

Timo Schulze/Karen Gedenk/Bernd Skiera*

Segmentspezifische Schätzung von Zahlungsbereitschaftsfunktionen

1 Problemstellung

Vor dem Hintergrund steigender Wettbewerbsintensität auf vielen Absatzmärkten hat die Bedeutung der Preispolitik in den letzten Jahren deutlich zugenommen¹. Ein wichtiges preispolitisches Instrument für Produkte oder Dienstleistungen, bei denen Kunden in der Regel mehr als eine Mengeneinheit nachfragen, ist die nichtlineare Preisbildung, auch mengenmäßige Preisdifferenzierung genannt, bei welcher der durchschnittlich pro Einheit zu zahlende Preis mit der gekauften Menge variiert². Typische Beispiele für die nichtlineare Preisbildung sind zweiteilige Tarife, die sich aus einem nutzungsunabhängigen und einem nutzungsabhängigen Preis zusammensetzen. Eingesetzt werden solche Tarife beispielsweise von Telekommunikationsunternehmen, Stromversorgern und Internet Providern³. Viel diskutiert wurde diese Form der Preisdifferenzierung vor kurzem auch in Zusammenhang mit der Preisreform der Deutschen Bahn. So setzt sich der Preis für eine Bahnfahrt mit BahnCard aus zwei Teilen zusammen. Die BahnCard ist hierbei die nutzungsunabhängige und die zusätzlich zu kaufende Fahrkarte, deren Preis abhängig ist von der zurückzulegenden Entfernung, die nutzungsabhängige Komponente eines zweiteiligen Tarifs. Das Ziel von Unternehmen bei der nichtlinearen Preisbildung ist es, durch das Abschöpfen zusätzlicher Konsumentenrente den Gewinn zu steigern.

Eine wesentliche Voraussetzung für eine nichtlineare Preisbildung ist die Kenntnis des Nutzungsverhaltens der Kunden bei unterschiedlichen Preisen. Abgebildet werden kann dieses Nutzungsverhalten durch Zahlungsbereitschaftsfunktionen, im angelsächsischen Sprachgebrauch als „willingness-to-pay functions“ bezeichnet⁴. Sie geben an, wie viel ein Kunde für verschiedene Nachfragemengen eines Produkts maximal zu zahlen bereit ist⁵. Dabei genügt es nicht, eine Zahlungsbereitschaftsfunktion für alle Kunden gemeinsam zu schätzen. Vielmehr setzt die Opti-

* Dr. *Timo Schulze*, Marketing Manager Planning & Analysis, AOL Deutschland GmbH & Co. KG, Millerntorplatz 1, 20359 Hamburg. Prof. Dr. *Karen Gedenk*, Universität zu Köln, Seminar für Allgemeine BWL, Marketing und Marktforschung, Albertus-Magnus-Platz-1, 50923 Köln. Prof. Dr. *Bernd Skiera*, Lehrstuhl für Betriebswirtschaftslehre, insbesondere Electronic Commerce, Johann Wolfgang Goethe-Universität Frankfurt, Mertonstraße 17, 60054 Frankfurt am Main.

¹ Vgl. *Diller* (2003), S. 5.

² Vgl. *Büschken* (2003), S. 523.

³ Vgl. *Choi/Stahl/Wbinston* (1997) S. 49; *Skiera* (2001) S. 274.

⁴ Vgl. *Wilson* (1993), S. 48; *Oren/Smith/Wilson* (1982), S. 291.

⁵ Vgl. *Skiera* (1999), S. 21; *Wilson* (1993), S. 48; *Oren/Smith/Wilson* (1982), S. 291.

mierung der Tarifstruktur bei der nichtlinearen Preisbildung die Kenntnis stärker disaggregierter Zahlungsbereitschaftsfunktionen voraus⁶. So werden Informationen über Konsumentenrenten und die daraus resultierenden Nachfragemengen auf individueller oder zumindest segmentspezifischer Ebene benötigt.

In bisherigen empirischen Studien zur nichtlinearen Preisbildung wurden die Zahlungsbereitschaftsfunktionen auf individuellem Niveau ermittelt⁷. Darauf aufbauend lassen sich optimale Tarifstrukturen bestimmen, da für jeden Kunden die für verschiedene Preise nachgefragte Menge prognostiziert werden kann. Die Annahme ist dabei, dass Kunden die Menge wählen, bei der sie ihre Konsumentenrente maximieren. Typischerweise tritt bei der individuellen Schätzung aber das Problem auf, dass pro Proband nur wenige Datenpunkte zur Verfügung stehen. Dies ist dadurch bedingt, dass bei einer zu umfangreichen Befragung die Bereitschaft zur Mitarbeit sinkt und die Gefahr einer Überforderung der Befragten zunimmt⁸. Durch die geringe Anzahl von Freiheitsgraden bei der individuellen Schätzung besteht aber die Gefahr eines Over-Fitting, so dass das Kaufverhalten bei anderen als den abgefragten Tarifstrukturen nur schlecht prognostiziert werden kann⁹. Bereits *Tacke* diskutiert daher die Möglichkeit, Zahlungsbereitschaften nicht individuell, sondern mit Hilfe der Clusteranalyse auf der Ebene von Segmenten zu ermitteln¹⁰. Allerdings handelt es sich dabei um einen zweistufigen Ansatz, bei dem die Zahlungsbereitschaftsfunktionen zunächst individuell geschätzt und erst anschließend aggregiert werden.

Wir schlagen im Folgenden einen Ansatz vor, mit dem Zahlungsbereitschaftsfunktionen in besser geeigneter Weise direkt auf Segmentebene geschätzt werden können. Wir übertragen dazu das in anderem Zusammenhang (insbesondere bei Paneldaten- und Conjoint-Analysen) häufig eingesetzte Finite Mixture-Modell¹¹ auf Zahlungsbereitschaftsfunktionen. Bei diesem Ansatz werden die Parameter der Zahlungsbereitschaftsfunktionen in den einzelnen Segmenten und die Wahrscheinlichkeit der Zugehörigkeit zu den Segmenten simultan geschätzt. Finite Mixture-Modelle führen typischerweise zu robusten und gut interpretierbaren Ergebnissen¹². Ex post lassen sich auf Basis der individuellen Segmentzugehörigkeitswahrscheinlichkeiten wieder Zahlungsbereitschaftsfunktionen für einzelne Kunden ermitteln. Wir setzen unser Modell ein, um Zahlungsbereitschaften für aktuelle Artikel von Online-Zeitungen zu ermitteln.

Der Aufsatz leistet damit folgende Beiträge:

- Wir setzen erstmalig ein Finite Mixture-Modell zur Schätzung von Zahlungsbereitschaftsfunktionen ein.
- Da die Bestimmung der Segmentanzahl bei Finite Mixture-Modellen auf Basis der üblichen Fit-Kriterien mit Problemen behaftet ist¹³, verwenden wir zusätzlich die Prognosegüte zur Bestimmung der Segmentanzahl.

⁶ Vgl. *Tacke* (1989), S. 163; *Brown/Sibley* (1986).

⁷ Vgl. *Tacke* (1989); *Clement* (2000); *Skiera* (1999).

⁸ Vgl. *Gensler* (2003), S. 58; *Skiera* (1999), S. 234; *Lenk et al.* (1996) S. 173ff.

⁹ Vgl. *Andrews/Ansari/Currim* (2002).

¹⁰ Vgl. *Tacke* (1989), S. 197f.

¹¹ Vgl. *Wedel/Kamakura* (2000); *Gensler* (2003), S. 95ff.

¹² Vgl. *Ailawadi/Gedenk/Neslin* (1999).

- Wir untersuchen die Face-Validität und die Robustheit von segmentspezifischen Zahlungsbereitschaftsfunktionen.
- Wir vergleichen segmentspezifische und individuelle Zahlungsbereitschaftsfunktionen in Hinblick auf Fit und Prognosegüte, wobei wir unterschiedliche Funktionsformen berücksichtigen.

Der Aufsatz ist wie folgt gegliedert. Kapitel 2 stellt verschiedene Varianten von Zahlungsbereitschaftsfunktionen vor und erläutert, warum wir bestimmte Ansätze auswählen. Kapitel 3 beschreibt anschließend die verwendeten Modelle und ihre Schätzung. In Kapitel 4 erläutern wir die Vorgehensweise der empirischen Studie, und in Kapitel 5 präsentieren wir deren Befunde. Der Beitrag endet mit einer Zusammenfassung der wesentlichen Ergebnisse in Kapitel 6.

