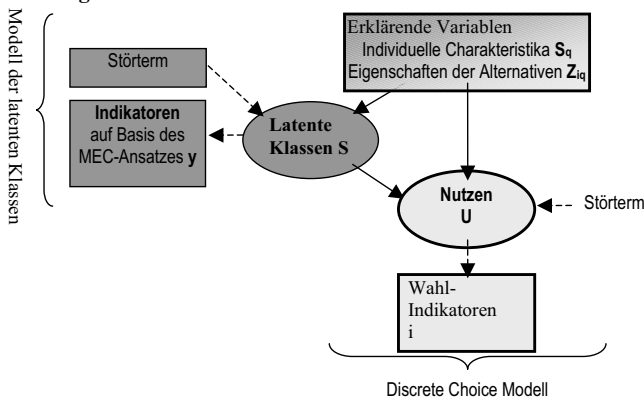
$$P_q(i) = \frac{\sum_{s=1}^S \exp(\lambda_s \beta_s x_{qi}) \cdot \exp(\mu \alpha_s S_q)}{\sum_j \exp(\lambda_s \beta_s x_{qj}) \cdot \sum_{k=1}^S \exp(\mu \alpha_k S_q)} \quad (7)$$

## 4 Integration der beiden Ansätze

### 4.1 Choice Modell latenter Klassen mit Indikatoren

Im LCCM-Modell wurden keine direkten Indikatoren verwendet, um die latenten Segmente zu identifizieren. Lediglich die Wahlindikatoren können als indirekte Indikatoren der latenten Segmente angesehen werden. Da der Informationsgehalt dieser Wahlindikatoren begrenzt ist, können Probleme bei der empirischen Identifikation latenter Segmente entstehen. In der vorliegenden Arbeit wird daher vorgeschlagen, zusätzlich MEC-Daten als direkte Indikatoren der latenten Klassen zu verwenden. Abbildung 2 soll diese Erweiterung verdeutlichen. So entspricht das postulierte Modell in seiner Grundstruktur dem LCCM-Modell, jedoch werden Indikatoren auf Basis des MEC-Ansatzes in das Modell eingeführt. Der obere Teil der Abbildung 2 entspricht einem Modell der latenten Klassen. Dabei sind die erklärenden Variablen kausal mit den latenten Klassen verbunden. Die latenten Klassen selbst sind dabei nicht beobachtbar, jedoch ihr Effekt auf die Indikatoren. Die Indikatoren ermöglichen somit die Identifikation der latenten Konstrukte. MEC-Daten scheinen dafür in hohem Maße geeignet, da mithilfe des MEC-Ansatzes kaufrelevante Attribute und deren Bedeutung für den Verbraucher erfasst werden. So spiegeln MEC-Daten die individuelle Sensibilität (Präferenz) der Verbraucher gegenüber bestimmten Produkteigenschaften wider. Der Modell setzt voraus, dass - neben den herkömmlichen Daten zur Schätzung des LCCM-Modells - noch quantitative MEC-Daten verfügbar sind.

Abbildung 2: Latent Class Choice Model mit Indikatoren



Quelle: Eigene Darstellung

Im generellen kann das LCCM-Modell mit Indikatoren durch folgende Gleichung beschrieben werden:

$$P_q(i, y) = \sum_{s=1}^S P_q(i|s) \cdot F_q(y|s) \cdot W_q(s) \quad (8)$$

Gleichung (8) wurde gegenüber Gleichung (3) um den Term  $F_q(y|s)$  erweitert.  $F_q(y|s)$  beschreibt dabei den Messzusammenhang zwischen den latenten Klassen und den Indikatoren, d.h. die Wahrscheinlichkeit, dass ein Individuum  $q$  der latenten Klasse  $s$  den Indikator  $y$  wählt. Dieser Zusammenhang muss noch spezifiziert werden, wobei HOFSTEDE (1999) einen möglichen Ansatz bietet: Angenommen es existieren  $l$  Verbindungen ( $l = 1, \dots, L$ ) zwischen den verschiedenen MEC-Elementen (Attributen und Konsequenzen bzw. Konsequenzen und Werte).  $y_l$  sei dann eine binäre Variable, die den Wert 1 annimmt, wenn ein Individuum die Verbindung  $l$  zwischen zwei MEC-Elementen angegeben hat, und ansonsten den Wert Null.  $u_l$  soll die Stärke einer Verbindung zwischen zwei MEC-Elementen angegeben,  $\theta_q$  die generelle Tendenz eines Individuums, eine Verbindung anzugeben.

