

# Data-Mining für die Angebotsoptimierung im Handel

Jochen Garcke

Michael Griebel

Michael Thess

## 1 Executive Summary

Der Handel ist weltweit durch gravierenden *Wettbewerbsdruck* gekennzeichnet. Deutschland gilt im Einzelhandel sogar als der wettbewerbsintensivste Markt der Welt. Um in diesem Wettbewerb zu bestehen, vertrauen die meisten Händler auf extensive Formen *ungezielten Massenmarketings*. Hierbei werden alle potentielle Kunden mit den gleichen riesigen Katalogen, ungezählten Werbebroschüren, aufdringlichen Lautsprecherdurchsagen und schrillen Bannerwerbungen bearbeitet. Im Ergebnis sind nicht nur die Kunden genervt, sondern auch die Rücklaufquoten von Marketingkampagnen seit Jahren fallend. Um dies zu vermeiden, ist eine *Individualisierung des Massenmarketings* empfehlenswert, in der Kunden auf sie zugeschnittene, individuelle Angebote erhalten. Die Aufgabe besteht darin, *dem richtigen Kunden zum richtigen Zeitpunkt zum richtigen Preis das richtige Angebot* zu unterbreiten. Dies stellt sich primär als eine mathematische Aufgabenstellung heraus, die die Bereiche Statistik, Optimierung, Analysis und Numerik betrifft. Die hierbei auftretenden Aufgabenstellungen der *Regressionsanalyse*, des *Clusterings* und der *Optimalen Steuerung* sind durch hohe Dimensionen und riesige Datenmengen gekennzeichnet und erfordern neue mathematische Konzepte und Verfahren.

Die solchen Ansätzen zugrunde liegende (semi)-automatisierte Wissensentdeckung durch Analyse großer Datenmengen hat sich in den letzten Jahren zum Anwendungs- und Forschungsgebiet des Data Mining entwickelt. Mit dem Begriff des Maschinellen Lernens wird dabei dessen algorithmischer Kern bezeichnet. Dieser Bereich war ursprünglich eher in der Informatik angesiedelt. Darüber hinaus hat die Verbindung zur Statistik von Anfang an eine wesentliche Rolle gespielt. In den letzten Jahren sind weitere mathematische Aspekte gerade in der Forschung verstärkt behandelt worden. Hier sei beispielsweise der Bereich der statistischen Lerntheorie erwähnt. Verfahren mit einem solchen Hintergrund werden mittlerweile nicht zuletzt auf Grund ihrer reichhaltigen mathematischen Unterfütterung in vielen Anwendungsbereichen erfolgreich eingesetzt.

Unter der Annahme, dass ähnliche Kundendaten für ein ähnliches Kundenverhältnis stehen, ist ein Einschätzen von neuen Kunden auf Basis des Verhaltens von bisherigen Kunden möglich. Grundlegend ist hierbei, dass viele moderne maschinelle Lernansätze die Darstellung von Funktionen über hochdimensionalen Merkmalsräumen beinhalten. Die nun mögliche gekoppelte nichtlineare Behandlung von verschiedenen Merkmalen wie beispielsweise Einkommen, Schuldenstand, Zahl der Kinder, oder Art des Autos erlauben deutlich verbesserte Schätzungen des wahrscheinlichen Kundenverhaltens. Die Approximationstheorie und die Numerik leisten deswegen bereits jetzt bei Neu- und Weiterentwicklung von maschinellen Lernverfahren einen substantiellen Beitrag. Dies wird sich in der Zukunft weiter verstärken.

Mittlerweile ist die Numerik für moderat höherdimensionale Probleme in einer ersten Stufe so weit entwickelt, dass sie auch für erste praxisrelevante Aufgaben des Data-Mining bei der Angebotsoptimierung im Handel Verwendung findet. Darüber hinaus ist jedoch insbesondere für wirklich hochdimensionale Probleme weitergehende Forschung und Entwicklung notwendig um noch mehr Merkmale und damit Dimensionen effizienter darstellen zu können. Hier erscheint es dringlich geboten speziell zugeschnittene Forschungsprogramme aufzulegen. Hierdurch könnte es mittelfristig gelingen die Methodenentwicklung so weit voranzutreiben, dass insbesondere vollständig automatisierte interaktive Systeme zur

Angebotsoptimierung zur Serienreife gebracht werden. Dies würde auch die internationale Wettbewerbsfähigkeit Deutschlands im Handel mit stärken helfen.

Dieser Artikel beschreibt die Rolle der Mathematik für die Angebotsoptimierung im Handel, insbesondere hinsichtlich der Approximationstheorie und Numerik. Dabei werden sowohl der aktuelle Stand und bisherige Erfolge, als auch neue Entwicklungen und Herausforderungen dargelegt.

## 2 Angebotsoptimierung im Handel: Übersicht & Status Quo

Im Handel ist die Dynamik des Marktes besonders groß. Das liegt zum einen daran, dass die Produkte weitgehend vergleichbar sind, da alle Händler insbesondere über den Großhandel Zugang zu einem weitgehend gleichen Sortiment haben. Zum anderen hat das Internet zahlreiche neue Geschäftsmodelle hervorgebracht und damit die Internationalisierung und den Wettbewerbsdruck im Handel drastisch verschärft. Insgesamt liegen umfassende – wenngleich auch zumeist anonyme – Daten über das Verhalten von Kunden vor, die bei der Optimierung von Angeboten genutzt werden können.