2 Zahlungsbereitschaftsfunktionen

2.1 Messung von Zahlungsbereitschaften

Grundsätzlich gibt es drei Datenquellen, auf die Instrumente zur Messung von Zahlungsbereitschaften zurückgreifen können: Nutzungsdaten, Nutzungsangebote und Präferenzdaten¹⁴. Ein Vorteil von Nutzungsdaten liegt darin, dass sie tatsächliches Verhalten erfassen, so dass bei ihrer Verwendung eine hohe externe Validität vermutet werden kann¹⁵. Dabei bieten sich insbesondere Feldexperimente zur Erfassung des Nutzungsverhaltens bei unterschiedlichen Preisen an¹⁶. Problematisch sind allerdings die hohen Kosten der Durchführung von Feldexperimenten. Werden aus Kostengründen nur wenige Preise getestet, so sind nur sehr eingeschränkte Aussagen zur Zahlungsbereitschaft möglich¹⁷. Bei Nutzungsangeboten können durch Auktionen oder Lotterien Zahlungsbereitschaften erhoben werden. Ein Vorteil dieser Verfahren ist, dass sie anreizkompatibel sind. Ihr Einsatz ist jedoch aufwändig, und trotz einiger viel versprechender Ergebnisse¹⁸ sind sie bislang erst vereinzelt angewendet worden.

In der Praxis werden häufig Präferenzdaten zur Ermittlung von Zahlungsbereitschaften verwendet¹⁹. Sie können in Form einer indirekten oder einer direkten Befragung erhoben werden. Während bei indirekten Befragungen typischerweise Conjoint-Analysen eingesetzt werden²⁰, kommen direkte Preisbefragungen in unterschiedlichen Varianten vor²¹. *Sattler/Nitschke* (2003) zeigen, dass direkte Befragungen im Vergleich zu Auktionen und Conjoint-Analysen durchaus geeignet

¹³ Vgl. *Andrews/Currim* (2003); *Wedel/Kamakura* (2000), S. 91.

¹⁴ Vgl. *Skiera* (1999), S. 160ff.; *Sattler/Nitschke* (2003), S. 364ff.

¹⁵ Vgl. *Skiera/Revenstorff* (1999), S. 224.

¹⁶ Vgl. *Danaber* (2002).

¹⁷ Vgl. *Danaber* (2002), S. 120f.; *Ben-Akiva et al.* (1994), S. 344; *Skiera/Revenstorff* (1999), S. 224.

¹⁸ Vgl. *Wertenbroch/Skiera* (2002), S. 230; *Skiera/Revenstorff* (1999); *Sattler/Nitschke* (2003), S. 366.

¹⁹ Vgl. *Ben-Akiva et al.* (1994), S. 355ff.

²⁰ Vgl. *Kalish/Nelson* (1991), S. 328ff.; *Green/Srinivasan* (1990); *Balderjahn* (2003), S. 391ff.

sind, um Zahlungsbereitschaften zu erheben. Wir wählen daher für unsere Untersuchung eine direkte Befragung.

Im Zusammenhang mit Zahlungsbereitschaftsfunktionen für die nichtlineare Preisbildung hat sich bei der direkten Befragung vor allem die von *Wyner/Benedetti/Trapp* (1984), *Skiera* (1999) und *Clement* (2000) angewendete Preis-Mengenbefragung bewährt. Bei dieser wird der Kunde gefragt, wie viele Einheiten eines Produkts er zu bestimmten Preisen kaufen würde. Der besondere Vorteil dieser Variante liegt darin, dass die für die Schätzung von Zahlungsbereitschaftsfunktionen erforderliche Zahlungsbereitschaft für verschiedene Mengeneinheiten auf vergleichsweise einfache und kostengünstige sowie für den Probanden verständliche Art ermittelt wird.

2.2 Funktionsverläufe von Zahlungsbereitschaftsfunktionen

Die Zahlungsbereitschaftsfunktion beschreibt, wie viel der i -te Kunde für eine Nachfragemenge von q_i Einheiten maximal zu zahlen bereit ist²². Um eine realistische Abbildung des Kundenverhaltens zu gewährleisten, muss die Funktion die Eigenschaften des ersten Gossenschen Gesetzes, also einen positiven, aber abnehmenden Grenznutzen, abbilden²³:

$$\frac{d U_i(q_i)}{dq_i} \geq 0 \quad (q_i \geq 0) \quad (1)$$

$$\frac{d^2 U_i(q_i)}{dq_i^2} < 0 \quad (q_i \geq 0) \quad (2)$$

wobei:

U_i : Nutzen des i -ten Probanden
 q_i : Nachfragemenge des i -ten Probanden

Tabelle 1 gibt einen Überblick über die in der Literatur verwendeten Zahlungsbereitschaftsfunktionen²⁴.

²¹ Vgl. *Sattler/Nitschke* (2003), S. 364f.

²² Vgl. *Skiera* (1999), S. 21; *Tacke* (1989); *Wilson* (1993).

²³ Vgl. *Gossen* (1854).

²⁴ In Anlehnung an *Skiera* (1999), S. 33f. Auf die Darstellung der ebenfalls in der Literatur verwendeten multiplikativen Zahlungsbereitschaftsfunktion wird verzichtet. Sie kann weder eine Sättigungsmenge noch eine maximale Zahlungsbereitschaft modellieren. Zudem stellt *Skiera* (1999) fest, dass Mengenangaben von Null den Verlauf der geschätzten Funktion unangemessen stark beeinflussen, was zu oftmals unplausiblen Ergebnissen führt.

Tabelle 1: Vergleich der Eigenschaften von Zahlungsbereitschaftsfunktionen

Funktionsverlauf	Quadratische Funktion	Semi-logarithmische Funktion	Modifiziert-exponentielle Funktion
Zahlungsbereitschaftsfunktion $ZB_i(q_i)$	$\begin{cases} a_i \cdot q_i - \frac{b_i}{2} \cdot q_i^2 & q_i \leq \frac{a_i}{b_i} \\ \frac{a_i^2}{2 \cdot b_i} & q_i > \frac{a_i}{b_i} \end{cases}$	$\begin{cases} \frac{q_i}{b_i} \cdot [1 + \ln(a_i) - \ln(q_i)] & q_i \leq a_i \\ \frac{a_i}{b_i} & q_i > a_i \end{cases}$	$a_i \cdot [1 - \exp(-b_i \cdot q_i)]$
Preisbereitschaftsfunktion $PB_i(q_i)$	$\begin{cases} a_i - b_i \cdot q_i & q_i \leq \frac{a_i}{b_i} \\ 0 & q_i > \frac{a_i}{b_i} \end{cases}$	$\begin{cases} \frac{\ln(a_i) - \ln(q_i)}{b_i} & q_i \leq a_i \\ 0 & q_i > a_i \end{cases}$	$a_i \cdot b_i \cdot \exp(-b_i \cdot q_i)$
Nachfragefunktion $q_i(p)$	$\begin{cases} \frac{a_i}{b_i} - \frac{1}{b_i} \cdot p & p \leq a_i \\ 0 & p > a_i \end{cases}$	$a_i \cdot \exp(-b_i \cdot p)$	$\begin{cases} \frac{1}{b_i} \cdot [\ln(a_i \cdot b_i) - \ln(p)] & p \leq a_i \cdot b_i \\ 0 & p > a_i \cdot b_i \end{cases}$
Maximale Zahlungsbereitschaft	$\frac{a_i^2}{2 \cdot b_i}$	$\frac{a_i}{b_i}$	a_i
Sättigungsmenge (maximale Nachfragemenge)	$\frac{a_i}{b_i}$	a_i	Keine Sättigungsmenge
Studien mit Schätzung auf individueller Ebene	<i>Tacke</i> (1989) <i>Skiera</i> (1999) <i>Clement</i> (2000)	<i>Skiera</i> (1999) <i>Clement</i> (2000)	<i>Tacke</i> (1989) <i>Skiera</i> (1999) <i>Clement</i> (2000)
Mit:	<p>p: Preis a_i, b_i: Parameter der Zahlungsbereitschaftsfunktion des i-ten Kunden</p>		

Zur Verdeutlichung ihrer Eigenschaften sind außerdem die entsprechenden Preisbereitschafts- und Nachfragefunktionen aufgeführt. Die Preisbereitschaftsfunktion ist die erste Ableitung der Zahlungsbereitschaftsfunktion und gibt die marginale Zahlungsbereitschaft an. Die Nachfragefunktion ist die Umkehrfunktion der Preisbereitschaftsfunktion und gibt an, welche Menge der i -te Kunde zum Preis p nachfragt.

Eine auffällige Schwäche der modifiziert-exponentiellen Zahlungsbereitschaftsfunktion ist, dass sie keine Sättigungsmenge berücksichtigen kann. Eine Schwäche der quadratischen Zahlungsbereitschaftsfunktion liegt darin, dass die Nachfragefunktion einen linearen Verlauf hat. Demnach ist die marginale Mengenänderung bei einer Preisänderung für alle Preise bis zum Erreichen des Maximalpreises gleich. Realistischer ist der semi-logarithmische Funktionsverlauf, bei dem die marginale Mengenänderung mit steigendem Preis abnimmt. Aus theoretischer Sicht ist demzufolge die semi-logarithmische Zahlungsbereitschaftsfunktion den anderen Funktionsverläufen vorzuziehen. Da in der Literatur jedoch auch die anderen beiden Funktionsformen verwendet werden, schätzen wir in unserer Studie alle drei Modelle und vergleichen sie anhand von Fit und Prognosegüte.