Die Wahrscheinlichkeit, dass ein Indikator  $y_l$  gewählt wird, kann nach Hofstede (1999) unter Annahme einer logistischen Verteilung von  $u_l$  durch folgende Formel dargestellt werden<sup>9</sup>:

$$F_q(y|s) = \frac{\exp\left[\sum_{l=1}^L y_{ql}(u_{ls} - \theta_q)\right]}{\prod_{l=1}^L [1 + \exp(u_{ls} - \theta_q)]}. \quad (9)$$

Setzt man Gleichung (5), (6) und (9) in Gleichung (8) ein, so erhält man:

$$P_q(i, y) = \frac{\sum_{s=1}^S \exp(\lambda_s \beta_s x_{qi}) \cdot \exp\left[\sum_{l=1}^L y_{ql}(u_{ls} - \theta_q)\right] \cdot \exp(\mu \alpha_s S_q)}{\sum_{s=1}^S \sum_j \exp(\lambda_s \beta_s x_{qj}) \cdot \prod_{l=1}^L [1 + \exp(u_{ls} - \theta_q)] \cdot \sum_{k=1}^S \exp(\mu \alpha_k S_q)}. \quad (10)$$

Bei der Schätzung dieses Modells würde eine Analyst folgende Parameter erhalten:

- $\beta_s$ : Koeffizienten der erklärenden Variablen (Eigenschaften der Alternativen, individuelle Charakteristika) für die jeweiligen Klassen. Diese bestimmen den Einfluss der erklärenden Variablen auf die Wahlentscheidung.
- $\alpha_s$ : Koeffizienten der individuellen Charakteristika, welche die Zugehörigkeit der Befragten zu den jeweiligen Klassen beschreiben. Diese bestimmen den Einfluss individueller Charakteristika auf die Zugehörigkeit zu einer Klasse.
- $u_{ls}$ : Koeffizienten geben an für die jeweiligen Klassen an, mit welcher Wahrscheinlichkeit eine bestimmte MEC-Verbindung auftritt.

#### 4.2 Potentielle Vorteile des Ansatzes

Folgende potentiellen Vorteile würden für das postulierte Modell sprechen.

**Formulierung eines Outputs:** Eine Limitation bisheriger MEC-Forschung ist, dass die kognitiven Strukturen für sich genommen kein Verhalten erklären können (GRUNERT et al., 1995). Mit Hilfe des postulierten Ansatzes könnte getestet werden, inwiefern heterogene kognitive Strukturen der Verbraucher existieren und wie sich diese im Entscheidungsverhalten der Verbraucher niederschlagen. Bisherige sozialpsychologischen und ökonomischen Studien haben meistens untersucht, inwieweit Einstellungen als erklärende Variable das Kaufverhalten bestimmen. Die Theorie des vernünftigen Handelns und Theorie des geplanten Verhaltens spiegeln diesen Zusammenhang wider (AJZEN und FISHBEIN, 1980; COOK et al., 2002). MEC-Daten könnten in dem Zusammenhang überlegen sein, da sie konsumentenspezifische Einstellungen konkret in Bezug auf bestimmte Produkteigenschaften erfassen. So werden beim Konsumenten in verschiedenen Kaufsituationen sowie bei verschiedenen Produkteigenschaften

9 Für eine detailliertere Diskussion dieses Ansatzes siehe HOFSTEDE (1999).

andere Einstellungen (Konsequenzen, Werte) angesprochen (GRUNERT et al., 1995; LOUVIERE et al., 2001).

**Wirkungsvolle Segmentierung:** Auf Basis des postulierten Ansatzes könnten aussagekräftige Segmente gebildet werden. Gegenüber bisherigen Ansätzen würden die Segmente sowohl aus den MEC-Daten als auch aus dem beobachteten Wahlverhalten der Verbraucher abgeleitet. Die Vorteile einer Segmentierung auf Basis von MEC-Daten (HOFSTEDTE et al., 1999) würden somit mit den Vorteilen einer auf dem Verhalten basierenden Segmentierung gekoppelt.

- **Verbesserte Identifikation:** Der Informationsgehalt von den Wahlindikatoren allein mag nicht ausreichen, um latente Segmente im LCCM-Modell zu identifizieren. In dem Zusammenhang kann der zusätzliche Informationsgehalt der MEC-Indikatoren helfen, um solche empirischen Identifikations-Probleme zu lösen.

