

Item-based Collaborative Filtering aus der Perspektive des Customer Relationship Managements

Seminararbeit

**aus Informationswirtschaft zum Thema:
“Recommender Systems – Grundlagen und Anwendungen”**

unter der Leitung von
o. Univ. Prof. Dkfm. Dr. Wolfgang H. Janko
und Univ.-Ass. Dr. Michael Hahsler

verfasst an der
Abteilung für Informationswirtschaft
Wirtschaftsuniversität Wien, UZA II - 3.Ebene
Augasse 2-6, A-1090 Wien, Austria



von

Jasna Tusek

E-Mail: jasna.tusek@wu-wien.ac.at
Homepage: <http://www.wu-wien.ac.at/usr/h99a/h9950128/>

Wien, 2005-05-25

Item-based Collaborative Filtering aus der Perspektive des Customer Relationship Managements

Item-based Collaborative Filtering from the perspective of Customer Relationship Management

Stichworte: Empfehlungssysteme, Kollaboratives Filtering, Kundenorientierung, Customer Relationship Management

Keywords: Recommender Systems, Collaborative Filtering, Customer Orientation, Customer Relationship Management

Zusammenfassung

Dieser Beitrag dient besserem Verständnis der sinnvollen Anwendung von Automated Collaborative Filtering. Kapitel 1 gibt einen theoretischen Überblick über das behandelte Thema. In diesem Zusammenhang stehen die Ziele der Nutzenmaximierung für den Kunden und für das Unternehmen im Vordergrund. Die Methode des Automated Collaborative Filtering wird aus der Perspektive des Customer Relationship Managements behandelt. In Kapitel 2 wird die theoretische Grundlage für insbesondere Item-based Collaborative Filtering gebracht. Das nächste Kapitel zeigt anhand von zwei Fallstudien die Nutzenpotentiale für den Kunden und für das Unternehmen.

Der Beitrag zeigt abschließend die bedeutende Wechselbeziehung zwischen Automated Collaborative Filtering und Customer Relationship Management auf.

Abstract

This paper helps to improve the comprehension of the useful application of Automated Collaborative Filtering. Chapter 1 gives a theoretical overview about the underlying topic. In this context the goals of utility maximisation for the customer and enterprise comes to the fore. The method of Automated Collaborative Filtering is studied from the perspective of Customer Relationship Management. Chapter 2 deals with the theoretical basis in particular for Item-based Collaborative Filtering. Next chapter identifies high profit capacity on the basis of two case studies.

Finally the paper treats the significant correlation between Automated Collaborative Filtering and Customer Relationship Management.

Kernpunkte für das Management

Dieser Beitrag liefert die theoretische Grundlage zur Methode des Item-based Collaborative Filtering und die Erarbeitung zweier Fallstudien. Die anschließende Qualitätsmessung dient dem theoretischen Komplement dieser Seminararbeit. Besonderes Augenmerk wurde auf das Kapitel Fazit gelegt.

- Die Wechselwirkung zwischen der Unternehmenstechnologie und Unternehmensphilosophie wird hervorgehoben.
- Anhand der Fallstudien werden Verbesserungspotentiale sichtbar gemacht und Hypothesen erarbeitet.
- Verbesserungspotentiale und Hypothesen sollen das Vertrauen in die Empfehlungssysteme steigern.

Inhaltsverzeichnis

1 Einführung	5
1.1 Empfehlungssysteme	5
1.2 Collaborative Filtering	5
1.3 Customer Relationship Management	6
1.3.1 One-to-One Marketing	7
1.3.2 Personalisierung.....	7
1.3.3 Profiling.....	8
2. Erklärungskonzepte	9
2.1 Automated Collaborative Filtering	9
2.1.1 Typische Verfahrenselemente des ACF	10
2.1.2 Qualitätsaspekte des ACF	11
2.2 Item-based Collaborative Filtering Algorithmen	11
2.2.1 Cluster-Modelle	13
2.2.2 Bayessche Netze.....	13
2.2.3 Hauptkomponentenverfahren	13
2.2.4 Neuronale Netze	14
2.3 Methoden zur Berechnung der Proximität	14
2.3.1 Leistungsvergleich	15
3 Fallstudien	16
3.1 Mobilkom Austria AG & Co KG	16
3.1.1 Analyse	16
3.1.2 Lösungsansatz.....	17
3.1.3 Nutzenpotential.....	19
3.2 United Cinemas International	19
3.2.1 Analyse	20
3.2.2 Lösungsansatz.....	20
3.2.3 Nutzenpotential.....	20
4 Qualitätsmessung	21
4.1 Verfahrenselemente bei der Beurteilung	21
4.2 Messung der Prognosegüte	21
4.2.1 Experimentelle Messung der Prognosegüte	22
4.2.2 Simulative Messung der Prognosegüte.....	22
4.3 Messung der Klassifikationsgüte	23
4.4 Messung der Prognosefehler	24
4.4.1 Absolute und quadrierte Prognosefehler	24
4.4.2 Absolute und quadrierte Mittelwertabweichung	25
4.4.3 Absolute und quadrierte Prognosefehlerverbesserung	25

5 Fazit	26
5.1 Signifikanz der Empfehlungssysteme	26
5.1.1 Wechselbeziehung zwischen Unternehmen und Kunden	26
5.1.2 Wechselbeziehung zwischen ACF und CRM	27
5.2 Verbesserungspotentiale	27
5.2.1 Nutzenmaximierung für den Kunden	28
5.2.2 Nutzenmaximierung für das Unternehmen	28
5.3 Hypothesen	28
6 Resümee	29
A Anhang	30
1 Rechtliche Aspekte	30
1.1 Allgemeine Geschäftsbedingungen der Mobilkom Austria	30
1.2 UCI-Online Nutzungsbedingungen.....	30
2 Lizenz für die freie Nutzung unveränderter Inhalte	30
3 Formatierungs- und Zitierregel	30
<i>Literaturverzeichnis</i>	31
<i>Abkürzungsverzeichnis</i>	34
<i>Bildverzeichnis</i>	35
<i>Tabellenverzeichnis</i>	35

1 Einführung

Die Notwendigkeit neue Kunden zu erwerben und bestehende Kunden stets zufrieden zu stellen ergibt sich für jedes gewinnorientierte Unternehmen. Diese Seminararbeit behandelt Empfehlungssysteme und die dahinter stehende Technologie mit Berücksichtigung unternehmerischer Ziele wie der Kundenorientierung und Kundenbindung.

In zwei Fallstudien werden die notwendige Implementierung und der bedeutende Nutzenzuwachs aufgezeigt. Der bedeutende Nutzenzuwachs setzt korrekte Implementierung des übereinstimmenden Algorithmus und höhere Qualität der Schätzungen voraus. Daher wird im Kapitel 4 auf Methoden zur Qualitätsmessung eingegangen. Die tatsächliche Realisierung der Implementierung wird den innovativen Unternehmen überlassen. Es wird darauf hingewiesen, dass diese Studie lediglich eine Empfehlung für Verbesserung des Servicegrades darstellt.

1.1 Empfehlungssysteme

Das Empfehlungssystem trifft aufgrund von Benutzerprofilen oder Benutzerverhalten eine Vorauswahl der verfügbaren Informationen. Dies kann mit sogenannten *Inferenzmechanismen* realisiert werden: Data Mining, Fuzzy-Logik, Regelbasierte Systeme, Multi-Agenten-Systeme, Case-Based Reasoning, Neuronale Netze, Bayes'sche Netze, Content-Based Filtering, Automated Collaborative Filtering, etc. [PuNe05]

Laut Literatur werden Empfehlungssysteme in individualisierte und nicht-individualisierte Empfehlungssysteme unterteilt. Individualisierte Empfehlungssysteme generieren *individuelle* Empfehlungen oder Prognosen, die auf persönlichen Präferenzen des Benutzers basieren. Im Vergleich dazu sind nicht-individualisierte Empfehlungssysteme unpersönlich, da sie identische Empfehlungen an alle Benutzer generieren. [Bohn03] Das Bild 1 stellt eine graphische Gliederung der Empfehlungssysteme dar.