Die Aufgabenstellungen in der Angebotsoptimierung im Handel lassen sich im Wesentlichen in folgende Teilgebiete untergliedern:

- *Kampagnenoptimierung* (d.h. Auswahl der Zielgruppen und -personen),
- *Cross- und Up-Selling* (d.h. Zusatzverkäufe an Kunden),
- *Sortimentsgestaltung* (d.h. Produktangebot und -kategorien),
- *Preisoptimierung* (d.h. Optimierung der Produktpreise und Promotions).

Seit einigen Jahren setzen Händler zur Untersuchung des Kundenverhaltens zunehmend mathematische Verfahren in verschiedenen Bereichen des Marketings ein, doch ist deren Nutzung noch zaghaf und sowohl von der Branche als auch der Marketingaktivität abhängig. Während im *E-Business* eine beachtliche Durchdringung von – allerdings oft noch unausgereiften - Verfahren zu verzeichnen ist, wird im *Versandhandel* Mathematik hauptsächlich zur Optimierung von *Mailing-Kampagnen* eingesetzt, also der Auswahl von Kunden mit hoher Reaktionswahrscheinlichkeit auf spezielle Angebote. Schlusslicht ist schließlich der *stationäre Handel*; doch eröffnet gerade die hier stattfindende technologische Revolution der interaktiven digitalen Einkaufshilfen neue interessante Möglichkeiten für die Entwicklung und den Einsatz neuer mathematischer Verfahren für die Angebotsoptimierung.

Günstig für die Verwendung mathematischer Verfahren ist die Tatsache, dass der Handel durch ein hohes Maß an Kundeninteraktion geprägt ist. Somit liegen umfassende - wenngleich zumeist anonyme - Daten über das Kundenverhalten vor. Mathematik hat sich hier zunächst in einigen klassischen Data-Mining-Feldern bewährt. So werden für die Mailingoptimierung Klassifikationsverfahren auf breiter Front eingesetzt. Zunehmend erfolgreich ist auch die Nutzung von Clusterverfahren für die Kundensegmentierung bei der Erstellung von Themenkatalogen. Andere Bereiche wie Echtzeitanalyse und -angebote setzen bisher zumeist nur einfachste Techniken ein. Schließlich ist im strategischen Bereich des *Category Management*, also für Aufgaben der Sortiments- und Preisoptimierung, der Einsatz moderner mathematischer Instrumente noch die Ausnahme. Gerade hier aber liegt – in Kombination mit Echtzeitanalysen der Optimalen Steuerung – ein wichtiges zukünftiges Betätigungsfeld für die interdisziplinäre Zusammenarbeit von Betriebswirten, Informatikern und Mathematikern. Weitere Informationen zu Data-Mining Methoden im Handel, Marketing und Customer Relationship Management findet man etwa in [Berry/Linoff 2004] oder [Schoenrade 2007].

Im Folgenden wollen wir exemplarisch auf die ersten beiden Aufgabenstellungen, d.h. die Kampagnenoptimierung und das Cross- und Up-Selling, und dort vorhandene Erfolgsgeschichten bei der Nutzung mathematischer Verfahren näher eingehen.

## 2.1 Kampagnenoptimierung

Die Kampagnenoptimierung ist hinsichtlich der Nutzung der Mathematik am weitesten fortgeschritten. Dabei geht es im wesentlichen darum, Werbekampagnen zielgruppengenau umzusetzen. Dies umfasst die Definition der Ziele und des Ablaufs der Kampagne sowie deren Auswertung. Dabei wird zwischen Zielgruppen (Segmentierung) und Zielpersonen (Individualisierung) unterschieden. Während also Zielgruppen streng anhand eines oder mehrerer Merkmale definiert sind (beispielsweise weiblich), basieren Zielpersonen auf individuellen Einschätzungen in Form einer numerischen Bewertung, dem sogenannten Score. Ein Beispiel für die Segmentierung ist die Einschränkung des Versands eines Sport-Katalogs auf Sport-affine Kunden, die bereits Sportartikel gekauft haben. Im Fall der Individualisierung wird hingegen für jeden einzelnen Kunden geprüft, ob er für *diesen* Sport-Katalog affin ist, unabhängig davon, ob er zum Segment der Sport-affinen Kunden gehört. Für die Segmentierung werden zumeist Clusteranalysen verwendet, während für die Individualisierung meist Klassifikations- und Regressionsverfahren eingesetzt werden. Dies wollen wir im Folgenden am Beispiel der Mailingoptimierung ausführlicher diskutieren.