## 5 Empirische Herausforderungen

### 5.1 Datenerhebung

Das entwickelte Modell verlangt sowohl Daten für die Discrete-Choice-Analyse als auch quantitative MEC-Daten. Prinzipiell können in der Discrete-Choice-Analyse reale Marktdaten oder hypothetische Daten aus Choice Experimenten verwendet werden<sup>10</sup>. Quantitative MEC-Daten könnten hingegen mittels der in Abschnitt 0 vorgestellten Verfahren erhoben werden.

Im generellen steigen mit dem postulierten Modell die Anforderungen an die Befragten. Es muss daher empirisch geprüft werden, inwiefern Befragte durch die Datenerhebung ge- oder überfordert werden.

### 5.2 Schätzung des Modells

Eine weitere Herausforderung stellt die Schätzung des Modells dar. Prinzipiell ist das klassische Maximum-Likelihood-Verfahren denkbar. Zu befürchten ist, dass entsprechende Algorithmen aufgrund der Vielzahl der Parameter nicht notwendigerweise zu einem globalen Maximum führen. Eine Alternative stellt die Schätzung mittels neuerer Bayesianischer Verfahren dar (TRAIN, 2002).

Ein weiteres empirisches Problem ist die Festlegung einer geeigneten Anzahl von Klassen. In der Literatur werden in dem Zusammenhang meist verschiedene Maßzahlen verwendet. Dazu zählen das *Akaike Information Criterion (AIC)* sowie das *Bayesian Information Criterion*.

## 6 Zusammenfassung und weiteres Vorgehen

In der vorliegenden Arbeit wurde ein theoretisches Modell präsentiert, das den MEC-Ansatz in die Discrete-Choice-Analyse integriert. Hintergrund ist eine bisher fehlende Verbindung von MEC-Daten mit dem Entscheidungsverhalten der Verbraucher. So wird postuliert, MEC-Daten in Form latenter Klassen in Discrete Choice Modelle einfließen zu lassen. Auf diese Weise könnte die inhärente Komplexität dieser Daten reduziert und der Einfluss heterogener kognitiver Segmente auf das Wahlverhalten getestet werden.

Der postulierte Ansatz würde somit erstmals eine Verbindung des MEC-Ansatzes zum Entscheidungsverhalten herstellen. Daneben stellt der Ansatz eine wirkungsvolle Segmentierung der Verbraucher dar, da entsprechende Segmente sowohl aus den kognitiven Strukturen als auch dem Wahlverhalten abgeleitet werden. Aus Sicht der Discrete Choice Analyse könnte der Ansatz eine bessere Identifikation und Interpretation latenter Klassen ermöglichen.

---

<sup>10</sup> Für eine detaillierte Diskussion von Choice Experimenten siehe Louviere et al. (2001).

Offen bleiben noch Fragen, welche die Datenerhebung, insbesondere eine etwaige Überforderung der Befragten, sowie die Schätzung des postulierten Modells betreffen. Abschließend könnten solche Fragen anhand einer empirischen Studie geklärt werden. Es ist daher vorgesehen, eine quantitative Befragung durchzuführen, die sich mit der Verbraucherwahrnehmung genetisch veränderter Lebensmittel beschäftigt. Der postulierte Ansatz soll daher anhand dieses konkreten Beispiels auf der GEWISOLA-Tagung präsentiert werden.