2.3 Berücksichtigung von Heterogenität

Die Schätzung einer für alle Kunden einheitlichen Zahlungsbereitschaftsfunktion ist wenig sinnvoll, da davon auszugehen ist, dass Kunden unterschiedliche Präferenzen für Produkte haben und damit auch unterschiedliche Zahlungsbereitschaften. Bei der Preisdifferenzierung in Form nichtlinearer Preisbildung möchte man diese Heterogenität aber gerade erfassen und ausnutzen, um möglichst viel Konsumentenrente abzuschöpfen.

Bislang wurde Heterogenität in der Form berücksichtigt, dass Zahlungsbereitschaftsfunktionen auf individuellem Niveau geschätzt wurden, d.h. als so genannte „Fixed Effects-Modelle“²⁵. Hierbei werden die Parameter der Zahlungsbereitschaftsfunktion für jeden Kunden einzeln ermittelt. Dieses Vorgehen zeichnet sich durch eine große Flexibilität hinsichtlich der Berücksichtigung von Heterogenität in den Präferenzen der Kunden aus. Problematisch ist aber zum einen, dass meist nur sehr wenige Beobachtungen pro Kunde vorliegen²⁶. Dies führt dazu, dass bei einer individuellen Schätzung die Parameter instabil sind und Aussagen zur Signifikanz kaum getroffen werden können. Außerdem besteht die Gefahr des Over-Fitting, so dass die Nachfragemenge der Kunden bei anderen als den abgefragten Tarifen nur schlecht prognostiziert werden kann. Zum anderen ist für eine sinnvolle Interpretation der Ergebnisse oft eine Verdichtung erforderlich. Clusteranalytische Verfahren können zwar prinzipiell zur Verdichtung der Ergebnisse herangezogen werden. Sie bauen letztlich aber auf den möglicherweise instabilen Ergebnissen der individuellen Parameterschätzung auf. Zudem führt die zweistufige Vorgehensweise – erst Schätzung einer Nutzungsfunktion, dann Bildung von Segmenten – dazu, dass in den beiden Stufen unterschiedliche Zielgrößen verwendet werden. So wird bei der Funktionsschätzung der Likelihood-Wert und bei der Clusterbildung das Verhältnis der Varianz zwischen den Segmenten und der Varianz innerhalb der Segmente maximiert²⁷. Eine simultane Schätzung würde möglicherweise zu anderen Ergebnissen führen, die insgesamt einen besseren Fit an die Daten aufweisen.

Besser geeignet zur Erfassung von Heterogenität in den Zahlungsbereitschaften der Kunden sind daher stochastische Ansätze, d.h. Random Effects-Modelle²⁸. Sie gehen davon aus, dass die zu schätzenden Parameter einer Verteilung folgen. Ist die Verteilung stetig, spricht man von einem Continuous Mixture-Modell. In diesem Fall werden die Parameter der Verteilung geschätzt. Erfolgt die Schätzung mit dem Hierarchical Bayes-Ansatz können darüber hinaus individuelle Parameter ermittelt werden. Ein Finite Mixture-Modell geht dagegen von einer diskreten Verteilung aus²⁹. Geschätzt werden Zahlungsbereitschaftsfunktionen für Segmente von Kunden und die Wahrscheinlichkeit der Kunden, zu den einzelnen Segmenten zu gehören, beziehungsweise die Größe der Segmente.

²⁵ Vgl. Skiera (1999); Clement (2000); Tacke (1989); Gensler (2003), S. 101f.

²⁶ Vgl. Skiera (1999), S. 93ff.; Allenby/Rossi (1999), S. 59.

²⁷ Vgl. Gensler (2003), S. 107; Cohen/Ramaswamy (1998), S. 15f.

²⁸ Vgl. Wedel/Kamakura (2000); Train (2003), S. 138ff.

²⁹ Vgl. Kamakura/Russell (1989).

Finite Mixture-Modelle weisen gegenüber Continuous Mixture-Modellen einige Vorteile auf. Zunächst sind sie flexibler, da sie keine bestimmten Verteilungsannahmen treffen³⁰. Weiterhin zeigen *Andrews/Ainslie/Currim* (2002), dass Hierarchical Bayes-Modelle zu schlechteren Ergebnissen als Finite Mixture-Modelle führen, wenn nur wenige Beobachtungen pro Kunde vorliegen. Da, wie oben erläutert, häufig Präferenzdaten zur Schätzung von Zahlungsbereitschaftsfunktionen herangezogen werden, liegen meist nur wenige Beobachtungen pro Kunde vor. Schließlich entsprechen Segmente der typischen Denkweise von Managern und lassen sich somit gut interpretieren und vermitteln³¹. Insgesamt haben sich Finite Mixture-Modelle bei der Präferenzanalyse immer wieder als sehr vorteilhaft erwiesen³². Wir verwenden daher im Folgenden einen Finite Mixture-Ansatz zur segmentspezifischen Schätzung von Zahlungsbereitschaftsfunktionen.

3 Modelle und ihre Schätzung

Zum besseren Verständnis wird zunächst auf die Schätzung von Zahlungsbereitschaftsfunktionen auf individueller Ebene eingegangen. Daran anschließend erfolgt die Vorstellung des Finite Mixture-Modells zur segmentspezifischen Schätzung von Zahlungsbereitschaftsfunktionen.

3.1 Individuelle Zahlungsbereitschaftsfunktionen

Ausgangspunkt der Schätzung sind Beobachtungen von Preis-Mengenkombinationen, also Angaben, welche Menge ein Proband zu unterschiedlichen Preisen nachfragt. Aus diesen Angaben wird die Nachfragefunktion $q_i(p)$ des i -ten Probanden geschätzt. Aus den Parametern der Nachfragefunktionen können dann die Parameter der Zahlungsbereitschaftsfunktionen abgeleitet werden (siehe *Tabelle 1*). Dies sei erläutert am Beispiel der semi-logarithmischen Zahlungsbereitschaftsfunktion. Die entsprechende Nachfragefunktion lautet:

$$q_{in}(p_n) = a_i \cdot \exp(-b_i \cdot p_n) + \varepsilon_{in} (a_i, b_i \geq 0) \quad (3)$$

wobei:

- q_{in} : Nachfragemenge des i -ten Probanden bei der n -ten Beobachtung
- p_n : Preis bei der n -ten Beobachtung
- a_i, b_i : Parameter der Zahlungsbereitschaftsfunktion des i -ten Probanden
- ε_{in} : Fehlerterm bei der n -ten Beobachtung des i -ten Probanden

³⁰ Vgl. *Ailawadi/Gedenk/Neslin* (1999); *Genster* (2003), S. 106.

³¹ Vgl. *Genster* (2003), S. 283; *Wedel/Kamakura* (2002), S. 182.

³² Für ausgewählte Beispiele siehe *Wedel/Kamakura* (2000), S. 118; *Andrews/Currim* (2003).

Zur Bestimmung der Parameterwerte a_i und b_i bietet sich die Maximum Likelihood-Schätzung an³³. Unter der Annahme, dass die Residuen normalverteilt sind, ist der folgende Likelihood-Wert zu maximieren:

$$L_i = \prod_{n=1}^N \left[(2\pi)^{-1/2} \cdot (\sigma_i^2)^{-1/2} \cdot \exp \left(-\frac{[q_{in} - a_i \cdot \exp(-b_i \cdot p_n)]^2}{2 \cdot \sigma_i^2} \right) \right] \quad (4)$$

wobei:

- L_i Likelihood-Wert für den i -ten Probanden
- σ_i^2 : Varianz des Fehlerterms für den i -ten Probanden
- N : Anzahl der Beobachtungen pro Proband

Zur Vereinfachung der Schätzung wird in der Regel der Logarithmus dieses Wertes maximiert, d. h. der Log-Likelihood-Wert. Die individuellen Zahlungsbereitschaftsfunktionen ergeben sich durch Einsetzen der geschätzten Parameter der Nachfragefunktionen in die Zahlungsbereitschaftsfunktionen.

3.2 Segmentspezifische Zahlungsbereitschaftsfunktionen

Im Folgenden beschreiben wir, wie der Finite Mixture-Ansatz auf die segment-spezifische Schätzung von Zahlungsbereitschaftsfunktionen übertragen werden kann³⁴. Dieses Modell ermöglicht die simultane Schätzung der segment-spezifischen Parameterwerte der Zahlungsbereitschaftsfunktion und der Segmentzugehörigkeit der Probanden. Wie bei der individuellen Schätzung werden die Parameterwerte der Nachfragefunktion geschätzt, nun aber auf Segmentebene.