### Erfolgsgeschichte: Mailingoptimierung

Beim Versand von Katalogen werden derzeit oft noch alle Kunden einer Adressliste angeschrieben, unabhängig davon wie hoch ihre Reagierwahrscheinlichkeit ist. Man spricht davon, dass die Kataloge unpersonalisiert versendet werden. Die Kosten für eine solche Mailingwerbemaßnahme setzen sich vereinfacht dargestellt aus den Fixkosten (primär Katalogerstellung und -druck), sowie den Kosten für den Mailingversand (M), das Nachfassen (NF) und die telefonische Bestellannahme (IP) zusammen. In Tabelle 1 ist die Gewinnrechnung für eine exemplarische Mailingaktion mit 100.000 Empfängern, 1% Reagierwahrscheinlichkeit und 500 EUR Einnahmen je Reagierer dargestellt. Der Einfachheit halber wird hierbei der Rohertrag mit dem Gewinn gleichgesetzt.

Fixkosten:	50.000 EUR	=	50.000 EUR
Kosten für M:	100.000 * 1,50 EUR	=	150.000 EUR
Kosten für NF:	98.500 * 1,50 EUR	=	147.750 EUR
Kosten für IP:	2.500 * 5 EUR	=	12.500 EUR
Gesamtkosten:		=	360.250 EUR
Einnahmen:	1.000 * 500 EUR	=	500.000 EUR
Gewinn:		=	<u>139.750 EUR</u>
Break-Even-Point:	721 Reagierer		

Tabelle 1: Gewinnrechnung für eine klassische Mailingkampagne.

Um nun die Profitabilität des Mailings zu erhöhen, sollen durch den Einsatz von Data Mining nur noch die Kunden mit der höchsten Reagierwahrscheinlichkeit angeschrieben werden. Der Ablauf einer solchen optimierten Mailingaktion ist in Abbildung 1 schematisch dargestellt. Dazu werden historische Mailings für den Katalog basierend auf dem vorhandenen Kundenstammdaten analysiert, daraus Modelle zur Erstellung der Kundenprofile für die Reagierwahrscheinlichkeit maschinell gelernt und diese dann auf die potentiell anzuschreibenden 100.000 Kunden angewendet. Im Ergebnis erhält man eine Scoring-Liste, aus der schließlich die 40.000 Kunden mit den höchsten Scores (d.h. der potentiell größten Reagierwahrscheinlichkeit) ausgewählt und angeschrieben werden. Bei fachgerechter

Umsetzung eines solchen Data Mining Ansatzes kann dabei mehr als eine Verdopplung der Antwortrate erreicht werden, hier seien es 950 Reagierer (ca. 2,4%).

Fixkosten:	50.000 EUR	=	50.000 EUR
Kosten für M:	40.000 * 1,50 EUR	=	60.000 EUR
Kosten für NF:	38.600 * 1,50 EUR	=	57.900 EUR
Kosten für IP:	2.100 * 5 EUR	=	10.500 EUR
<b>Gesamtkosten:</b>		=	<b>178.400 EUR</b>
<b>Einnahmen:</b>	950 * 500 EUR	=	<b>475.000 EUR</b>
<b>Gewinn:</b>		=	<b><u>296.600 EUR</u></b>
Break-Even-Point: bereits nach 357 Reagierern!			

Tabelle 2: Gewinnrechnung für eine optimierte Mailingkampagne.

Die Gewinnrechnung in Tabelle 2 zeigt, dass im Vergleich zur klassischen Mailingkampagne der Gewinn trotz weniger Einnahmen im Ergebnis von ca. 140.000 EUR auf ca. 297.000 EUR steigt. Darüber hinaus werden Kunden nicht mehr so stark mit Katalogen überflutet was ein weiteres Plus ist. Solche personalisierten Mailingkampagnen werden mittlerweile von etlichen Versandhändlern erfolgreich eingesetzt.




Abbildung 1: Ablauf einer optimierten Mailingkampagne .

Die Optimierung einer Mailingkampagne basiert dabei auf der Klassifikation von Kunden mittels eines Modells, das aus vorhandenen Kundendaten gelernt wurde. Ein Beispiel für ein solches Klassifikationsverfahren ist in Abbildung 2 genauer beschrieben. Mathematisch basiert es auf der approximativen Rekonstruktion und Auswertung von hochdimensionalen Funktionen über einem Zustandsraum von Kundenattributen. Dabei kann die Methode der dünnen Gitter [Bungartz/Griebel 2004, Zenger 1991] zur Approximation hochdimensionaler

Funktionen eingesetzt werden. Alternativen sind hier kernbasierte Ansätze mit beispielsweise radialen Basisfunktionen oder neuronalen Netzen. Darüber hinaus existieren viele weitere Techniken zur Klassifikation [Hastie/Tibshirani/Friedman 2001].

### Klassifikation und Regression mit Regularisierungsnetzwerken

Das Problem der Optimierung einer Mailingkampagne stellt ein *Klassifikationsproblem* dar, das mathematisch als ein *hochdimensionales Approximationsproblem* formuliert werden kann.