## Literatur

- AJZEN, I. und M. FISHBEIN (1980): *Understanding Attitudes and Predicting Social Behavior*. Prentice-Hall, Englewood Cliffs, NJ.
- AURIFEILLE, J. und P. VALETTE-FLORENCE (1995): Determination of the Dominant Means-End Chains: A Constrained Clustering Approach. In: *International Journal of Research in Marketing* 12(3): 267-278.
- BAGOZZI, R. und P. A. DABHOLKAR (1994): Consumer Recycling Goals and their Effects on Decisions to Recycle: A Means-end Analysis. In: *Psychology and Marketing* 1(4): 313-340.
- BEN-AKIVA, M., D. MCFADDEN, M. ABE, U. BÖCKENHOLT, D. BOLDOC, D. GOPINATH, T. MORIKAWA, V. RAMASWAMY, V. RAO, D. REVELT und D. STEINBERG (1997): Modeling Methods for Discrete Choice Analysis. In: *Marketing Letters* 8(3): 273-286.
- BOTSCHEN, G. und E. THELEN (1998): Hard versus Soft Laddering: Implications for Appropriate Use. New Developments and Approaches in Consumer Behaviour Research. In: I. BALDERJAHN et al. (Hrsg.). Schaffer-Poeschel, Stuttgart: 322-339.
- BREDAHL, L. (1999): Consumers' Cognitions With Regard to Genetically Modified Foods. Results of a Qualitative Study in Four Countries. In: *Appetite* 33(3): 343-360.
- CHESHER, A. und J. M. C. SANTOS SILVA (2002): Taste Variation in Discrete Choice Models. In: *Review of Economic Studies* 69(1): 147-168.
- COOK, A. J., G. N. KERR und G. MOORE (2002): Attitudes and Intentions towards Purchasing GM food. In: *Journal of Economic Psychology* 23(5): 557-572.
- GOPINATH, D. (1995). Modeling Heterogeneity in Discrete Choice Processes: Application to Travel Demand. Department of Civil and Environmental Engineering. Massachusetts, Massachusetts Institute of Technology.
- GRUNERT, K. G., S. C. GRUNERT und E. SÖRENSEN (1995). Means-End Chains and Laddering: An Inventory of Problems and an Agenda for Research. Working Paper. Aarhus, Dänemark, Center for Market Surveillance, Research and Strategy for the Food Sector, Aarhus School of Business.
- GRUNERT, K. G., L. LÄHTEENMÄKI, N. K. NIELSEN, J. B. POULSEN, O. UELAND und A. ÅSTRÖM (2001): Consumer Perceptions of Food Products Involving Genetic Modification - Results from a Qualitative Study in Four Nordic Countries. In: *Food Quality and Preference* 12(8): 527-542.
- HERRMANN, A. (1996): Nachfrageorientierte Produktgestaltung - Ein Ansatz auf Basis der "Means end"-Theorie. Gabler, Wiesbaden.
- HOFSTEDE, F. T., A. AUDENAERT, J. E. M. STEENKAMP und M. WEDEL (1998): An Investigation into the Association Pattern Technique as a Quantitative Approach to Measuring Means-End Chains. In: *International Journal of Marketing Research* 15(1): 37-50.
- HOFSTEDE, F. T., J. E. M. STEENKAMP und M. WEDEL (1999): International Market Segmentation Based on Consumer-Product Relations. In: *Journal of Marketing Research* 36(1): 1-17.
- LOUVIERE, J. J., J. SWAIT und D. A. HENSHER (2001): *Stated Choice Methods: Analysis and Applications*. Cambridge University Press, Cambridge.
- MCFADDEN, D. (1974): Conditional Logit Analysis of Qualitative Choice Behavior. *Frontiers in Econometrics*. In: P. ZAREMBKA (Hrsg.). Academic Press, New York: 105-142.
- OLSON, J. C. (1989): Theoretical Foundations of Means-End Chains. In: *Werbeforschung & Praxis* 5: 174-178.
- REYNOLDS, T. J. und J. GUTMAN (1988): Laddering, Theory, Method, Analysis, and Interpretation. In: *Journal of Advertising Research* 28(1): 11-31.

- ROSSITER, J. R. und L. PERCY (2001): The a-b-e Model of Benefit Focus in Advertising. Understanding Consumer Decision Making: The Means End-Approach to Marketing and Advertising Strategy. In: T. J. REYNOLDS und J. OLSON (Hrsg.). Lawrence Erlbaum, Mahwah, NJ: 183-214.
- RUSSELL, C. G., I. FLIGHT, P. LEPPARD, J. A. VAN LAWICK VAN PABST, J. A. SYRETTE und D. N. COX (2004): A Comparison of Paper-and-Pencil and Computerized Methods of "Hard" Laddering. In: Food Quality and Preference 15(3): 279-291.
- TRAIN, K. (2002): Discrete Choice Methods with Simulation. Cambridge University Press, Cambridge.
- VALETTE-FLORENCE, P. und B. RAPACCHI (1991): Improvements in Means-End Chain Analysis: Using Graph Theory and Correspondence Analysis. In: Journal of Advertising Research 31(1): 30-45.
- WEDEL, M. und W. A. KAMAKURA (2000): Market Segmentation: Conceptual and Methodological Foundations. Kluwer, Dordrecht.
- ZANOLI, R. und S. NASPETTI (2002): Consumer Motivation in the Purchase of Organic Food: A Means-End Approach. In: British Food Journal 104(8): 643-653.