Dies führt zu zwei Erweiterungen der Likelihood-Funktion. Zum einen muss berücksichtigt werden, dass jeder Proband mit einer gewissen a priori-Wahrscheinlichkeit η_s den einzelnen Segmenten angehört. Zum anderen muss die Likelihood-Funktion über alle Probanden gemeinsam maximiert werden. Beide Erweiterungen führen zu folgender Likelihood-Funktion:

$$L = \prod_{i=1}^I \sum_{s=1}^S \left(\eta_s \cdot \prod_{n=1}^N \left[(2\pi)^{-1/2} \cdot (\sigma_s^2)^{-1/2} \cdot \exp \left(-\frac{[q_{in} - a_s \cdot \exp(-b_s \cdot p_n)]^2}{2 \cdot \sigma_s^2} \right) \right] \right) \quad (5)$$

³³ Die nichtlineare Nachfragefunktion (3) ist unter bestimmten Bedingungen linearisierbar und kann dann auch mit OLS geschätzt werden. Die Linearisierbarkeit hängt dabei von Annahmen über den Fehlerterm ab (vgl. *Greene* (2003), S. 11). So ist die Funktion $q_i(p) = a_i \cdot \exp(-b_i \cdot p + \varepsilon)$ linearisierbar, $q_i(p) = a_i \cdot \exp(-b_i \cdot p) + \varepsilon$ dagegen nicht. In der unten dargestellten empirischen Studie ergibt sich für die Schätzung der nichtlinearisierten Funktion der bessere Fit, so dass diese Vorgehensweise gewählt wird.

³⁴ Die Kombination eines Regressionsmodells mit einem Finite Mixture-Modell wird auch als Finite Mixture-Regressionsmodell bezeichnet (vgl. *Wedel/Kamakura* (2000), S. 101).

wobei:

η_s : a priori-Wahrscheinlichkeit der Zugehörigkeit zum s -ten Segment = relative Größe des s -ten Segments

I : Anzahl der Probanden

S : Anzahl der Segmente

Über die zwei Nebenbedingungen (6) und (7) wird sichergestellt, dass die a priori-Wahrscheinlichkeiten der Segmentzugehörigkeit bzw. die Segmentgrößen zwischen Null und Eins liegen und sich zu Eins summieren:

$$0 \leq \eta_s \leq 1 \tag{6}$$

$$\sum_{s=1}^S \eta_s = 1 \tag{7}$$

Die a priori-Wahrscheinlichkeiten der Segmentzugehörigkeit η_s sind für alle Probanden gleich. Auf Basis der erfragten Nachfragemengen können jedoch individuelle a posteriori-Wahrscheinlichkeiten der Segmentzugehörigkeit bestimmt werden³⁵:

$$\omega_{is} = \frac{\eta_s \cdot \prod_{n=1}^N \left[(2\pi)^{-1/2} \cdot (\sigma_s^2)^{-1/2} \cdot \exp \left(- \frac{[q_{in} - a_s \cdot \exp(-b_s \cdot p_n)]^2}{2 \cdot \sigma_s^2} \right) \right]}{\sum_{z=1}^S \eta_z \cdot \prod_{n=1}^N \left[(2\pi)^{-1/2} \cdot (\sigma_z^2)^{-1/2} \cdot \exp \left(- \frac{[q_{in} - a_z \cdot \exp(-b_z \cdot p_n)]^2}{2 \cdot \sigma_z^2} \right) \right]} \tag{8}$$

wobei:

ω_{is} : a posteriori-Wahrscheinlichkeit der Segmentzugehörigkeit des i -ten Probanden zum s -ten Segment

Die Schätzung der Finite Mixture-Modelle wurde mit der Software GAUSS unter Verwendung des MAXLIK-Moduls und des BFGS-Algorithmus durchgeführt.

4 Vorgehensweise der empirischen Studie

Die hier vorgestellte Studie untersucht Zahlungsbereitschaften für aktuelle Artikel von Online-Zeitungen. Dies ist für Zeitungsverlage eine ausgesprochen wichtige Frage, da viele von ihnen derzeit über Nutzungspreise für ihr Online-Angebot nachdenken. Einige Jahre lang haben Zeitungsverlage ihre Erlöse im Internet primär über Werbeeinnahmen generiert. Da sie damit jedoch meist keinen Gewinn erzielen konnten, beginnen sie nun, ihre Angebote oder zumindest Teile davon, kostenpflichtig zu machen. Vorreiter in Deutschland ist beispielsweise SPIEGEL ONLINE. Aber auch die Online-Verantwortlichen anderer Zeitungen gehen davon aus, dass die Bedeutung von Nutzungspreisen in Zukunft stei-

³⁵ Vgl. Kamakura/Russell (1989); Wedel/Kamakura (2000), S. 81, Gensler (2003), S. 120.

gen wird³⁶. Dabei ist die Preisfindung für die Verlage sehr schwierig, da die Höhe der Zahlungsbereitschaft von Lesern bisher noch weitgehend unbekannt ist.

Die Datenerhebung für unsere Untersuchung erfolgte im März 2003 durch eine Online-Befragung in Kooperation mit einer überregionalen deutschen Tageszeitung, deren Online-Angebot zu den zehn am meisten genutzten Websites von deutschen Tageszeitungen im Internet zählt. Die Zeitung zeichnet sich durch intensive Online-Aktivitäten aus. Durch einen kompletten Relaunch des Online-Auftritts nur wenige Wochen vor der Befragung wurde versucht, das Angebot noch besser auf die Bedürfnisse der Online-Leser zuzuschneiden. Auf die Befragung wurden die Leser der Online-Ausgabe der Zeitung durch ein Pop-Up aufmerksam gemacht, das sie bei Interesse über einen Link zum Online-Fragebogen weitergeleitet hat.

Die Zahlungsbereitschaft für aktuelle Artikel der Online-Ausgabe wurde durch folgende Preis-Mengenbefragung erhoben:

Frage A

Wie viele Artikel würden Sie für die jeweiligen Preise wohl durchschnittlich pro Monat lesen?

- _____ Artikel bei 1,00€/Artikel
- _____ Artikel bei 0,50€/Artikel
- _____ Artikel bei 0,25 €/Artikel
- _____ Artikel bei 0,10 €/Artikel
- _____ Artikel, wenn diese kostenfrei sind

Folgende Frage diente als Hold-Out, mit dem die Prognosegüte der geschätzten Zahlungsbereitschaftsfunktionen ermittelt werden soll:

Frage B

Welchen dieser Tarife würden Sie bevorzugen (wenn alle Tarife monatlich abgerechnet würden)?

Bitte geben Sie für den für Sie attraktivsten Tarif eine „1“ an. Für den Tarif, den Sie am zweitbesten finden, eine „2“ und für den Tarif, den Sie am unattraktivsten finden, eine „3“.

- Abonnementgebühr von 10 € pro Monat
- Preis pro Artikel von 0,25 €
- Abonnementgebühr von 5 € pro Monat sowie Preis pro Artikel von 0,10 €

Folgende Frage diente der Ermittlung der Anzahl der Artikel, die von den Kunden zum Zeitpunkt der Befragung regelmäßig gelesen wurden:

Frage C

Wie viele Artikel lesen Sie durchschnittlich pro Woche in der aktuellen Online-Ausgabe dieser Zeitung (ohne Archiv)?

Insgesamt nahmen 2221 Kunden an der Befragung teil. Von diesen gaben 201 Kunden an, eine Zahlungsbereitschaft für den Abruf einzelner aktueller Artikel

³⁶ Vgl. Schulze/Nix/Gedenk (2003), S. 98.

von der untersuchten Online-Zeitung zu haben. Nach Ausschluss von Antworten mit fehlenden Werten gehen 187 Kunden in die weiteren Analysen ein. *Abbildung 1* gibt einen Überblick über die in *Frage A* jeweils höchste angegebene Zahlungsbereitschaft dieser Kunden, und *Tabelle 2* zeigt, welchen Tarif die Kunden in *Frage B* als erste Präferenz angegeben haben.

Abbildung 1: Höchste Zahlungsbereitschaft pro Artikel




Tabelle 2: Erste Präferenz der Kunden bei der Tarifwahl

Tarifforn	Nennung als 1. Präferenz	Anteil
Abonnementgebühr von 10€ pro Monat	88	47,1 %
Preis pro Artikel von 0,25€	58	31,0 %
Abonnementgebühr von 5€ pro Monat sowie Preis pro Artikel von 0,10€	41	21,9 %

5 Befunde der empirischen Studie

5.1 Bestimmung der Segmentanzahl

Bei Verwendung eines Finite Mixture-Modells muss der Marktforscher eine Entscheidung zur Anzahl der Segmente treffen. Dies geschieht, indem man Modelle mit unterschiedlich vielen Segmenten schätzt und anhand eines Gütekriteriums das Beste auswählt. Nach welchem Gütekriterium die Auswahl der Anzahl der Segmente erfolgen

soll, ist trotz der weiten Verbreitung von Finite Mixture-Modellen nicht abschließend geklärt³⁷. Häufig wird in der Literatur die Segmentlösung gewählt, bei der das Bayesian Information Criterion (*BIC*) am geringsten ist³⁸. Das *BIC* ist ein Fit-Maß, das auf dem Log-Likelihood-Wert basiert und eine Korrektur für die Anzahl der geschätzten Parameter und die Anzahl der zur Schätzung verwendeten Beobachtungen vornimmt.