Dabei beschreibt  $T = \{x_i \in \mathfrak{R}^d\}_{i=1}^M$  eine Menge von  $M$  Kunden, welche bereits an einer vorhergehenden Mailingkampagne teilgenommen haben und durch  $d$  Merkmale wie Geschlecht, Alter und Beruf gekennzeichnet sind. Weiterhin sei für jeden Kunden der Wert des Zielmerkmals  $y_i \in \{-1; +1\}$  bekannt, d.h. ob der Kunde auf die Kampagne reagiert hat oder nicht. Ziel ist es aus den vorliegenden Daten eine Funktion zu rekonstruieren, die den wahrscheinlichen Zusammenhang zwischen den Merkmalen und dem Kundenverhalten wiedergibt und somit Vorhersagen für neue Kunden ermöglicht. Dies ist exemplarisch in zwei Dimensionen im nebenstehenden Bild dargestellt.

Der Lösungsprozess gliedert sich in zwei Phasen: Zunächst wird in der *Trainingsphase* aus den historischen Daten  $T$  die Klassifikationsfunktion  $f$  berechnet, welche den Zusammenhang zwischen Kundenmerkmalen und Reaktionswahrscheinlichkeit beschreibt.

Um die Klassifikationsfunktion  $f$  zu berechnen, wird ein Minimierungsproblem

$$\min_{f \in V} R(f)$$


in einem geeigneten Funktionenraum  $V$  gelöst, wobei  $R$  ein Operator ist, der  $V \rightarrow \mathfrak{R}$  abbildet. Für die anspruchvollsten derzeitigen Verfahren kann dieser mit Hilfe des sogenannten Regularisierungsnetzwerk-Ansatzes [Girosi/Jones/Poggio 1995] aufgeschrieben werden:

$$R(f) = \frac{1}{M} \sum_{i=1}^M C(f(x_i), y_i) + \lambda \varphi(f)$$

mit  $C(x, y)$ , dem Fehlerfunktional zwischen Daten und

der Klassifikationsfunktion, z.B.  $C(x, y) = (x - y)^2$ ,

$\varphi(f)$  dem Regularisierungsoperator, der Prior-Annahmen über  $f$  ausdrückt, z.B.  $\varphi(f) = \|\nabla f\|^2$ , und dem Regularisierungsparameter  $\lambda$ .



Klassifikation mittels einer Dünngitterfunktion.

Bei der eigentlichen numerischen Berechnung wird nun eine diskrete Approximation der Funktion  $f$  bestimmt. Auf Grund der hohen Dimensionen lässt sich hier beispielsweise die **Methode der dünnen Gitter** [Bungartz/Griebel 2004, Zenger 1991] verwenden. Dieser Ansatz weist zudem nur eine lineare Skalierung mit der Zahl der Daten auf, für Details siehe [Garcke/Griebel/Thess 2001]. Die Methode der dünnen Gitter bricht den Fluch der Dimensionen konventioneller gitterbasierter Diskretisierungsansätze durch die Verwendung einer abgeschnittenen Tensorprodukt-Multiskalenbasis. Die Anzahl der benötigten Gitterpunkte wächst zwar weiterhin noch exponentiell mit der Zahl der Dimensionen, allerdings mit einer im Vergleich sehr viel kleineren Basis.

In der *Applikationsphase* wird nun die Klassifikationsfunktion  $f$  auf die Daten neuer Kunden angewendet. Dabei liefert  $f$  den *Score* – je höher dieser ist, desto wahrscheinlicher gehört der Kunde der Reagiererkategorie an. Daher werden nach der Anwendung der Klassifikators auf neue Kundendaten die zugehörigen Kunden nach ihrem Scorewert absteigend sortiert und danach die  $n$  ersten Kunden für die Kampagne ausgewählt. Für die Wahl der richtigen *Ausstattungs-dichte*  $n$  spielen Kosten für die Kampagne und erwarteter Kundenumsatz eine Rolle.

Heutzutage werden für Mailingkampagnen oft bis zu einige Millionen Kunden analysiert um eine möglichst gute Auswahl zu treffen. Der Einsatz von Klassifikationsverfahren zur Mailingoptimierung bringt dabei bis zu 100% höhere Erträge, wobei hier zu beachten ist, dass die Antwortraten beim herkömmlichen Mailing typischerweise unter 1% liegen.

Abbildung 2: Dünn-Gitter-Klassifikation für die Optimierung von Mailingkampagnen.

## 2.2 Cross- und Up-Selling

Nun betrachten wir ein zweites Beispiel für die Angebotsoptimierung im Handel, das Cross- und Up-Selling. Jeder Verkäufer weiß, dass es leichter ist einem Bestandskunden zusätzliche Produkte zu verkaufen als neue Kunden zu gewinnen. Genau diese zentrale Thematik der Kundenwertsteigerung adressiert das so genannte Cross- und Up-Selling. Die Aufgabe besteht darin, Kunden, die durch Interesse oder Kauf Produktpräferenzen signalisiert haben, ergänzende Produkte anzubieten (Cross-Selling) bzw. zum Kauf höherwertiger Substitutionsprodukte anzuregen (Up-Selling). Neben der Umsatzsteigerung auf der Seite des Händlers führt gutes Cross-Selling auf der Seite des Kunden zu größerer Zufriedenheit. Indem der Kunde gezielt die ihn interessierenden Angebote erhält, spart er Zeit und kann lästiges Suchen vermeiden.