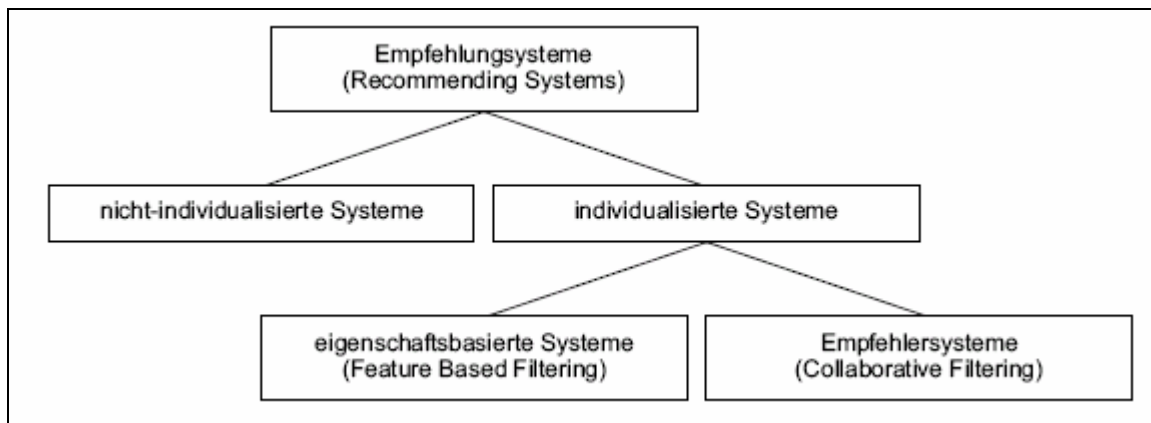


Bild 1 Arten von Empfehlungssystemen [Bohn03]

1.2 Collaborative Filtering

In der Literatur wurde der Begriff *Collaborative Filtering* erstmals von Goldberg et al. verwendet. Der Begriff bedeutet, dass sich Personen gegenseitig bei der Informations-Filterung helfen und somit eine gemeinschaftliche Informations-Filterung betreiben. [GNOT92]

Empfehlungssysteme basieren auf automatisiertem kollaborativen Filtering. Diese systemgestützte Filteringmethode identifiziert Nutzer mit denselben Interessen und Vorzügen. Weiterempfohlen werden nur jene Objekte, die auch von der eigenen Interessensgruppe bevorzugt werden. Das Bild 2 stellt die bedeutendsten Formen von Collaborative Filtering graphisch dar.

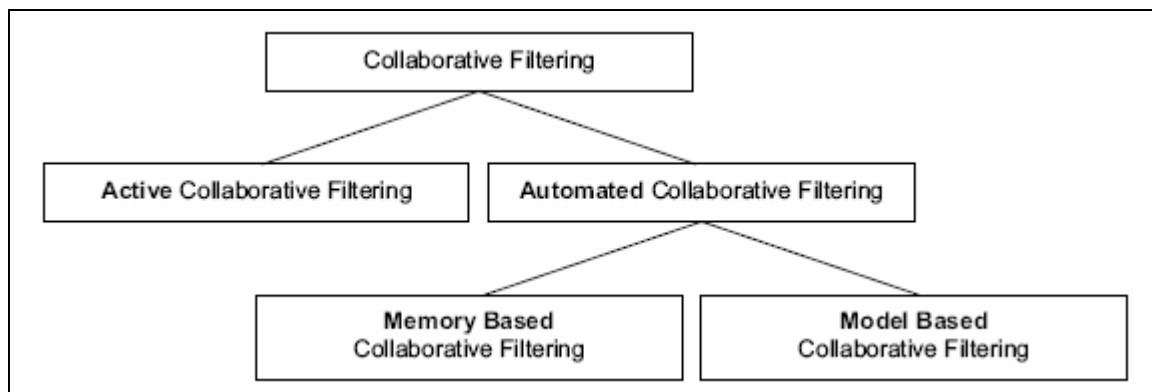


Bild 2 Active vs. Automated Collaborative Filtering [Bohn03]

Runte unterscheidet zwischen aktivem und passivem Filtern. Bei Active Collaborative Filtering empfehlen sich Benutzer gegenseitig Objekte, indem sie aktiv eine Empfehlung abgeben und diese durch Push-Kommunikation wie beispielsweise per Email verbreiten. Bei Passive Collaborative Filtering sucht der Benutzer lediglich passiv nach Empfehlungen anderer Benutzer durch Pull-Kommunikation wie beispielsweise per World-Wide-Web. [Runt00] Diese Methode wird auch Automated Collaborative Filtering genannt. Einerseits erfolgt die Erhebung der Daten über den Benutzer *automatisch* anhand der Clickstream-Analysen und andererseits werden aus den bekannten Präferenzen der Benutzer *automatisch* fehlende Präferenzen abgeleitet.

1.3 Customer Relationship Management

Laut Literatur wird unter Customer Relationship Management (CRM) ein integriertes Marketing-Instrument verstanden, das primär dem Zweck dient die Zufriedenheit der Kunden zu steigern. Auf diese Weise soll der Kunde langfristig an das Produkt des Unternehmens gebunden werden. [Desi05]

Customer Relationship Management wird auch allgemeiner als eine effektive Geschäftsphilosophie verstanden, die der Optimierung der Kundenidentifizierung, Kundenbestandssicherung sowie des Kundenwertes dient. [CaTe05] Durch die Qualitätsmessung des Automated Collaborative Filtering kann dieser Kundenwert gesteigert werden. Daher wird in Kapitel 4 näher auf die Qualitätsmessung eingegangen.

Durch die Globalisierung und zunehmende Informationstechnologie erhält der Kunde ausreichend Produktinformationen. Somit verfügt er über erhebliche Verhandlungsmacht als je zuvor. Für das Unternehmen gilt daher auf die Qualität der Produkte zu achten. Zudem werden zusätzliche und für den Kunden nützliche Informationen zur Zufriedenheit der Kunden beitragen. Mit der Zufriedenheit steigt auch das Erfolgsniveau einer auf Customer Relationship Management - basierten Unternehmensphilosophie. [Muth00]

Das Empfehlungssystem, das auf der Methode des Automated Collaborative Filtering basiert, kann diese Unternehmensphilosophie hilfreich unterstützen. Vice versa bietet die kundenorientierte Unternehmensphilosophie begründeten Anlass für die Implementierung dieser Technologien. In den folgenden Kapiteln wird dieser Sachverhalt begründet.

1.3.1 One-to-One Marketing

Die individualisierte Beziehung zum einzelnen Kunden wird durch die One-to-One Marketingstrategie definiert. Anhand der Informationstechnologien kann diese individuelle Beziehung zum Kunden auch tatsächlich verwirklicht werden.

Informations- und Kommunikationstechnologien stiften mit geringen Kosten für den Kunden höheren Nutzen für das Unternehmen. Gleichzeitig steigt auch der Nutzen des Kunden. Kundenwünsche werden individueller, schneller und kostengünstiger erfasst und bearbeitet. Das dabei verwirklichte Ziel der persönlichen Beziehung zu jedem Kunden sorgt für individuelle Kundenbetreuung bei der Aufgabe der Bedürfnisbefriedigung. [Schm01]

Mit dem Einsatz von Empfehlungssystemen kann die individuelle Beziehung zum Kunden verstärkt und ein höherer Kundenzufriedenheitsgrad bewirkt werden. Durch die Anwendung der Automated Collaborative Filtering Methode lassen sich Empfehlungssysteme sinnvoll und effektiv einsetzen.

1.3.2 Personalisierung

Laut Literatur werden die nächsten Jahre durch einen ansteigenden Trend zur Personalisierung von Angeboten geprägt sein. Runte liefert in seiner Arbeit einen methodischen Beitrag zu Personalisierungsverfahren und untersucht in diesem Zusammenhang die Methode des Automated Collaborative Filtering. [Runt00] Jedes Filterverfahren präsentiert dem Benutzer eine Auswahl der Teilmenge aus einer Gesamtmenge von Objekten. Die Teilmenge mit der höchsten Präferenz wird dem Benutzer des Systems zwecks bestimmter Ziele „empfohlen“. Diese Ziele werden vom Bereich Customer Relationship Management gedeckt.