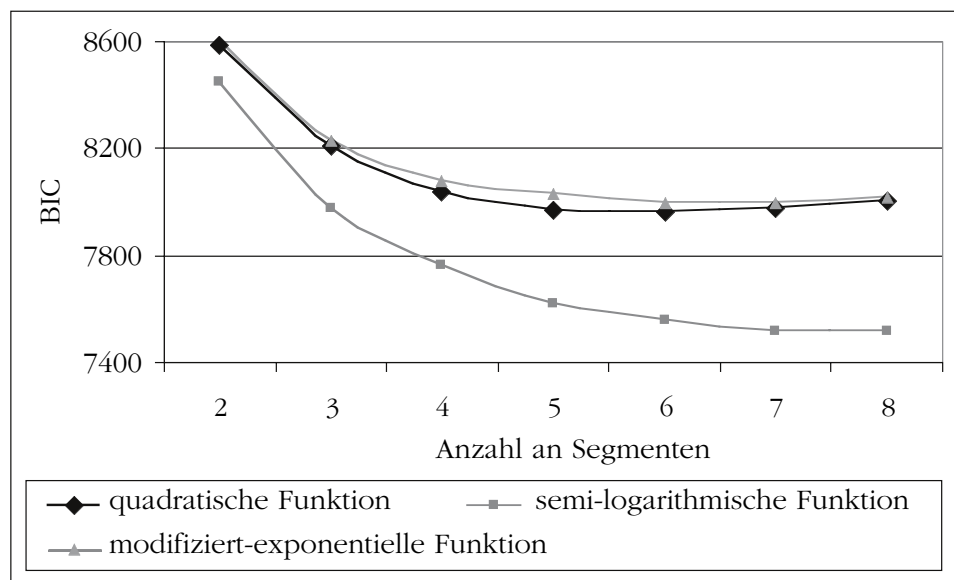
$$BIC = -2 \cdot LL + \ln(I \cdot N) \cdot K \tag{9}$$

wobei:

- LL*: Log-Likelihood
- K*: Anzahl der zu schätzenden Parameter

Abbildung 2 zeigt das BIC für die verschiedenen Funktionsverläufe bei einer unterschiedlichen Anzahl von Segmenten. Beim semi-logarithmischen und beim modifiziert-exponentiellen Funktionsverlauf³⁹ weist das BIC jeweils bei 7 Segmenten, beim quadratischen Funktionsverlauf bei 6 Segmenten den geringsten und damit besten Wert auf.

Abbildung 2: *BIC bei unterschiedlicher Anzahl an Segmenten*

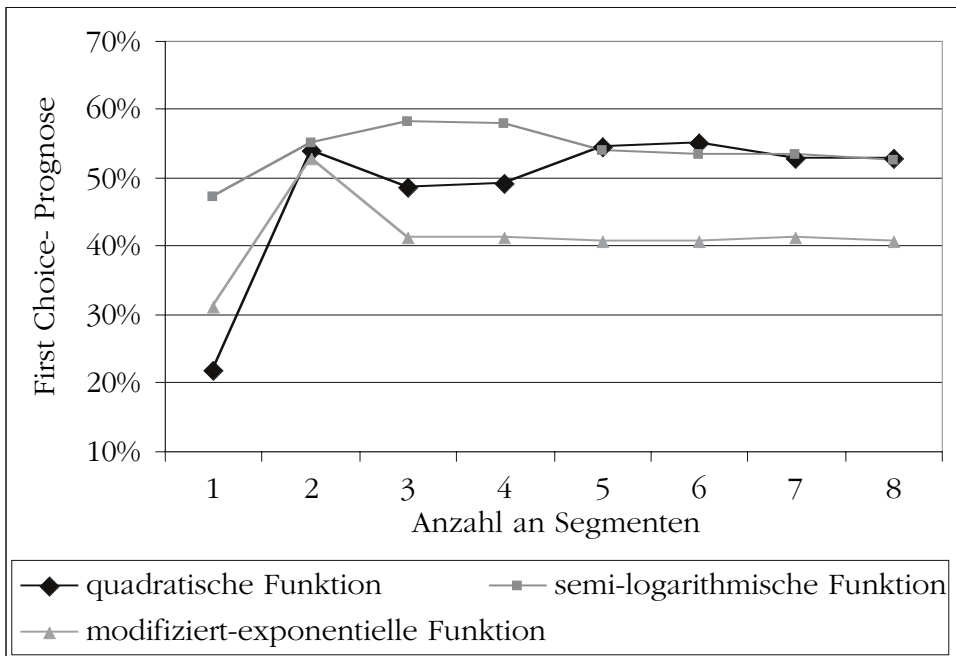


³⁷ Vgl. *Andrews/Currim* (2003), *Wedel/Kamakura* (2000), S. 91.
³⁸ Vgl. *Gensler* (2003), S. 124f.; *Abramson et al.* (2000); *Ailawadi/Gedenk/Neslin* (1999). Das BIC weist im Vergleich zum AIC den Vorteil auf, dass eine Überparametrisierung durch eine zu hohe Segmentanzahl vermieden wird (vgl. *Celeux/Soromenbo* (1996), S. 198). Das ebenfalls häufig verwendete CAIC, das eine mögliche Überparametrisierung des Modells noch stärker vermeidet als das BIC, führt für unser Modell mit Ausnahme des modifiziert-exponentiellen Funktionsverlaufs, bei dem nach dem CAIC eine 6-Segmentlösung favorisiert würde, zu den gleichen Empfehlungen.
³⁹ Bei der Schätzung der modifiziert-exponentiellen Zahlungsbereitschaftsfunktion tritt das Problem beim Preis von Null auf, dass der Logarithmus für einen Wert von Null nicht definiert ist. Daher werden in Anlehnung an *Skiera* (1999), S. 274f. alle Preise um einen konstanten Wert von 0,01 erhöht.

Die Prognosegüte ermitteln wir dabei auf Basis der sich aus der segmentspezifischen Schätzung ergebenden individuellen Zahlungsbereitschaftsfunktionen. Prinzipiell gibt es zwei Möglichkeiten, solche individuellen Zahlungsbereitschaftsfunktionen zu berechnen. Erstens können die Parameter jeder individuellen Zahlungsbereitschaftsfunktion als gewichteter Durchschnitt der Segmentparameter berechnet werden, wobei die a posteriori-Wahrscheinlichkeiten der Segmentzugehörigkeit des jeweiligen Kunden als Gewichte dienen. Zweitens können für den einzelnen Kunden direkt die Parameterwerte des Segments verwendet werden, dem der Kunde mit der höchsten a posteriori-Wahrscheinlichkeit zugeordnet wird. Da die a posteriori-Wahrscheinlichkeiten für das relevante Segment im zweiten Fall sehr hoch sind (bei allen Funktionsformen im Durchschnitt größer 0,91), führen beide Vorgehensweisen zu sehr ähnlichen Ergebnissen. Dies spricht für eine sehr trennscharfe Segmentlösung. Im Folgenden berichten wir die Ergebnisse, die sich ergeben, wenn die Parameter gemäß den a posteriori-Wahrscheinlichkeiten gewichtet werden.

Abbildung 3 zeigt die Prognosegüte nach dem First Choice-Kriterium für unterschiedlich viele Segmente. Berechnet wurde, in wieviel Prozent der Fälle die in Frage B angegebene erste Präferenz der Kunden durch die auf Basis von Frage A ermittelte Zahlungsbereitschaftsfunktion richtig prognostiziert wird.

Abbildung 3: First Choice-Prognose der verschiedenen Funktionsverläufe bei unterschiedlicher Anzahl an Segmenten



Die beste Prognose erfolgt beim modifiziert-exponentiellen Funktionsverlauf bei 2 Segmenten, beim semi-logarithmischen Funktionsverlauf bei 3 Segmenten und beim quadratischen Funktionsverlauf bei 6 Segmenten. Nach dem Kriterium der Prognosegüte erhält man also beim semi-logarithmischen und modifiziert-exponentiellen Funktionsverlauf deutlich weniger Segmente als nach dem verwendeten Fit-Kriterium. Dies spricht dafür, dass bei diesen beiden Funktionsverläufen bereits bei 5 oder 6 Segmenten ein gewisses Over-Fitting auftritt.

Insgesamt kommen wir zu keinem eindeutigen Ergebnis bezüglich der optimalen Segmentanzahl. Prognosegüte erscheint uns zwar tendenziell wichtiger als Fit. Allerdings unterscheiden sich die Werte der Prognosegüte für unterschiedliche Segmentlösungen insbesondere bei der semi-logarithmischen Funktion nicht so deutlich, dass wir das Fit-Kriterium ganz vernachlässigen möchten. Wir verwenden daher für die folgenden Analysen jeweils zwei Segmentlösungen – diejenige mit dem besten Fit und diejenige mit der besten Prognosegüte. Dies erlaubt uns zugleich zu untersuchen, wie robust das Finite Mixture-Modell gegenüber einer veränderten Segmentanzahl ist.