Cross-Selling beginnt bereits mit der Disposition der Produkte im Markt. Dies ist traditionell Aufgabe des Disponenten. Seit einigen Jahren werden hier aber auch mathematische Verfahren verwendet. Dabei werden vorrangig Methoden der *Clusteranalyse* eingesetzt; besonders die *Warenkorbanalyse* erfreut sich steigender Beliebtheit. Diese Verfahren arbeiten *transaktions-basiert* und analysieren z.B. die Kassendaten auf Verbundkäufe. Häufig zusammen gekaufte Produkte werden dann auch auf der Fläche zusammen plaziert. Alternativ dazu werden *content-basierte* Methoden eingesetzt, die Produkte und Kategorien über deren Attribute analysieren (Farbe, Beschreibung, *Klang*, etc.) und daraus Produktcluster finden.

Neben der Disposition von Produkten hat das E-Business eine völlig neue Art des aktiven und automatisierten Cross-Sellings eingeführt: *Empfehlungsmaschinen* (*Recommendation Engines*) und *Berater* (*Avatare*) weisen den Kunden auf ergänzende Produkte und Services hin. Vorreiter war hier der Onlineshop *Amazon.com*. Kunden werden gezielt während des Einkaufs und des damit verbundenen Warenkorbprozesses auf Ansichtsseiten mit passenden Produkten hingewiesen („Kunden, die dieses Produkt gekauft haben, kauften auch...“). Wenn auch die frühen Algorithmen von *Amazon.com* auf einfacher Korrelationsanalyse basierten, so haben sie doch den modernen Empfehlungsmaschinen und adaptiven Analysesystemen den Weg gewiesen. Im E-Business haben sich Empfehlungsmaschinen mittlerweile etabliert und werden in verallgemeinerter Form für vielfältigste Anwendungen wie Suchen, Interessenabgleich, persönliche Seiten und dynamische Navigationsgestaltung benutzt. Zugleich ist dies zum Thema umfangreicher universitärer Forschung geworden und es gibt derzeit eine Vielzahl von Veröffentlichungen hierzu. Die aktuellen Methoden reichen von Clustering und Textanalyse, über Bayesche Netze und neuronale Netze bis hin zu komplexen hybriden Lösungen. Wenn auch das mathematische Niveau vieler Ansätze noch unbefriedigend ist, so kann es dennoch keinen Zweifel daran geben, dass hier momentan ein spannendes Forschungsthema für die Angewandte Mathematik entsteht. Dies wollen wir im Folgenden am Beispiel der dynamischen Programmierung bei Produktvorschlägen ausführlicher diskutieren.

### Erfolgsgeschichte: Produktvorschläge

Empfehlungsmaschinen nehmen heute einen wichtigen Platz in der automatisierten Kundenkommunikation ein. Eine Empfehlungsmaschine bietet basierend auf dem Klick- und Kaufverhalten der Kunden automatisch passende Produktvorschläge an. Hierbei lernt die Empfehlungsmaschine online direkt aus der Kundeninteraktion. Das klassische Beispiel sind Online-Shops. Empfehlungsmaschinen erhöhen den Umsatz um bis zu 20% und führen zu größerer Kundenzufriedenheit. Doch ist damit ihr Potential noch lange nicht erschöpft: Moderne Empfehlungsmaschinen variieren mittlerweile Design, Sortiment und Preise abhängig von den Nutzern und erschließen völlig neue Möglichkeiten der Personalisierung.

## Produktempfehlung als Reinforcement Learning Problem

Das Problem der adaptiven Produktempfehlungen kann als *Reinforcement Learning* Problem dargestellt werden, das mathematisch auf der Theorie der Optimalen Steuerung basiert. Dazu gibt es neben theoretischen Ansätzen bereits auch eine erfolgreiche kommerzielle Umsetzung.

Im Reinforcement Learning wird eine Menge von Zuständen  $s$  betrachtet. In jedem Zustand kann eine Aktion  $a$  aus einer Menge von Aktionen ausgewählt werden, die zu einem neuen Zustand  $s'$  mit der skalaren *Belohnung*  $r$  führt. Die Summe aller Belohnungen soll hierbei über eine *Episode* maximiert werden. Im einfachsten Fall einer Empfehlungsmaschine entsprechen die Zustände den angeschauten Produkten, die Aktionen den empfohlenen Produkten und die Belohnungen den Produktpreisen im Falle des Kaufs.