Die Methode des gemeinschaftlichen Filterns beruht auf der Ähnlichkeit vieler Präferenzen, die jeweils von unterschiedlichen Benutzern abgegeben wurden. Bestehende Präferenzen sind Bewertungen von mehreren Benutzern über verschieden Objekte. Diese werden in den Benutzerprofilen gespeichert und zur Prognose fehlender Präferenzen herangezogen. Die Zielsetzung erfordert sowohl aus betriebswirtschaftlicher Sicht (Maximierung der Kaufwahrscheinlichkeit oder des Deckungsbeitrags) als auch aus informationstechnischer Sicht die Individualisierung von Empfehlungen, Inhalten, Angeboten und Werbung in Online-Medien. [Schm01]

Neben der Individualisierung der Beziehung zum Kunden kann auch das Produkt individualisiert werden. Der Kunde kann beispielsweise aus verschiedenen Musiktiteln jene aussuchen, die er auf seiner Wunsch-CD haben möchte. [Runt00]

Neukundenakquisition und Kundenbindung erfordern Webseiten, deren Inhalte auf jeden einzelnen Benutzer zugeschnitten werden können. Eine derartige Personalisierung erlaubt eine konsequente Orientierung an den Bedürfnissen des einzelnen Kunden und stellt somit die bestmögliche Umsetzung des One-to-One Marketing dar. [Schm01] In der Tabelle 1 ist ein Überblick über die Personalisierungsarten gegeben. Die Methode des Automated Collaborative Filtering zählt laut Literatur zur präferenzbasierten Personalisierungsstrategie.

Im Kapitel 2 wird auf die präferenzbasierte Personalisierungsstrategie eingegangen. Das charakteristische Merkmal des Automated Collaborative Filtering liegt darin, dass aus den Vorlieben der Benutzer Regeln abgeleitet werden, die es erlauben Rückschlüsse auf die Vorlieben anderer Benutzer zu ziehen. Automated Collaborative Filtering lässt auch spartenübergreifende Empfehlungen zu. [Schm01]

	Namenserkennung	Check-Box- Personalisierung	Segmentierung & regelbasierte Personalisierung	Präferenzbasierte Personalisierung
Identifizierung	Cookies/Login	Cookies/Login	Cookies/Login	Cookies/Login
Inhalte	statisch	dynamisch	dynamisch	dynamisch
Regelsystem	-	-	statisch	Dynamisch (lernend)
Technologie	Datenbank	Datenbank	Datenbank + Data Mining	Datenbank + (Automated) Collaborative Filtering

Tabelle 1 Überblick über die verschiedenen Arten der Personalisierung [Schm01]

1.3.3 Profiling

Für die individuelle Betreuung der Kunden sind Kundenprofile unerlässlich. Dabei werden Inhalts-, Stamm- und Bewegungsdaten über Kunden gesammelt und unter Nutzerprofilen in Datenbanken gespeichert. Zu den Stammdaten zählen persönliche Daten wie Name, Adresse und demographische Daten wie Beruf, Bildungsgrad, Familienstand, eventuell auch allgemeine Interessen und Nutzungsgewohnheiten. Bewegungsdaten werden heimlich mithilfe von Logfiles erhoben. Dabei werden die Logfiles automatisch vom Webserver generiert und jede Bewegung des Kunden auf der Webseite des Unternehmens wird von Logfiles protokolliert. Inhaltsdaten dienen der Evaluierung der Kundeninteressen und stellen die auf der Webseite des Unternehmens unmittelbar zur Verfügung stehenden Informationen dar. Die Kundeninteressen lassen sich dabei von den Inhaltsdaten, die der Kunde abgerufen hat, ableiten. Aus den genannten Daten lassen sich zudem Persönlichkeitsprofile erstellen. Diese beinhalten Interessen, Vorlieben und Gewohnheiten des Kunden. [Schm01]

2. Erklärungskonzepte

Der Prozess des Automated Collaborative Filtering beruht vereinfachend zusammengefasst auf Informationsquellen, Algorithmen und dem zugrunde liegenden Lernprozess. Die Erhebung von Informationen und Daten über den Benutzer und seinen Vorlieben bzw. Präferenzen erfolgt auf Basis folgender Informationsquellen [Schm01]:

- ⇒ Transaktionsdaten (implizite Datenerhebung)
- ⇒ Clickstream-Analysen (implizite Datenerhebung)
- ⇒ Vom Benutzer abgegebene Bewertungen (explizite Datenerhebung)

Die Transaktionskosten umfassen bereits getätigten Konsum. Unter Clickstream-Analysen werden Daten ohne das Wissen des Benutzers erhoben, indem Aufzeichnungen über aufgerufene Webseiten, ihre Inhalte, die Verweildauer des Benutzers, die angeklickten Links etc. gespeichert werden. Darüber hinaus können diese Informationen aggregiert zusammengefasst werden um die beliebten Inhalte der Webseite zu eruieren. [Schm01] Somit lassen sich die Clickstream-Analysen zur Bewertung des Angebots auf der Webseite heranziehen.

Das Automated Collaborative Filtering System wird von komplexen Algorithmen ausgeführt, die sehr effizient arbeiten und eine laufende Optimierung zulassen. Die Leistungsfähigkeit dieser Systeme wird durch sog. Learning Engines kontinuierlich verbessert. Der zugrunde liegende Lernprozess erlaubt kurzfristige Anpassung an die sich ständig ändernden Trends und Vorlieben. Das häufigste Hindernis beim Einsatz des Automated Collaborative Filtering Systems ist das Cold-start Problem. Solange die Datenbank leer ist, können keine Empfehlungen erzeugt werden. Erst wenn eine gewisse Datenstruktur und Datenmenge vorhanden ist, kann Automated Collaborative Filtering zuverlässige Prognosen erstellen und Empfehlungen generieren. [Schm01]

2.1 Automated Collaborative Filtering

In diesem Abschnitt wird der Prozess des Automated Collaborative Filtering anhand vorherrschender Literatur näher erläutert.

Die Ausgangssituation dieses Prozesses entsteht anhand einer Liste aus m Benutzern $U=(u_1, u_2, \dots, u_m)$ und einer Liste aus n Objekten $I=(i_1, i_2, \dots, i_n)$. Jedem Benutzer (u_i) wird eine Liste an Objekten (I_{U_i}) zugeordnet, die er bewerten soll. Jede explizit abgegebene Bewertung stellt einen Teil des Benutzerprofils dar. Unter den Benutzern (u_m) befindet sich ein *aktiver Benutzer*, für den Vorhersagen und Empfehlungen generiert werden. Dabei sind die Begriffe *Vorhersagen* von *Empfehlungen* zu unterscheiden. Die Vorhersage ist ein numerischer Wert, der ein Objekt vorhersagt. Die Empfehlung ist eine Liste aus präferierten Objekten, die für den aktiven Benutzer generiert wurde. Die Liste enthält neue Objekte, das heißt jene Produkte, die der Kunde noch nicht konsumiert hat. [SKKR01]

Der Algorithmus des Automated Collaborative Filtering generiert den Nutzen eines Objekts für einen bestimmten Benutzer, für den sog. aktiven Benutzer. Dabei werden vorangegangene Bewertungen des aktiven Benutzers und Bewertungen anderer Benutzer mit ähnlichen Präferenzen bzw. Interessen herangezogen. Der Automated Collaborative Filtering Algorithmus repräsentiert die Daten über Benutzer und über Objekte in einer Bewertungsmatrix $A(m*n)$. Jeder Eintrag stellt eine Bewertung, die von einem Benutzer abgegeben wurde, dar. Die noch nicht bewerteten Objekte haben den Wert von Null. Die Algorithmen des Automated Collaborative Filtering können in zwei Hauptkategorien unterteilt werden: in *memory-based* (benutzerbasiertes) und in *model-based Algorithm* (modellbasiertes Algorithmus). [SKKR01]

Benutzerbasierte Algorithmen suchen nach Benutzergruppen, sog. *Nachbarn des aktiven Benutzers*. Die Nachbarn bewerten untereinander die Objekte ähnlich oder tendieren ähnliche Objekte zu kaufen. Nun werden die Präferenzen der Nachbarn kombiniert und für den aktiven Benutzer wird eine Liste von Top-N Empfehlungen generiert. Modellbasierte Algorithmen gehören zum probabilistischen Ansatz. Sie entwickeln zuerst ein Modell von Benutzer-Ratings. Unter diesem Ansatz basiert der Prozess des Collaborative Filtering auf der Berechnung des Erwartungswertes einer Benutzer-Vorhersage mit Hilfe der bereits bewerteten Objekte (von demselben Benutzer). Dieser Prozess wird von diversen Lernalgorithmen wie Bayes'sche Netze und Clustering durchgeführt. [SKKR01] Das Bild 3 stellt den Prozess des Collaborative Filtering graphisch dar.