5.2 Darstellung der Segmentlösungen auf Basis der semi-logarithmischen Zahlungsbereitschaftsfunktion

Im Folgenden wollen wir die Face-Validität und die Robustheit der Segmentlösungen untersuchen und betrachten daher, welche Zahlungsbereitschaften für unterschiedliche Segmentanzahlen ermittelt wurden. Dabei zeigen wir die Befunde für die semi-logarithmische Funktion, da sie in Bezug auf sowohl Fit als auch Prognosegüte den anderen beiden Funktionstypen überlegen ist. Bei der semi-logarithmischen Zahlungsbereitschaftsfunktion weist die 3-Segmentlösung die höchste Prognosegüte und die 7-Segmentlösung die beste Anpassung nach dem *BIC* auf, so dass diese beiden Segmentlösungen kurz vorgestellt und miteinander verglichen werden.

Tabelle 3 und *Abbildung 4* zeigen zunächst die 3-Segmentlösung. Es ergibt sich ein relativ kleines Segment von Kunden (14 %), die eine hohe maximale Zahlungsbereitschaft haben und viele Artikel abrufen wollen. Die Anzahl von maximal 225 Artikeln erscheint auf den ersten Blick sehr hoch. Diese Angabe bezieht sich jedoch auf einen Monat, so dass pro Tag weniger als 8 Artikel abgerufen würden, was durchaus realistisch ist. Es folgen zwei weitere etwa gleich große Segmente, wobei die Kunden in Segment 3 nur eine sehr geringe Zahlungsbereitschaft haben und im Schnitt weniger als maximal einen Artikel pro Tag abrufen würden. Das Segment 2 hat dagegen eine eher mittlere Zahlungsbereitschaft und würde maximal 66 Artikel pro Monat abrufen. Die Höhe der Zahlungsbereitschaft in den einzelnen Segmenten ist durchaus realistisch. Als Vergleichsbasis kann der Preis eines Abonnements der gedruckten Ausgabe von etwas weniger als 30€ im Monat herangezogen werden. Demnach existiert ein kleines Segment von Kunden, das bereit ist, für die Online-Ausgabe deutlich mehr als den Abonnement-Preis für die gedruckte Ausgabe zu bezahlen. Dies sind Kunden, die der Aktualität und jederzeitigen Verfügbarkeit von Online-Informationen offenbar einen besonderen Wert zuweisen. Der Großteil der Kunden hingegen würde für das Online-Angebot nur bedeutend weniger bezahlen.

Tabelle 3: Eigenschaften der Zahlungsbereitschaftsfunktionen bei der 3-Segmentlösung

	Parameter der Zahlungsbereitschaftsfunktion*		Sättigungsmenge (Anzahl der Artikel pro Monat)	Maximale Zahlungsbereitschaft (€ pro Monat)	Segmentgröße
	a_i	b_i			
Segment 1	225,41	5,39	225	41,86	14 %
Segment 2	65,62	3,85	66	16,99	40 %
Segment 3	18,44	2,91	18	6,33	46 %

* alle signifikant auf 1 %-Niveau

Abbildung 4: Verlauf der Zahlungsbereitschaftsfunktionen bei der 3-Segmentlösung

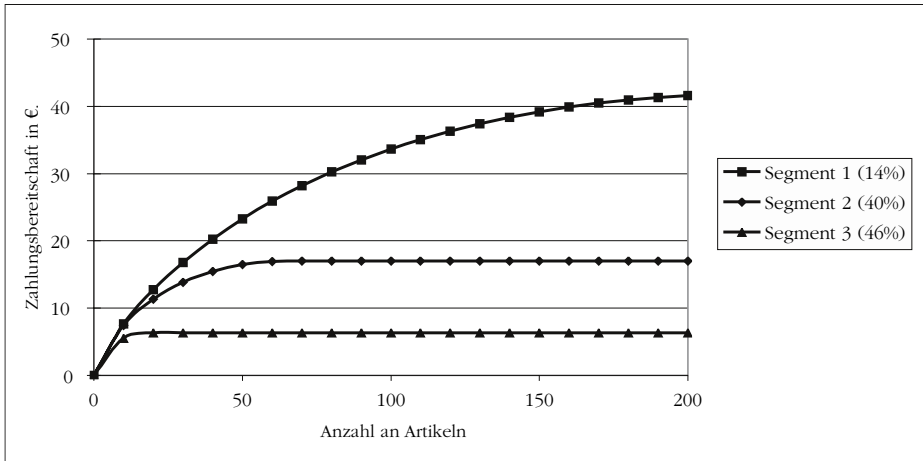


Tabelle 4 gibt einen Überblick über die 7-Segmentlösung. Interessant ist, dass die Kunden in Segment 3 eine höhere Sättigungsmenge, aber eine niedrigere maximale Zahlungsbereitschaft aufweisen als die Kunden in den Segmenten 4 und 5. Demnach befinden sich in Segment 3 Kunden mit einer zwar prinzipiell hohen Nachfrage, aber relativ geringer Zahlungsbereitschaft pro Artikel.

Tabelle 4: Eigenschaften der Zahlungsbereitschaftsfunktionen bei der 7-Segmentlösung

	Parameter der Zahlungsbereitschaftsfunktion*		Sättigungsmenge (Anzahl der Artikel pro Monat)	Maximale Zahlungsbereitschaft (€ pro Monat)	Segmentgröße
	a_i	b_i			
Segment 1	339,22	3,71	339	91,43	3 %
Segment 2	195,28	7,08	195	27,58	10 %
Segment 3	102,00	7,34	102	13,89	7 %
Segment 4	91,83	3,14	92	29,25	9 %
Segment 5	47,59	3,08	48	15,44	25 %
Segment 6	24,01	2,83	24	8,49	28 %
Segment 7	9,16	3,39	9	2,70	17 %

* alle signifikant auf 1 %-Niveau

Um die Robustheit des Finite Mixture-Ansatzes zu beurteilen, werden nun die beiden Segmentlösungen miteinander verglichen. *Tabelle 5* stellt gegenüber, wie die einzelnen Kunden bei der 3- und der 7-Segmentlösung den jeweiligen Segmenten zugeordnet werden.

Tabelle 5: Zuordnung der Kunden bei der 3- und der 7-Segmentlösung

	Segment 1	Segment 2	Segment 3
Segment 1	6	0	0
Segment 2	19	0	0
Segment 3	0	14	0
Segment 4	1	15	0
Segment 5	0	46	2
Segment 6	0	0	51
Segment 7	0	0	33

Mit Ausnahme von 3 Kunden (1,6 % der Stichprobe) erfolgt beim Übergang von einer 3- zu einer 7-Segmentlösung nur eine weitere Aufteilung der bereits bei der 3-Segmentlösung gefundenen Segmente. Dieses Ergebnis wird auch durch eine Betrachtung der Zahlungsbereitschaftsfunktionen auf individuellem Niveau bestätigt. Hierzu werden die individuellen Parameterwerte für jeden einzelnen Kunden entsprechend der 3- und der 7-Segmentlösung ermittelt⁴⁰.

⁴⁰ Die individuellen Parameterwerte der 3- und der 7-Segmentlösung werden entsprechend der a posteriori-Wahrscheinlichkeit der Segmentzugehörigkeit des jeweiligen Kunden gewichtet.

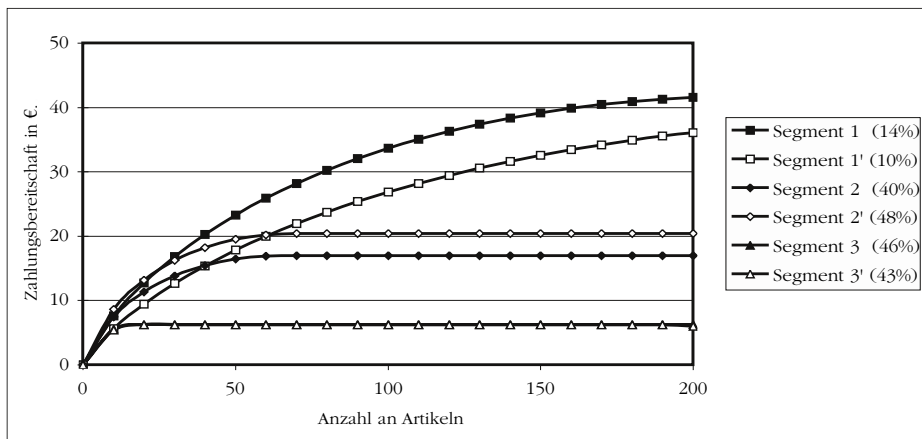
Die Korrelationen zwischen den aufgrund der 3- und der 7-Segmentlösung berechneten individuellen Sättigungsmengen und maximalen Zahlungsbereitschaften betragen nach Pearson 0,93 beziehungsweise 0,76. Dies zeigt, dass die Ergebnisse sich auch bei einer unterschiedlichen Segmentanzahl nicht substantiell verändern.