Sofern nun die sogenannte Markov-Eigenschaft erfüllt ist, kann zu einem *Markov Decision Prozess* übergegangen werden, der durch die diskrete *Bellman-Gleichung* beschrieben wird:

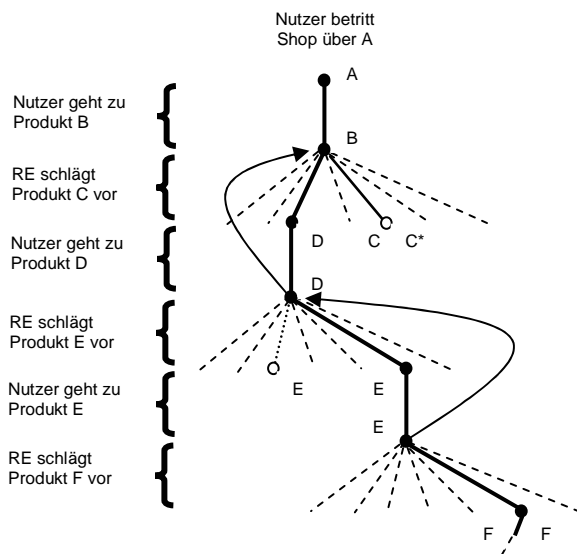
$$V^\pi(s) = \sum_a \pi(s, a) \sum_{s'} P_{ss'}^a \left[ R_{ss'}^a + \gamma V^\pi(s') \right]$$

mit  $P_{ss'}^a$ : Übergangswahrscheinlichkeiten

$R_{ss'}^a$ : Übergangsbewohnungen

$\gamma$ : Discountrate.

Hierbei ist  $V^\pi(s)$  eine *Zustandswertfunktion*, die jedem Zustand  $s$  die erwartete kumulierte Belohnung über den Rest der Episode zuordnet. Es wird nun die optimale *Policy*  $\pi(s, a)^*$  gesucht, welche die stochastische Wahl der richtigen Aktion  $a$  im Zustand  $s$  beschreibt. Somit liefert  $\pi(s, a)^*$  die optimalen Empfehlungen.



*Interpretation der Kundeninteraktion als Wechselspiel zwischen Empfehlungsmaschine und Kunde.*

Zur Berechnung der optimalen Policy werden verallgemeinerte Verfahren der Optimalen Steuerung benutzt, insbesondere *Policy Iteration* und *Value Iteration* Verfahren.

Da in vielen Applikationen die Zustandswertfunktion  $V^\pi(s)$  aufgrund der Vielzahl an Zuständen nicht mehr tabular erfasst werden kann, wird sie in diesen Fällen über Regressionsansätze approximiert. Hier spielt wiederum die effiziente und approximative Darstellung von hochdimensionalen Funktionen eine entscheidende Rolle. Es ist weiterhin zu unterscheiden zwischen RL-Verfahren, die ein Modell kennen und nutzen, d.h. die Übergangswahrscheinlichkeiten  $P_{ss'}^a$  kennen (z.B. über Regression); hier können die klassischen Methoden der Optimalen Steuerung benutzt werden, welche die Berechnung für Dutzende von Millionen Zuständen in wenigen Stunden erlauben. Auf der anderen Seite stehen modellfreie Verfahren – insbesondere Monte Carlo und TD-Verfahren – die zum reinen Online-Lernen genutzt werden.

Abbildung 3: Dynamische Programmierung für Kundeninteraktion.

Im stationären Handel schien der Einsatz automatischer Empfehlungssysteme bislang technisch unmöglich, obwohl das Interesse dafür durchaus vorhanden ist, da die meisten Kaufentscheidungen erst vor Ort fallen. Doch bahnt sich gerade hier ein grundlegender Wandel an. Mittlerweile stehen in ersten Shopping Malls in den USA elektronische Geräte wie der Personal Shopping Assistant (PSA) zur Verfügung, ein persönlicher Einkaufsberater, der auf dem Einkaufswagen platziert wird. Kunden können nun Produkte aus dem Regal an den Scanner des PSA halten und bekommen neben detaillierten Informationen zum Produkt passende Produktempfehlungen (Abbildung 4). Diese Systeme ermöglichen erstmals eine vollständig automatisierte Interaktion mit dem Kunden im Geschäft, etwa in Form von Echtzeit-Coupons auf dem Kassenschein abhängig von Einkauf oder in Form von Preisänderungen in Echtzeit mittels elektronischer Preisschilder. Damit ergibt sich ein interessantes und weites neues Feld für automatische Analysesysteme sowie Empfehlungsmaschinen zur Bereitstellung von Produktvorschlägen und Preisoptimierung.



Abbildung 4: Produktempfehlungen im Personal Shopping Assistant.

Eine moderne mathematische Formulierung solcher adaptiven Produktempfehlungen mittels Ansätzen aus dem Gebiet der stochastischen optimalen Steuerung wird in Abbildung 3 genauer diskutiert. Dabei wird eine Reinforcement Learning Formulierung verwendet, die auf eine diskrete Hamilton-Jacobi Bellmann Gleichung führt. Wiederum treten hochdimensionale Zustandsräume auf für deren Behandlung bisher neuronale Netze, kernbasierte Ansätze oder Entscheidungsbäume verwendet werden [Sutton/Barto 1998]. Hier gibt es zudem wieder die Möglichkeit die Methode der dünnen Gitter einzusetzen [Munos2000].