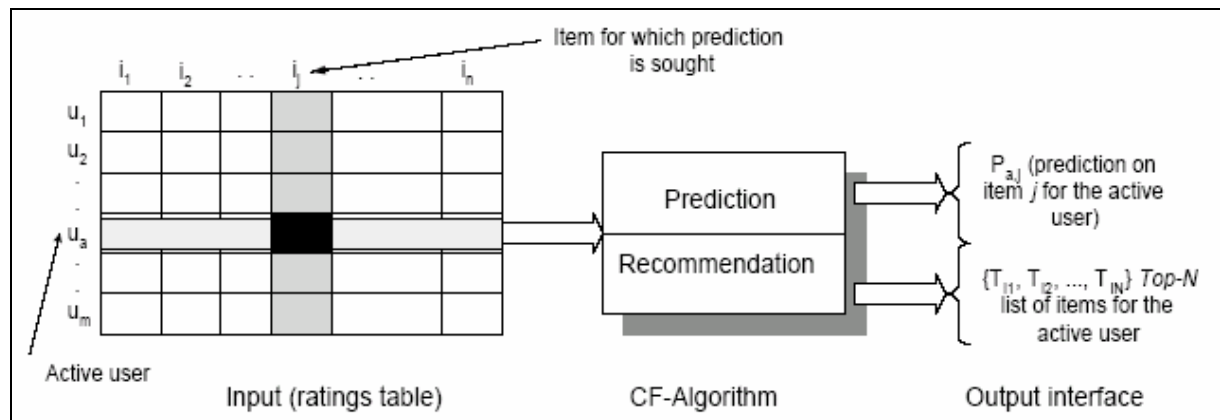


Bild 3 Collaborative Filtering Prozess [SKKR01]

ACF-Systeme basieren auf unvollständige und spärliche Datensätze. Dies kann auch zu falschen Empfehlungen für den Betroffenen führen. Da der Mensch sich in einer ständig ändernden Gesellschaft weiterentwickelt, sind Abweichungen zwischen den vergangenen Interessen und jenen in der Gegenwart praktisch vorprogrammiert. Somit kann auch der Benutzer des Systems eine und dieselbe Empfehlung an einem Tag gutheißen und an einem anderen nicht. Dieses resultierende Hindernis steht der Akzeptanz der ACF-Systeme in hochriskanten Situationen im Weg. [HeKR00]

Das Problem liegt dann nicht am System selbst, sondern im Defizit an Vertrauen der Benutzer in das System. Die Literatur bietet zu diesem Themengebiet diverse Erklärungsansätze zwecks Gewinnung von Vertrauen unter den Benutzern und zwecks Verbesserung der Systemleistung. In diesem Zusammenhang wird auf die Literatur von Herlocker et al. [HeKR00; HKBR99] verwiesen.

2.1.1 Typische Verfahrenselemente des ACF

Das Bild 4 zeigt typische Verfahrenselemente, die sich in den diversen Varianten des Automated Collaborative Filtering identifizieren lassen. Zu Beginn werden Daten über den aktiven Benutzer erhoben und aufgezeichnet. Sobald ausreichend relevante Daten über einen Benutzer vorliegen, kann die Proximitätsberechnung zwischen dem aktiven Benutzer und anderen Benutzern, die in der gleichen Datenmatrix gespeichert sind, durchgeführt werden. Die daraus berechneten Ähnlichkeitswerte dienen der Selektion von Benutzern, die ähnliche Bewertungen abgegeben haben wie der aktive Benutzer. Diese Benutzer werden in der Literatur auch Mentoren genannt. Daraufhin wird anhand der Benutzerprofile dieser Mentoren die Prognose für die fehlenden Werte im Benutzerprofil des aktiven Benutzers berechnet. [Runt00]

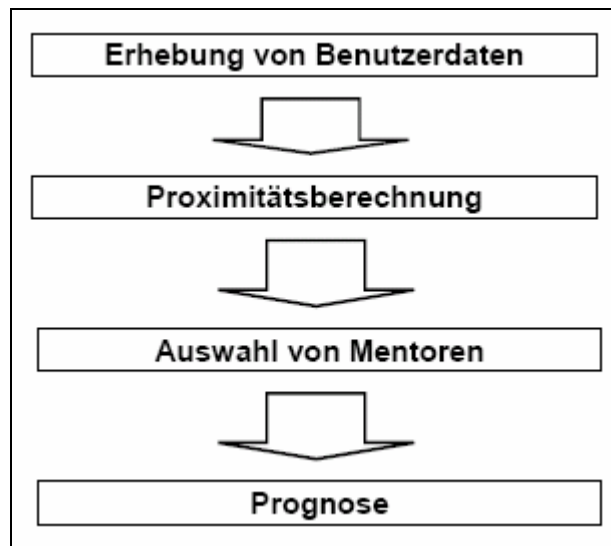


Bild 4 Typische Verfahrenselemente beim Automated Collaborative Filtering [Runt00]

2.1.2 Qualitätsaspekte des ACF

Laut vorherrschender Literatur wurden diverse Experimente zur Messung von Qualität der Vorhersagen durchgeführt. Zu diesem Zweck wurden Sensitivitätsanalysen am Modellumfang erstellt um den Einfluss des Modellumfangs auf die Qualität der Vorhersagen zu bestimmen. Die Resultate ergaben, dass der Fehlerwert (mean absolute error) mit der Erhöhung des Modellumfangs sinkt. Dieser positive Effekt steigt zu Beginn drastisch und sinkt dann statisch wenn der Modellumfang über einen Grenzwert hinaus weiter erhöht wird. [SKKR01; HEKR00; HKBR99]

Die Anzahl an Objekten, die von zwei Benutzern als gleichwertig eingestuft wurde, beeinflusst die Vorhersage in einem bestimmten Maß. Der Effekt der Beeinflussung ist abhängig davon wie viele Übereinstimmungen zwischen zwei Benutzern auftreten. Die Anzahl der Übereinstimmungen wird in Verhältnis zu der Anzahl der Gesamtbewertungen gestellt. Dabei sind zwei wichtige Aspekte zu berücksichtigen: das absolute Verhältnis zwischen zwei Benutzern und das relative Verhältnis. In einem Szenario, wo Benutzer zehn Objekte gleichwertig bewerten, wird das Ergebnis auch signifikant gewichtet. In einem anderen Szenario wo zwei Benutzer nur ein Objekt gleich bewerten wird die Gewichtung (Relevanz) dementsprechend gering ausfallen. Der relative Aspekt zeigt das Verhältnis zwischen den in Summe bewerteten Objekten eines Benutzers und der Anzahl der Übereinstimmungen an Bewertungen mit einem zweiten Benutzer. [SKKR01; HEKR00; HKBR99]

2.2 Item-based Collaborative Filtering Algorithmen

In diesem Abschnitt werden jene Empfehlungsalgorithmen erläutert, die dem probabilistischen Ansatz folgen. Die Algorithmen berechnen die Ähnlichkeit der vom Benutzer bereits bewerteten Objekte $\{i_1, i_2, \dots, i_n\}$ mit dem Zielobjekt i und selektieren die ähnlichsten Objekte i_K heraus $\{i_1, i_2, \dots, i_K\}$. Sobald die ähnlichsten Objekte gefunden wurden, wird die Vorhersage anhand des gewogenen Durchschnittswertes bewertet. Diese beiden Aspekte werden laut Literatur Ähnlichkeits- und Vorhersageschätzung genannt. [SKKR01]

Die Grundidee der Ähnlichkeitsschätzung zwischen zwei verschiedenen Objekten i und j ist die Isolierung der Benutzer, die beide Objekte bewertet haben. Zur Bestimmung der Ähnlichkeit s_{ij} wird eine entsprechende Berechnungsmethode angewendet. Das Bild 5 stellt den Prozess der

Ähnlichkeitsschätzung dar. Die Reihen in der Matrix präsentieren die Benutzer und die Spalten stellen die Objekte dar. Zur Berechnung der Ähnlichkeit zwischen Objekten können verschiedene Methoden herangezogen werden. In der Literatur werden *Kosinusbasierte*, *Korrelationsbasierte* und *Kosinusbereinigte Ähnlichkeitsmaße* genannt. [SKKR01] Zwecks der Erläuterung dieser Ähnlichkeitsmaßen wird anschließend in Kapitel 2.3 näher darauf eingegangen.