Weiterhin untersuchen wir die Robustheit der segmentspezifischen Schätzung dadurch, dass wir die Schätzung mit einem Teilsample wiederholen und die Ergebnisse beider Schätzungen vergleichen. Bei unseren Daten fällt auf, dass bei vielen Kunden die geplante zukünftige Nutzung stark von der derzeitigen Nutzung abweicht. Dies kann daran liegen, dass die Probanden nicht konsistente Antworten gegeben haben, oder aber daran, dass sie ihr Verhalten in Zukunft tatsächlich ändern wollen. Wir wollen daher untersuchen, ob wir nur mit den Kunden, die keine starke Verhaltensänderung angeben, zu anderen Ergebnissen kommen als mit dem Gesamtsample. Somit wiederholen wir die segmentspezifische Schätzung nur mit den 83 Kunden, bei denen die in *Frage A* angegebene zukünftige Nutzung bei einem kostenlosen Angebot von der in *Frage C* angegebenen und auf Monatsbasis umgerechneten derzeitigen Nutzung um weniger als 25 % abweicht. Die segmentspezifische Schätzung ist robust, wenn die Schätzung mit dem Teilsample zu vergleichbaren Ergebnissen führt wie die Schätzung mit allen Kunden.

Nach dem BIC ist wieder die 7-Segmentlösung zu wählen und die First Choice-Prognose ist mit 61,4 % wieder bei 3 Segmenten am höchsten. Um den Verlauf der segmentspezifischen Zahlungsbereitschaftsfunktionen zu vergleichen, werden in *Abbildung 5* die Zahlungsbereitschaftsfunktionen der 3-Segmentlösungen bei 83 und bei 187 Kunden dargestellt. Wie *Abbildung 5* zu entnehmen ist, verändert sich zwar die Höhe der Zahlungsbereitschaft in den einzelnen Segmenten geringfügig. Bei einer individuellen Betrachtung zeigt sich aber, dass die Struktur der Segmente gleich bleibt. So werden alle Kunden, die bei dem Modell mit 83 Kunden im Segment 1' sind, auch bei dem Modell mit 187 Kunden dem Segment 1 zugeordnet. Entsprechend werden auch alle Kunden in dem Segmenten 2' dem Segment 2 und alle Kunden in dem Segment 3' dem Segment 3 zugeordnet. Auch bei dem Vergleich der 7-Segmentlösungen wird die Robustheit der Schätzung bestätigt. Hier werden bei der 7-Segmentlösung mit 83 Kunden 97,6 % der Kunden dem entsprechenden Segment der 7-Segmentlösung bei 187 Kunden zugeordnet.

Insgesamt können daher eine hohe Face-Validität und eine hohe Robustheit der segmentspezifischen Schätzung sowohl bei unterschiedlichen Segmentanzahlen als auch bei der Schätzung mit einem Teilsample konstatiert werden.

Abbildung 5: Vergleich des Verlaufs der Zahlungsbereitschaftsfunktionen der 3-Segmenlösungen mit 83 und 187 Kunden



5.3 Vergleich von segmentspezifischer und individueller Schätzung

Im Folgenden sollen die Zahlungsbereitschaftsfunktionen, die mit Hilfe des Finite Mixture-Modells ermittelt wurden, mit den individuell geschätzten Zahlungsbereitschaftsfunktionen verglichen werden. Dies geschieht anhand von Fit und Prognosegüte. *Tabelle 6* zeigt die Fit-Werte für unterschiedliche Funktionsformen und Segmentanzahlen und *Tabelle 7* die entsprechenden Werte für die Prognosegüte⁴¹.

Tabelle 6 ist zu entnehmen, dass bei der individuellen Schätzung der größte und damit beste Log-Likelihood-Wert erreicht wird. Dies ist nicht überraschend, da bei der individuellen Schätzung durch die sehr hohe Zahl von geschätzten Parametern die höchste Flexibilität für eine gute Anpassung gegeben ist. Wird hingegen das aussagekräftigere BIC zum Vergleich der individuellen und segmentspezifischen Schätzung herangezogen, ergibt sich ein anderes Bild, da hier eine Anpassung für die Anzahl der geschätzten Parameter vorgenommen wird. Nach dem BIC ist der Fit bei der segmentspezifischen Schätzung deutlich besser als bei der individuellen Schätzung. Dies gilt für alle Funktionsformen und nicht nur für die Segmentlösung mit dem besten Fit, sondern auch für diejenige mit der besten Prognose.

⁴¹ Bei der individuellen Schätzung ergibt sich der Log-Likelihood-Wert aus der Summe der Log-Likelihood-Werte der individuellen Schätzungen über alle Kunden. Der BIC korrigiert diese Summe entsprechend für die Anzahl der geschätzten Parameter und der zur Schätzung verwendeten Beobachtungen.

Tabelle 6: Fit bei individueller und segmentspezifischer Schätzung

	Individuell			Segmentanzahl mit bestem Fit			Segmentanzahl mit bester Prognose		
	LL	BIC	# Kunden mit höherem BIC	# Segmente	LL	BIC	# Segmente	LL	BIC
Quadratisch	-3177	10192	39	6	-3901	7959	6	-3901	7959
Semi-logarithmisch	-2377	8590	135	7	-3665	7515	3	-3952	7979
Modifiziert-exponentiell	-3151	10139	13	7	-3905	7995	2	-4281	8610

Tabelle 7: Prognosegüte bei individueller und segmentspezifischer Schätzung

	Individuell		Segmentanzahl mit bestem Fit		Segmentanzahl mit bester Prognose	
	Richtige Prognose	# Segmente	Richtige Prognose	# Segmente	Richtige Prognose	# Segmente
Quadratisch	52,9 %	6	55,1 %	6	55,1 %	6
Semi-logarithmisch	53,5 %	7	53,5 %	3	58,3 %	3
Modifiziert-exponentiell	40,1 %	7	41,2 %	2	52,9 %	2

Bezüglich der Prognosegüte ist *Tabelle 7* zu entnehmen, dass auch hier die segmentspezifische Schätzung der individuellen Schätzung überlegen ist. So ist die Prognose der segmentspezifischen Schätzung in fünf von sechs Fällen höher als bei der entsprechenden individuellen Schätzung. Nur beim semi-logarithmischen Modell und 7 Segmenten ist die Prognosegüte lediglich genau so hoch wie bei individuellen Zahlungsbereitschaftsfunktionen. Die Befunde deuten also darauf hin, dass bei der individuellen Schätzung ein gewisses Over-Fitting auftritt.

Insgesamt zeigt sich, dass die segmentspezifische Schätzung der individuellen Schätzung in Bezug auf Fit und Prognose überlegen ist. Außerdem wird noch einmal die Vorteilhaftigkeit des semi-logarithmischen Funktionsverlaufs gegenüber den anderen beiden Funktionsformen bestätigt.

6 Zusammenfassung und Schlussfolgerungen

Die nichtlineare Preisbildung bietet Unternehmen in vielen Fällen die Möglichkeit, ihren Gewinn bedeutend zu steigern. Voraussetzung für ihren erfolgreichen Einsatz ist allerdings die genaue Kenntnis der Zahlungsbereitschaft der Kunden. Die Schätzung einer Zahlungsbereitschaftsfunktion auf aggregiertem Niveau ist dabei

nicht ausreichend. Da aber auch eine individuelle Schätzung von Zahlungsbereitschaftsfunktionen mit erheblichen Problemen verbunden ist, insbesondere wenn nur wenige Beobachtungen pro Kunden vorliegen, wird im vorliegenden Beitrag erstmalig ein Finite Mixture-Modell zur Ermittlung segmentspezifischer Zahlungsbereitschaftsfunktionen eingesetzt.

In einer empirischen Studie zu Zahlungsbereitschaften für aktuelle Artikel einer Online-Zeitung wird das Modell praktisch angewendet. Die wichtigsten Befunde können folgendermaßen zusammengefasst werden:

- Wird die Segmentanzahl nach Maßgabe des Fit (BIC) bestimmt, ergeben sich bei zwei von drei Funktionsformen mehr Segmente, als wenn die Prognosegüte als Kriterium herangezogen wird. Dies spricht dafür, dass bei diesen Funktionsformen bei vielen Segmenten ein gewisses Over-Fitting erfolgt.
- Die Segmentlösungen, die zum besten Fit bzw. zur besten Prognose führen, sind sich inhaltlich sehr ähnlich, was für eine hohe Robustheit des Ansatzes spricht. Die hohe Robustheit wird auch dadurch bestätigt, dass die Wiederholung der Schätzung mit einem Teilsample zu vergleichbaren Ergebnissen führt.
- Die semi-logarithmische Funktionsform erweist sich auf beiden Aggregationsniveaus hinsichtlich Fit und Prognosegüte als der quadratischen und der modifiziert-exponentiellen Funktionsform überlegen.
- Die segmentspezifische Schätzung führt zu einem besseren Fit – gemessen durch das BIC – als die individuelle Schätzung.
- Die segmentspezifische Schätzung ist der individuellen Schätzung auch bezüglich der Prognosegüte überlegen.
- Die Ergebnisse der segmentspezifischen Schätzung haben eine hohe Face-Validität, und die gute Interpretierbarkeit der Segmente bietet Managern wichtige Einsichten für ein zielgruppenorientiertes Marketing.