### 3 Ausblick

Ein wichtiger Aspekt von erfolgreichen Data Mining Verfahren wie sie im Handel auftreten, ist die approximative und effiziente Darstellung von hochdimensionalen Funktionen. Hier sind gerade im letzten Jahrzehnt Fortschritte erzielt worden um den so genannten Fluch der Dimension [Bellman 1957] zu brechen, d.h. Verfahren zu entwickeln und zu analysieren, deren Komplexität nicht exponentiell mit der Dimension des zu Grunde liegenden Raums skaliert. Neben der bereits erwähnten Methode der dünnen Gitter [Bungartz/Griebel 2004] seien hierzu Niedrig-Rang Tensorproduktansätze [Beylkin/Mohlenkamp 2005, Börm/Grasedyck/Hackbusch 2003] sowie diverse nichtlineare Approximationsverfahren wie etwa neuronale Netze, Kernmethoden und LASSO erwähnt. Jeder Ansatz hat dabei seine eigene spezifische Annahme an die zu approximierende Funktion und die Daten damit der Fluch der Dimension auch wirklich umgangen werden kann. Hier ist weitere Forschungsarbeit im Bereich der Numerik hochdimensionaler Probleme erforderlich um die Effizienz der Verfahren voranzubringen und ihren Einsatzbereich, insbesondere für Probleme der Angebotsoptimierung im Handel, besser zu verstehen.

Eine grundlegende Weiterentwicklung der hier dargestellten Angebotsoptimierung im Handel besteht darin in Zukunft den kompletten *Kundenlebenszyklus* zu managen. Bisher werden Marketingaktionen wie Kampagnen, Cross- und Upselling sowie Sortiments- und Preisoptimierung zumeist isoliert betrachtet. Diese Maßnahmen zur Ertragssteigerung erweisen sich dabei oft als nicht nachhaltig. Im Idealfall soll über alle 5 Dimensionen (Kunde, Inhalt, Zeit, Werbeform, Preis) des Eingangsproblems eine Optimierung stattfinden mit dem



Ziel den Kundenwert über den gesamten Kundenlebenszyklus zu maximieren. Auf mathematischer Seite kann dabei ein Beitrag bei der Quantifizierung und Optimierung des Wertes eines jeden Kunden erfolgen. So kann eine Ertragsrechnung auf Kundenbasis stattfinden, die mit Methoden der stochastischen optimalen Kontrolle beziehungsweise hier in der Form des Reinforcement Learning im Hinblick auf den Ertrag pro Kunden maximiert wird. Solche erweiterten Optimierungsprobleme erfordern wiederum die Darstellung von Funktionen (dem Kundenwert) über einem hochdimensionalen Raum (dem Zustandsraum). Der Zustandsraum gibt hier den Kunden, die Produkte sowie deren Preise und den Zeitpunkt und die Form der Werbeaktionen wieder. Das Unternehmen kann Aktionen durchführen, wie zu bestimmten Zeiten geeignete Werbung zu passenden Produkten mit attraktiven Preisen zu schalten. Der Erfolg misst sich im erzielten Kundenwert. Interessant für die Zukunft sind dabei die Entwicklung neuer adaptiver Regressionsverfahren, etwa für die Echtzeitoptimierung von Kampagnen, sowie die optimale Steuerung, etwa für die Umsatzoptimierung über dem gesamten Kundenlebenszyklus. Beide Fragestellungen müssen dabei in hochdimensionalen Approximationsräumen betrachtet und gelöst werden.

Abschließend seien kritische Bemerkungen zur kommerziellen Nutzung von personenbezogenen Daten und Wohnumfeldinformationen erlaubt. Banken, Versicherungen, und, wie dargestellt zunehmend auch der Einzelhandel, arbeiten in immer stärkerem Maße mit Kundenprofilen und Risikogruppen. Gute Konditionen gibt es dabei nur für gute Kunden. Verstärkt wird dieser Trend durch immer umfassendere Datenbanken, durch Kundenkarten und einen schwunghaften Handel mit Verbraucherdaten. Es gibt Untersuchungen die vor einer zunehmend pauschalen Beurteilung von Verbrauchergruppen warnen. Es besteht die Gefahr, dass viele Personengruppen gewisse Dienstleistungen oder Produkte nicht in Anspruch nehmen können, weil sie von Unternehmen, die ein Data Mining-Modell in ihren Geschäftsprozess integriert haben, auf Grund der Datenlage automatisch gesperrt werden. Kunden, die abhängig von ihrem Wohnort erhöhte Kreditzinsen zahlen müssen, Versicherte, die pauschal auf Grund von Erkrankungen keine Berufsunfähigkeitsversicherung erhalten oder Personen, die wegen verspäteter Bezahlung der Handyrechnung und resultierendem negativen SCHUFA-Eintrag keine Wohnung bekommen sind aktuelle Beispiele. Um solchen Fehlentwicklungen zu begegnen ist auf Dauer eine hohe Transparenz der Data-Mining Lösungen möglichst mit Erklärungskomponenten notwendig („warum bekommen ich das empfohlen, wie kam die Empfehlung konkret zu Stande?“). Auch sind existierende Datenschutzgesetze unter diesen Aspekten vom Gesetzgeber kritisch zu hinterfragen und gegebenenfalls anzupassen.