Das Bild 5 zeigt graphisch die Isolierung jener Benutzer, die beide Objekte bewertet haben, und die Ähnlichkeitsschätzung.




Bild 5 Isolierung und Ähnlichkeitsschätzung [SKKR01]

Nächster Schritt liegt darin einen Output - Interface hinsichtlich der Vorhersagen zu generieren. Nach der Isolierung der ähnlichsten Objekte werden Vorhersagen anhand der Bewertungen der Zielgruppe und der erforderlichen Methoden erstellt. Laut Literatur werden zwei Methoden unterschieden: *weighted sum* und *Regression*. [SKKR01] Dazu wird eine visuelle Beschreibung des Vorgangs präsentiert. Der Prozess zur Generierung der Vorhersage für fünf Nachbarn ist im Bild 6 dargestellt.

Im typischen E-commerce Szenario wird eine Menge an Objekten, mit einer Anzahl von Benutzern verglichen. Die Objekte sind in der Theorie als konstant anzusehen. Aufgrund dieses Konstanzansatzes lassen sich die Objektähnlichkeiten theoretisch in Vorhinein schätzen. [SKKR01] Im Gegensatz dazu wird in der Realität das Sortiment des Öfteren ergänzt oder verändert. Jedes neue Objekt bzw. Produkt, das in das Sortiment aufgenommen wird, kann aufgrund des Cold-start Problems nicht empfohlen werden. Zuerst muss das Produkt von Benutzern bewertet werden. Liegen genügend Bewertungen vor, können Prognosen für den aktiven Benutzer erstellt werden.

In den vorliegenden Fallstudien, die in dieser Arbeit behandelt werden, sind die Objekte kurzfristig statisch. Langfristig ändern sie sich jedoch, immer dann wenn ein Film oder Mobiltelefon aus dem Sortiment entnommen wird und ein aktueller Film bzw. aktuelles Mobiltelefon in das Sortiment aufgenommen wird. Die daraus resultierende Dynamik sollte kein Hindernis für die erfolgreiche Anwendung des Empfehlungssystems sein. Tatsächlich wird auch nur ein geringer Anteil von ähnlichen Objekten benötigt um Vorhersagen zu berechnen. Aus einer Gesamtmenge n wird für jedes Objekt j eine geringe Anzahl k an ähnlichen Objekten berechnet wobei $k < n$ gilt. [SKKR01]




Bild 6 Item-based collaborative filtering Algorithmus [SKKR01]

Im Folgenden werden vier modellbasierte Algorithmen präsentiert.

2.2.1 Cluster-Modelle

Clustering Technologien identifizieren Benutzergruppen, sog. *Clusters* oder *Blöcke*, die ähnliche Präferenzen aufweisen. Sobald die Clusters gebildet sind, werden Empfehlungen für den aktiven Benutzer erstellt. Dabei wird von den Präferenzwerten der restlichen Benutzer, die sich im selben Cluster befinden wie der aktive Benutzer, ein Durchschnittswert berechnet. Der Durchschnittswert kann auch übergreifend von Präferenzwerten der Benutzer anderer Blöcke, in denen sich der aktive Benutzer ebenfalls befindet, berechnet werden. Diese Werte werden mit dem Grad der Teilnahme in Prozentsatz gewichtet. [SaKR98; OCHe99]

2.2.2 Bayessche Netze

Mit Bayes'schen Netzen werden auf Basis von Entscheidungsbäumen bedingte Wahrscheinlichkeiten für die Ausprägung bestimmter Variablen berechnet. Die Knoten dieser Entscheidungsbäume repräsentieren die Objekte und die Kanten stellen die Bewertungen für diese Objekte dar.

Die Komplexität der Entscheidungsbäume und der Lernalgorithmen steigt stark an wenn eine mehrdeutige Bewertungsskala (statt einer binären Skala) vorliegt. Die ansteigende Komplexität wirkt sich auf die Rechenzeit des Lernalgorithmus nachteilig aus. Sind die Entscheidungsbäume jedoch für alle Objekte vollständig berechnet, sind individuelle Prognosen mit geringem Zeitaufwand durchführbar. [Runt00]

2.2.3 Hauptkomponentenverfahren

Ken Goldberg kreierte die Webseite, Jester 2.0 (<http://shadow.ieor.berkeley.edu/humor/>), die auf Basis einiger vom Benutzer bewerteten Scherze, weitere Scherze empfiehlt. Das in Jester 2.0 verwendete modellbasierte Hauptkomponenten-Verfahren basiert auf Verdichtung von zehn Globalbewertungen zu zwei Eigenvektoren. Anhand dieser Eigenvektoren wird die individuelle Präferenz-Prognose für jeden einzelnen Benutzer erstellt. [Runt00; Bohn03]

2.2.4 Neuronale Netze

Anhand von neuronalen Netzen lassen sich nicht-lineare Ursache-Wirkungs-Beziehungen modellieren um somit die Funktionsweise des menschlichen Gehirns nachzuempfinden. [Kinn94]

Ein neuronales Netz besteht aus Werten eines Inputvektors, der über spezielle funktionelle Zusammenhänge in einen Outputvektor transformiert wird. Die Werte des Vektors (sog. Neuronen) werden mit Gewichtungen (sog. Synapsen) versehen. Die Gewichtungen bestimmen dabei den funktionalen Zusammenhang zwischen dem Input- und Outputvektor. Der sich aus Neuronen und Synapsen ergebende Lernalgorithmus läuft solange, bis das Netz mit hinreichender Genauigkeit den Wirkungszusammenhang zwischen Input- und Outputvektor wiedergibt. Im Idealfall kann das neuronale Netz nun für alle möglichen Inputvektoren die dazupassenden Outputvektoren ermitteln. [Kinn94;Runt00]

Die neuronalen Netze gehören wie auch Bayes'sche Netze zu probabilistischen Methoden, da die Wahrscheinlichkeiten für bestimmte Ausprägungen auf einer Bewertungsskala ermittelt werden. [Runt00]

2.3 Methoden zur Berechnung der Proximität

Der Begriff *Proximität* ist ein Oberbegriff für Ähnlichkeitsmaßen, Distanzmaßen und Korrelationsmaßen. [EnDi05] Im Folgenden werden drei relevante Methoden der Ähnlichkeitsmaßen wiedergegeben, die in der Literatur zum Thema Automated Collaborative Filtering genannt werden.

Kosinusbasierte Ähnlichkeitsmaße („*Cosine-based Similarity*“) misst die Ähnlichkeit zwischen zwei Objekten i und j anhand der Berechnung des Kosinus $\cos(i, j)$. [SKKR01]

$$\text{sim}(i, j) = \cos(\vec{i}, \vec{j}) = \frac{\vec{i} \cdot \vec{j}}{\|\vec{i}\|_2 * \|\vec{j}\|_2}$$

Korrelationsbasierte Ähnlichkeitsmaße („*Correlation-based Similarity*“) misst die Ähnlichkeit zweier Objekte anhand der Pearson-Korrelation. Zuerst werden jene Benutzer isoliert, die beide Objekte i und j bewertet haben. Diese Benutzer werden mit U bezeichnet.