Unsere Befunde zeigen also, dass die segmentspezifische Schätzung von Zahlungsbereitschaftsfunktionen der individuellen Herangehensweise überlegen ist. Nach Maßgabe der Prognosegüte sollte sogar nur eher eine geringe Anzahl von Segmenten verwendet werden. Aufbauend auf den ermittelten segmentspezifischen Zahlungsbereitschaftsfunktionen können Unternehmen optimale Preise für z.B. zweiteilige Tarife bestimmen. Dabei ist natürlich zu berücksichtigen, dass wir nur einen Anwendungsfall und nur eine Methode zur Messung von Zahlungsbereitschaften untersucht haben. In weiteren Studien könnte daher auch untersucht werden, inwiefern Daten aus indirekten Befragungen in Form von Conjoint-Analysen oder Daten aus Nutzungsangeboten und tatsächliche Nutzungsdaten für die segmentspezifische Schätzung von Zahlungsbereitschaftsfunktionen geeignet sind.

Literaturverzeichnis

- Abramson, Charles et al.* (2000), Parameter Bias from Unobserved Effects in the Multinomial Logit Model of Consumer Choice, in: *Journal of Marketing Research*, Vol. 37, S. 410-426.
- Ailawadi, Kusum L./Gedenk, Karen/Neslin, Scott A.* (1999), Heterogeneity and Purchase Event Feedback in Choice Models: An Empirical Analysis with Implications for Model Building, in: *International Journal of Research in Marketing*, Vol. 16, S. 177-198.
- Allenby, Greg M./Rossi, Peter E.* (1999), Marketing Models of Consumer Heterogeneity, in: *Journal of Econometrics*, Vol. 89, S. 57-78.
- Andrews, Rick L./Ainslie, Andrew/Currim, Imran S.* (2002), An Empirical Comparison of Logit Choice Models with Discrete Versus Continuous Representations of Heterogeneity, in: *Journal of Marketing Research*, Vol. 39, S. 479-487.
- Andrews, Rick L./Ansari, Asim/Currim, Imran S.* (2002), Hierarchical Bayes Versus Finite Mixture Conjoint Analysis: A Comparison of Fit, Prediction, and Partworth Recovery, in: *Journal of Marketing Research*, Vol. 39, S. 87-98.
- Andrews, Rick L./Currim, Imran S.* (2003), A Comparison of Segment Retention Criteria for Finite Mixture Logit Models, in: *Journal of Marketing Research*, Vol. 40, S. 235-243.
- Balderjahn, Ingo* (2003), Erfassung der Preisbereitschaft, in: *Diller, Hermann/Herrmann, Andreas* (Hrsg.), *Handbuch Preispolitik*, S. 387-404.
- Ben-Akiva, Moshe et al.* (1994), Combining Revealed and Stated Preferences Data, in: *Marketing Letters*, Vol. 5, S. 335-349.
- Broun, Stephen J./Sibley, David S.* (1986), *The Theory of Public Utility Pricing*.
- Büschken, Joachim* (2003), Nicht-lineare Tarife, in: *Diller, Hermann/Herrmann, Andreas* (Hrsg.), *Handbuch Preispolitik*, S. 521-533.
- Celeux, Gilles/Soromenho, Gilda* (1996), An Entropy Criterion for Assessing the Number of Clusters in a Mixture Model, in: *Journal of Classification*, Vol. 13, S. 195-212.
- Choi, Soo-Yong/Stabl, Dale O./Whinston, Andrew B.* (1997), *The Economics of Electronic Business*.
- Clement, Michel* (2000), *Interaktives Fernsehen: Analyse und Prognose seiner Nutzung*.
- Cohen, Steven H./Ramaswamy, Venkatram* (1998), Latent Segmentation Models, in: *Marketing Research*, Vol. 10, S. 15-21.
- Danaher, Peter J.* (2002), Optimal Pricing of New Subscription Services: Analysis of a Market Experiment, in: *Marketing Science*, Vol. 21, S. 119-138.
- Diller, Hermann* (2003), Aufgabenfelder, Ziele und Entwicklungstrends der Preispolitik, in: *Diller, Hermann/Herrmann, Andreas* (Hrsg.), *Handbuch Preispolitik*, S. 3-32.
- Gensler, Sonja* (2003), Heterogenität in der Präferenzanalyse.
- Gossen, Hermann H.* (1854), *Entwicklung der Gesetze des menschlichen Verkehrs und der daraus fließenden Regeln für menschliches Handeln*.
- Green, Paul E./Srinivasan, V.* (1990), Conjoint Analysis in Marketing: New Developments with Implications for Research and Practice, in: *Journal of Marketing*, Vol. 52 (October), S. 3-19.
- Greene, William H.* (2003), *Econometric Analysis*, 5. Aufl.
- Kalish, Shlomo/Nelson, Paul* (1991), A Comparison of Ranking, Rating and Reservation Price Measurement in Conjoint Analysis, in: *Marketing Letters*, Vol. 2, S. 327-335.
- Kamakura, Wagner A./Russell, Gary J.* (1989), A Probabilistic Choice Model for Market Segmentation and Elasticity Structure, in: *Journal of Marketing Research*, Vol. 26, S. 379-390.
- Lenk, Peter J. et al.* (1996), Hierarchical Bayes Conjoint Analysis: Recovery of Partworth Heterogeneity from Reduced Experimental Designs, in: *Marketing Science*, Vol. 15, S. 173-191.
- Oren, Shumel S./Smith, Stephen A./Wilson, Robert B.* (1982), Nonlinear Pricing in Markets with Interdependent Demand, in: *Marketing Science*, Vol. 1, S. 287-313.
- Sattler, Henrik/Nitschke, Thomas* (2003), Ein empirischer Vergleich von Instrumenten zur Erhebung von Zahlungsbereitschaften, in: *zfbf*, 55. Jg., S. 364-381.

- Schulze, Timo/Nix, Jörg Steffen/Gedenk, Karen* (2003), Erlösquellen von Onlinezeitungen, in: Jahrbuch der Absatz- und Verbrauchsforschung, 49. Jg., S. 84-103.
- Skiera, Bernd* (1999), Mengenbezogene Preisdifferenzierung bei Dienstleistungen.
- Skiera, Bernd* (2001), Preisdifferenzierung, in: *Albers, Sönke et al.* (Hrsg.), Marketing mit Interaktiven Medien. Strategien zum Markterfolg, 3. Aufl., S. 267-282.
- Skiera, Bernd/Revenstorff, Inken* (1999), Auktionen als Instrument zur Erhebung von Zahlungsbereitschaften, in: *zfbf*, 51. Jg., S. 224-242.
- Tacke, Georg* (1989), Nichtlineare Preisbildung: Höhere Gewinne durch Differenzierung.
- Train, Kenneth E.* (2003), Discrete Choice Methods with Simulation.
- Wedel, Michel/Kamakura, Wagner A.* (2000), Market Segmentation. Conceptual and Methodological Foundations, 2. Aufl.
- Wedel, Michel/Kamakura, Wagner A.* (2002), Editorial: Introduction to the Special Issue on Market Segmentation, in: *International Journal of Research in Marketing*, Vol. 19, S. 181-183.
- Wertebroch, Klaus/Skiera, Bernd* (2002), Measuring Consumers' Willingness to Pay at the Point of Purchase, in: *Journal of Marketing Research*, Vol. 39, S. 228-241.
- Wilson, Robert B.* (1993), Nonlinear Pricing.
- Wyner, Gordon A./Benedetti, Lois H./Trapp, Bart M.* (1984), Measuring the Quantity and Mix of Product Demand, in: *Journal of Marketing*, Vol. 48 (Winter), S. 101-109.

Summary

Willingness-to-pay functions are an important basis for determining optimal non-linear tariffs. To date, these functions have been estimated at the individual level. However, this may result in instable parameters and over-fitting. Therefore, we propose estimating willingness-to-pay functions at the segment level. We use a finite mixture model that estimates willingness-to-pay and the segment structure simultaneously. In an empirical study we apply our model to analyze willingness-to-pay for online newspapers. We find that the segment level estimation is very robust and outperforms the estimation at the individual level in terms of fit and prediction. Furthermore, the segment level results are easy to interpret and thus yield interesting insights for managers.

JEL-Classification: C14, D49, M31.

Keywords: Finite Mixture Model; Non-Linear Pricing; Willingness-to-Pay Function.

Finite Mixture-Modell; Nichtlineare Preisbildung; Zahlungsbereitschaftsfunktion.