## **Visionen und Handlungsempfehlungen**

Es ist in der Zukunft durchaus vorstellbar, dass sich Data-Mining Verfahren in Form von Analysesystemen sowie Empfehlungsmaschinen zur Bereitstellung von Produktvorschlägen und Preisoptimierung für eine vollständig automatisierte Interaktion mit dem Kunden im Geschäft durchsetzen werden. Der Schwerpunkt wird hierbei auf Interaktivität und Adaptivität liegen, wobei Online-Learning eine wichtige Rolle spielen wird. Ein weiterer Trend ist sicherlich den komplettern Kundenlebenszyklus (Customer Life Cycle) zu managen und dabei den Kundenwert (Lifetime value) für ein Unternehmen über den gesamten Kundenlebenszyklus maximieren. Technisch wäre dies schon heute weitgehend machbar, alle Informationen und Daten des Kundenlebenszyklus sind prinzipiell in den Unternehmen vorhanden, werden jedoch aktuell oft noch nicht genutzt, da sie meist IT-technisch noch nicht direkt aufbereitet zur Verfügung stehen. Weiterhin sollte auch der oben erwähnte Echtzeitansatz nicht mehr allzu schwierig umsetzbar sein, da die Unternehmen aktuell in Richtung Service-orientierter Architektur (SOA) gehen. Insgesamt sind somit die technischen Voraussetzungen für den Einsatz von Data-Mining Methoden für die Angebotsoptimierung im Handel gegeben.

Notwendig ist jedoch noch die mathematische Weiterentwicklung von interaktiven, adaptiven Online-Learning Methoden. Bisher existieren hier meist nur heuristische ad hoc Ansätze.

Eine moderne mathematische Formulierung solcher adaptiven Produktempfehlungen kann mittels Ansätzen aus dem Gebiet der stochastischen optimalen Steuerung über eine Reinforcement Learning Formulierung gelingen, die auf eine diskrete Hamilton-Jacobi Bellmann Gleichung führt. Für deren effiziente und schnelle Lösung sind jedoch neue Algorithmen und Verfahren insbesondere für den hochdimensionalen Fall erst zu entwickeln beziehungsweise bestehende Methoden substantiell zu verbessern. Dies kann nur in interdisziplinärer Zusammenarbeit zwischen Mathematik, Informatik und Anwendern geschehen. Dazu ist jedoch ein spezifisches Förderungsinstrument zu schaffen, das es interessierten Gruppen ermöglicht in diesem Bereich aktiver zu werden. Mit dem Schwerpunktprogramm 1324 „Mathematische Methoden zur Extraktion quantifizierbarer Informationen aus komplexen Systemen“ der Deutschen Forschungsgemeinschaft sowie dem Programm „Mathematik für Innovationen in Industrie und Dienstleistungen“ des BMBF wurden aktuell sowohl auf praktischer als auch theoretischer Seite wichtige erste Schritte gemacht, die es in der Zukunft zu verstetigen und auszubauen gilt. Hierzu ist aber neben der institutionellen Förderung auch der finanzielle Einsatz der Industrie und des Handels gefragt, der leider noch sehr zögerlich und wenig risikofreudig ist.

#### **4 Literatur**

Bellman 1957

R. Bellman, Dynamic Programming, Princeton Univ. Press, 1957.

Berry/Linoff 2004

Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management, Wiley and Sons, 2004.

Beylkin/Mohlenkamp 2005

G. Beylkin und M. J. Mohlenkamp, Algorithms for Numerical Analysis in High Dimensions, SIAM J. Sci. Comput., 26:2133-2159, 2005.

Börm/Grasedyck/Hackbusch 2003

S. Börm, L. Grasedyck und W. Hackbusch, Hierarchical Matrices, Lecture Note 21, Max Planck Institute for Mathematics in the Sciences, Leipzig, 2003.

Bungartz/Griebel 2004

H.J. Bungartz und M. Griebel, Sparse Grids, Acta Numerica, 13:147-269, 2004.

Garcke/Griebel/Thess 2001

J. Garcke, M. Griebel und M. Thess, Data Mining with Sparse Grids, Computing, 67:225-253, 2001.

Girosi/Jones/Poggio 1995

F. Girosi, M. Jones und T. Poggio, Regularization Theory and Neural Network Architectures, Neural Computation, 7:219-265, 1995.

Hastie/Tibshirani/Friedman 2001

T. Hastie, R. Tibshirani und J. Friedman, The Elements of Statistical Learning, Springer, 2001.

Munos 2000

R. Munos, A Study of Reinforcement Learning in the Continuous Case by the Means of Viscosity Solutions, Machine Learning, 40(3):265--299, 2000.

Schoenrade 2007

B. Schoenrade, Data Mining im Marketing: Status Quo und Entwicklungspotential, Vdm Verlag, Dr. Müller, 2007.

Sutton/Barto 1998

R.S. Sutton and A.G. Barto, Reinforcement Learning: An Introduction, MIT Press, 1998.

Zenger 1991

C. Zenger, Sparse Grids, In Parallel Algorithms for Partial Differential Equations, Proceedings of the Sixth GAMM-Seminar, Kiel, 1990, volume 31, Notes on Num. Fluid Mech., Vieweg-Verlag, 241-251, 1991.