Die durchschnittliche Bewertung des Objektes i und j wird mit \bar{R}_i und \bar{R}_j bezeichnet. [SKKR01]

$$\text{sim}(i, j) = \frac{\sum_{u \in U} (R_{u,i} - \bar{R}_i)(R_{u,j} - \bar{R}_j)}{\sqrt{\sum_{u \in U} (R_{u,i} - \bar{R}_i)^2} \sqrt{\sum_{u \in U} (R_{u,j} - \bar{R}_j)^2}}$$

Kosinusbereinigte Ähnlichkeitsmaße („*Adjusted Cosine Similarity*“) misst die Ähnlichkeit zwischen Objekt i und j wobei im Vergleich zur *Kosinusbasierten Ähnlichkeitsmaße* nun die Abweichung in der Beurteilungsskala zwischen verschiedenen Benutzern berücksichtigt wird. [SKKR01]

$$\text{sim}(i, j) = \frac{\sum_{u \in U} (R_{u,i} - \bar{R}_u)(R_{u,j} - \bar{R}_u)}{\sqrt{\sum_{u \in U} (R_{u,i} - \bar{R}_u)^2} \sqrt{\sum_{u \in U} (R_{u,j} - \bar{R}_u)^2}}$$

2.3.1 Leistungsvergleich

Der Leistungsvergleich zwischen den genannten drei Ähnlichkeitsmaßen hat laut Literatur ergeben, dass die „Adjusted Cosine Similarity“ den niedrigsten Fehlerwert, *Mean Absolute Error (MAE)*, aufweist. Die Fehlerwerte dienen der Qualitätsmessung und werden in Kapitel 4 näher erläutert. Das Bild 7 stellt den Leistungsvergleich zwischen den genannten Ähnlichkeitsmaßen graphisch dar.

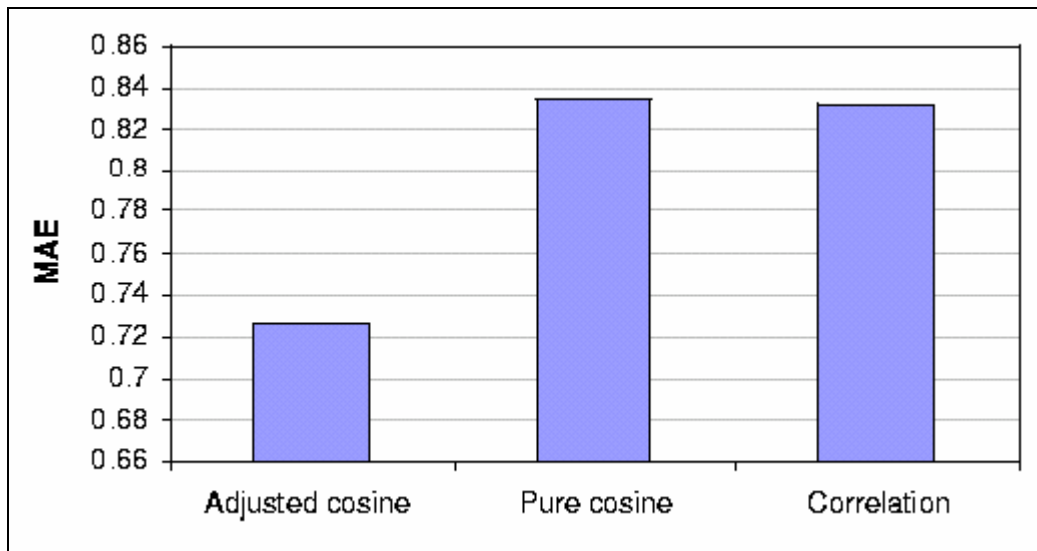


Bild 7 Leistungsvergleich zwischen den Ähnlichkeitsmaßen

3 Fallstudien

Die Analyse erfolgt aus der Perspektive des Customer Relationship Management. Dabei steht das Ziel, die Kundenzufriedenheit und Kundenbindung zu steigern, im Vordergrund. Empfehlungssysteme helfen Benutzern jene Objekte zu finden, die sie auf kommerziellen Webseiten kaufen bzw. konsumieren wollen. Die zugrunde liegenden Algorithmen erzeugen Objekt-Empfehlungen für den aktiven Benutzer, die aus den Meinungen der Benutzer mit ähnlichem Geschmack resultieren. Die Benutzer in den beiden Fallstudien sind bestehende Kunden. Die Objekte sind je nach Fallstudie entweder die Mobiltelefone oder Spielfilme. Objekt-Empfehlungen können auf Basis bereits beschriebener Methoden erfolgen.

3.1 Mobilkom Austria AG & Co KG

Mobilkom Austria AG & Co KG ging aus dem Funktechnischen Dienst (FTD) hervor und existiert seit 1992. Das Unternehmen ist eine Tochter der Telekom Austria und ist in der Mobilfunkbranche tätig. Mobilkom Austria ist der größte österreichische Mobilfunkbetreiber und vertreibt GSM- und UMTS-Dienste unter der Marke A1. [Wiki05] Das Bild 8 zeigt relevante Daten vom Impressum der Mobilkom Austria.




Bild 8 A1-Impressum [MoAu05]

3.1.1 Analyse

In diesem Abschnitt wird das derzeitige Angebot analysiert um anschließend am theoretischen Verbesserungspotential anzuknüpfen. Das aktuelle Angebot für bestehende Kunden erstreckt sich auf 24 Mobiltelefone. Alle Angebote, die vorübergehend lediglich dem Erwerb von Neukunden dienen, werden hier ausgeklammert. Die Analyse ist daher auf den Bereich für bestehende Kunden eingegrenzt.

Zum Erwerb von neuen Mobiltelefonen können bestehende Kunden ihre gesammelten Punkte gegen ein neues Mobiltelefon eintauschen. Der Kunde sammelt nach der Anmeldung automatisch Mobilpoints (MP). Bei der Anmeldung erhält der Kunde 100 MP, dann jeden Monat 80 MP und 4 MP für jeden Euro des Nettorechnungsbetrages. [MoAu05]

Aktuelle Situation erfordert vom Kunden eigenständige Recherche nach neuen Angeboten. Hat der Kunde die Zeit nicht, folgt eine spontane Entscheidung, die nicht unbedingt zu seiner Zufriedenheit ausfällt. Das Empfehlungssystem dient der kundenindividuellen Betreuung und aktivem Marketing bei entsprechender Applikation. Der Kunde tendiert zu Neuanschaffungen bei individuellen bzw. personalisierten Angeboten. Jedes Unternehmen, das sein Angebot über World Wide Web zu

vermarkten versucht, kann die Technologie des Automated Collaborative Filtering zum Zweck des aktiven Marketings sinnvoll einsetzen.

Das Bild 9 zeigt einen kurzen Abriss vom Angebot zum 2005-05-12. Alle Mobiltelefone werden in Verbindung mit 7500 Mobilpoints angeboten. Das aktuelle Angebot ist auf diese 7500 Mobilpoints beschränkt.

Die Kunden sind interessiert, ein Produkt zu finden, das ihren Geschmack trifft und in deren Preisklasse passt. Besondere Bedeutung haben Inhalte, die den aktiven Kunden einen zusätzlichen Anreiz bieten, die Webseite erneut aufzusuchen. Solche Inhalte sollten immer auf den neuesten Stand gebracht werden. Dabei kann es um nützliche Grundlageninformationen oder Hintergrundberichte handeln, die gezielt auf die individuellen Bedürfnisse des Nutzers zugeschnitten sind. Der Inhalt einer Webseite stellt somit ein wesentliches Kundenbindungsinstrument im E-Commerce dar. Hierbei kommt es vor allem auf den individuell zugeschnittenen Inhalt an, der einen bestimmten Zusatznutzen hervorbringt. [Schm01]

Mit MOBILPOINTS zum neuen A1 Handy!

Egal, ob Sie schon MOBILPOINTS sammeln oder noch nicht:
Ihr neues NEXT Handy erhalten Sie sofort, wenn Sie schon 6 Monate A1 Kunde sind. Jederzeit und supergünstig!
> [Alles über NEXT](#)

	Samsung SGH E330 um ab 69,- EUR + 7500 MOBILPOINTS DETAILS		Qtek 9090 um ab 539,- EUR + 7500 MOBILPOINTS DETAILS
	Nokia 6020 um ab 89,- EUR + 7500 MOBILPOINTS DETAILS		SonyEricsson T290i um 40,- EUR + 7500 MOBILPOINTS DETAILS
	VF MCC 3G WLAN um ab 99,- EUR + 7500 MOBILPOINTS		Nokia 6630 um ab 189,- EUR + 7500 MOBILPOINTS

Bild 9 A1-Angebot [MoAu05]

3.1.2 Lösungsansatz

Basierend auf der Theorie der Volkswirtschaftslehre können wir von der begründeten Annahme ausgehen, dass vielfältigeres Angebot bedeutend höhere Nachfrage hervorbringt. Vom betriebswirtschaftlichen Standpunkt betrachtet, ist das Unternehmen bestrebt den Absatz zu maximieren. Zu diesem Zweck sollte das Angebot in vielfältigere Variationen unterteilt werden. Das Angebot lässt sich in verschiedene Preisklassen einteilen. Im Zusammenhang mit den gesammelten Mobilpoints ergeben sich verschiedene Alternativen. Die Tabelle 2 zeigt vier Kategorien in die sich das Angebot über ein bestimmtes Mobiltelefon, bestehend aus der Kombination aus Preisklassen und Mobilpoints, beispielhaft erweitern lässt.

Angebot	Preisklassen	Mobilpoints (MP)
1	0 Euro – 100 Euro	+ 7500
2	101 Euro – 200 Euro	+ 3500
3	201 Euro – 400 Euro	+ 1500
4	ab 401 Euro	+ 0

Tabelle 2 Angebotserweiterung durch Kombination aus Preisklassen und MP

Mit einer höheren Auswahl an Produkten kann auch ein höherer Zufriedenheitsgrad erreicht werden. Die Produkte aller vier Preisklassen können in Kombination mit den Mobilpoints-Alternativen angeboten werden, abhängig vom Gesamtwert des betreffenden Mobiltelefons. Auf diese Weise kann ein und dasselbe Mobiltelefon in vier verschiedenen Angeboten enthalten sein. Bei Inanspruchnahme von Angebot 2 oder 3 bekommt Kunde 500 Mobilpoints geschenkt. Für das Unternehmen bedeutet diese Inanspruchnahme im Vergleich zum Angebot 1 einen höheren Cash Flow zum Zeitpunkt des Absatzes.

Bei Inanspruchnahme von Angebot 2 zahlt der Kunde für die Differenz von 7500 und 3500 zwischen 101 und 200 Euro. Der Preis ist vom Wert des Mobiltelefons abhängig. In der Tabelle 3 ist die Differenz der Mobilpoints für Angebot 2 und 3 im Verhältnis zum Angebot 1 dargestellt.

Angebot	Preisklassen	Mobilpoints (MP)	MP-Differenz
1	0 Euro – 100 Euro	+ 7500	
2	101 Euro – 200 Euro	+ 3500	7500-3500=4000
3	201 Euro – 400 Euro	+ 1500	7500-1500=5500
4	ab 401 Euro	+ 0	

Tabelle 3 Angebotsvergleich

Solange der Kunde einen negativen Mobilpoints-Kontostand aufweist, kann er von keinem Angebot Gebrauch machen. Es besteht die Möglichkeit die Mobilpoints aufzukaufen und wieder in den positiven Bereich zu gelangen. Das Aufkaufen von negativen Mobilpoints ist in der Tabelle 4 zum Zeitpunkt 2005-05-12 dargestellt. [MoAu05]

Fehlende MOBILPOINTS	Euro
1 – 1000	35,-
1001 – 2500	70,-
2501 – 3500	140,-
3501 – 5500	180,-
5501 – 7500	220,-

Tabelle 4 Preise für fehlende Mobilpoints [MoAu05]

Angenommen der Kunde zahlt 140 Euro für das Mobiltelefon, dann erspart er sich 500 Mobilpoints. Dies begünstigt baldige Inanspruchnahme eines neuen Mobiltelefons. Für das Unternehmen bedeuten detaillierte Angebote auch eine genaue Kostendeckung. Der resultierende Nutzen für den Kunden und für das Unternehmen ist in der Tabelle 5 zusammengefasst.

Angebot	Nutzen für den Kunden	Nutzen für das Unternehmen
1		
2	4000-3500=500 MP	Im Vergleich zu Angebot 1 höherer Cashflow zum Zeitpunkt des Absatzes
3	5500-5000=500 MP	
4		

Tabelle 5 Nutzen für den Kunden und für das Unternehmen

Mit der vorgestellten vielfältigeren Auswahl an Angeboten kann die Häufigkeit der Inanspruchnahme neuer Angebote gesteigert werden ohne, dass das Aufkaufen von fehlenden Mobilpoints notwendig wäre. Durch das vielfältige Angebot kann der Kunde selbst entscheiden ob er nun im positiven oder negativen Bereich bleiben möchte. Die Tabelle 6 zeigt die *Angebote über günstige Mobiltelefone* und Angebote über Mobiltelefone höherer Preisklassen.

Nr	Preisklassen	MP 0	MP 1	MP 2	MP 3
1	0 Euro – 100 Euro	-	-	-	+ 7500
2	101 Euro – 200 Euro	-	-	+ 3500	+ 7500
3	201 Euro – 400 Euro	-	+ 1500	+ 3500	+ 7500
4	ab 401 Euro	0	+ 1500	+ 3500	+ 7500

Tabelle 6 Angebotserweiterung

Primäres Ziel einer CRM-Philosophie ist die Zufriedenheit der Kunden und zweitrangig die Absatzsteigerung. Durch vielfältigeres Angebot lässt sich auch der Absatz von Produkten höherer Preisklassen erhöhen. Mit der Absatzsteigerung an Produkten höherer Preisklassen steigt die Nachfrage nach zwar teuren aber dafür innovativen Produkten. Steigende Nachfrage nach Produkten bringt höhere Investitionen in die Forschung mit sich und erhöht somit auch den Entwicklungsgrad. Die Tabelle 7 stellt den Zusammenhang zwischen CRM und Innovation dar.

Voraussetzung:		CRM-Ziele:		Folgerung:		
Vielfältigeres Angebot, Ansteigende Nachfrage	→	Kundenbindung, Zufriedenheit der Kunden	→	E&F steigt	→	Erhöhung des Wohlstands

Tabelle 7 Zusammenhang zwischen CRM und Innovation

3.1.3 Nutzenpotential

Zuerst wird die Annahme getroffen, dass der Nutzen des Kunden und des Unternehmens gleichwertig sind. Diese Gleichbehandlung wird dem Anspruch der Zufriedenheit beider Akteure gerecht. Auf dieser Basis fühlt sich keiner der Akteure benachteiligt.

Aus dem vielfältigeren Angebot lassen sich Nutzenpotentiale ableiten. Die Entscheidungsgrundlage wird durch ein erweitertes Angebot ausgedehnt. Das vielfältigere Angebot bietet dem Kunden mehrere Alternativen zugleich und eine höhere Entscheidungsauswahl. Dadurch kann der Zufriedenheitsgrad gesteigert werden. Mit diesem Angebot lässt sich das Empfehlungssystem entsprechend einsetzen. Die im Kapitel 2 beschriebene Methode des Item-based collaborative Filtering kann dazu beitragen dem Kunden passende Angebote zu liefern und gleichzeitig auch unbeliebte Angebote aus dem Sortiment zu streichen.

3.2 United Cinemas International

United Cinemas International setzte als Pionierunternehmen das Konzept des Multiplex-Kinos zum ersten Mal in den USA um. [Wiki05] Das auch unter UCI KINOWELT bekannte Unternehmen betreibt in Deutschland und Österreich 22 Multiplex Kinos mit mehr als 200 Leinwänden. Das Unternehmen wurde im Oktober 2004 von Terra Firma Capital Partners übernommen und ist weiterhin bestrebt, die Marktstärke in Europa auszubauen. [UCIM05a] Im Bild 10 ist das UCI-Impressum dargestellt.

Impressum

United Cinemas International Multiplex Gesellschaft mbH
Shopping City Süd Top 43
2351 Wiener Neudorf
Tel: (02236) 686-10
Fax: (02236) 686-11
E-mail: zentrale@uci-kinowelt.de

Firmenbuchnummer: FN 39357 d; Firmenbuchgericht: Landesgericht
Wiener Neustadt; UID: ATU 37303707; Mitglied der Wirtschaftskammer
Wien, Niederösterreich, Steiermark, Fachgruppe der Lichtspieltheater
und Audiovisionsveranstalter Wien, Niederösterreich, Steiermark

Bild 10 Impressum von UCI Kinowelt [UCIM05b]

3.2.1 Analyse

Da die Seminararbeit in Wien verfasst wird, liegt es nahe für diese Analyse auch das Angebot des UCI KINOWELT Millenium City in Wien vorzustellen. Anschließend folgt die Studie des theoretischen Verbesserungspotentials.

Das Angebot zum 2005-05-12 umfasst 36 Kinofilme inklusive zwei Überraschungsprämieren. Das gesamte Angebot ist alphabetisch auf einer Seite dargestellt und bietet somit einen Überblick. Jeder Film ist einzeln anzuklicken. Auf der Webseite wird eine kurze Beschreibung des Kinofilms gegeben. Zusätzlich zu der Filmbeschreibung finden sich meistens Informationen über Regie, Darsteller, Laufzeit, Land und Genre.

3.2.2 Lösungsansatz

Laut Literatur wurden Empfehlungssysteme bereits erfolgreich von Kinobetreibern eingesetzt. Ein vereinfachtes Beispiel soll den begründeten Einsatz von Automated Collaborative Filtering beschreiben. Angenommen fünf Kinobesucher haben dieselben Kinofilme ähnlich bewertet und einer von diesen fünf Kinobesuchern hat einen der Kinofilme noch nicht gesehen und daher auch nicht bewertet. Die Wahrscheinlich ist hoch, dass ihm dieser eine Kinofilm auch ähnlich gefallen wird wie den restlichen vier Kinobesuchern. Zwar wird dem Besucher die Entscheidung nicht abgenommen, aber dafür um einiges leichter gemacht. Für fanatische Kinobesucher, die sich fast jeden Film ansehen, wird es kaum einen Unterschied machen ob ein Empfehlungssystem eingesetzt wird oder nicht. Dennoch kann es hilfreich sein sich in Zeitnot und nach kurzfristig vereinbarten Terminen eine Empfehlung holen zu können. Diese ökonomische Terminplanung kann daher anhand der Inanspruchnahme der Informationstechnologie ausgeschöpft werden.

3.2.3 Nutzenpotential

Die Implementierung von Empfehlungssystemen ist zwar seitens des Unternehmens mit Kosten verbunden, bietet aber den entsprechenden Mehrwert, der Zufriedenheit und Kundentreue hervorruft. Der Einsatz von Empfehlungssystemen bietet eine individuelle Kundenbetreuung, die auf der systemgestützten Technologie basiert und daher auch Flexibilität bietet. Die Kunden entscheiden selbst ob und wann sie von dem System Gebrauch machen. In der Zeit der Informationstechnologie ist die Flexibilität und schnelles Service und damit auch höhere Zufriedenheit seitens der Kunden realisierbar.

4 Qualitätsmessung

Erfolgreiche Empfehlung kann jene sein, die den Kunden überzeugt das empfohlene Produkt zu konsumieren. Auf jeden Fall ist eine Empfehlung dann erfolgreich wenn sie für den Kunden einen zusätzlichen Nutzen stiftet.

Ein Beispiel aus der Volkswirtschaftslehre soll diesen Sachverhalt verdeutlichen. Der Kunde bezahlt für ein Produkt jenen Preis, der unter dem von ihm wahrgenommenen Wert des Produktes liegt. Der Kunde ist bereit ein Produkt zum Marktpreis zu kaufen, wenn der Wert des Produktes für den Kunden über dem Marktpreis liegt. Dieser zusätzliche Nutzen wird in der Literatur Mehrwert genannt und kann auch durch den Einsatz von qualitativen Empfehlungssystemen realisiert werden.

Die Qualitätsmessung der angewendeten Verfahren bei Empfehlungssystemen ist daher wesentliches Kompliment dieser Seminararbeit.

4.1 Verfahrenselemente bei der Beurteilung

Bei der Beurteilung der Automated Collaborative Filtering Verfahren kommen stets drei Ausgangswerte zur Anwendung: das tatsächliche Rating, die erstellte Prognose und der Mittelwert. Zur Berechnung der Prognosefehler werden das tatsächliche Rating und die Prognose herangezogen. Die Mittelwertabweichung ergibt sich aus dem Vergleich von dem tatsächlichen Rating mit dem Mittelwert. [Runt00] Das Bild 11 zeigt den Vergleich anhand von fünf Verfahrenselementen.

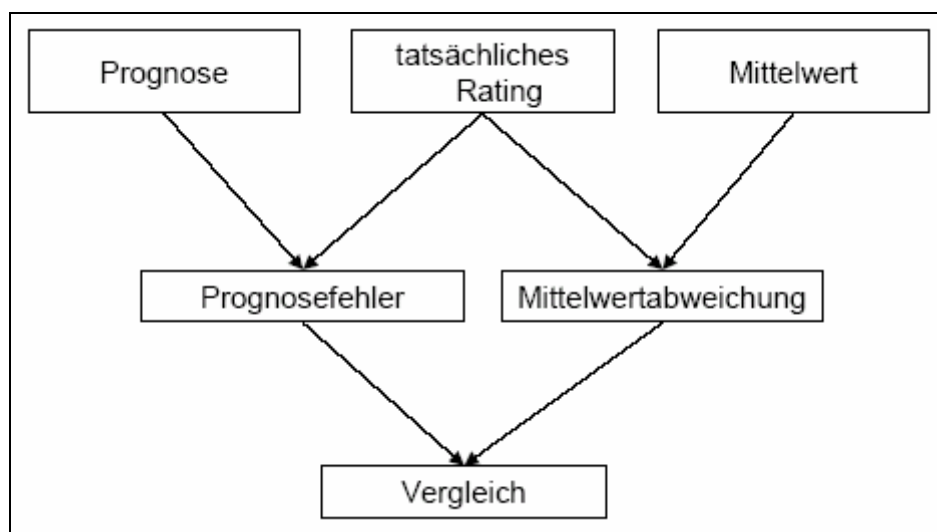


Bild 11 Muster für empirische Auswertung [Runt00]

4.2 Messung der Prognosegüte

Der Untersuchung der Automated Collaborative Filtering Methode dienen zwei wesentliche Verfahren: experimentelle und simultane Messung der Prognosegüte. Beide Verfahren evaluieren die externe Validität bzw. die Prognosegüte der ACF-Methode. [Runt00]

4.2.1 Experimentelle Messung der Prognosegüte

Das Bild 12 stellt die Vorgehensweise der experimentellen Messung der Prognosegüte dar. Zuerst werden Objekte mit den höchsten Prognosewerten empfohlen. Der Benutzer kann anschließend ein Feedback über die Qualität der gezeigten Empfehlungen abgeben. Dieses Feedback stellt den *wahren* Präferenz-Wert, den sog. Sollwert, dar. Anschließend wird der Sollwert mit dem Istwert der Prognose verglichen um Prognosefehler für das betreffende Objekt zu bestimmen. Auf Basis dieser Werte wird eine aggregierte Prognosegüte ermittelt. Wünscht der Benutzer weitere Empfehlungen, dann werden ihm diese angezeigt. Daraufhin wird erneut ein Feedback vom Benutzer über die Qualität der Empfehlungen eingeholt. [Runt00]

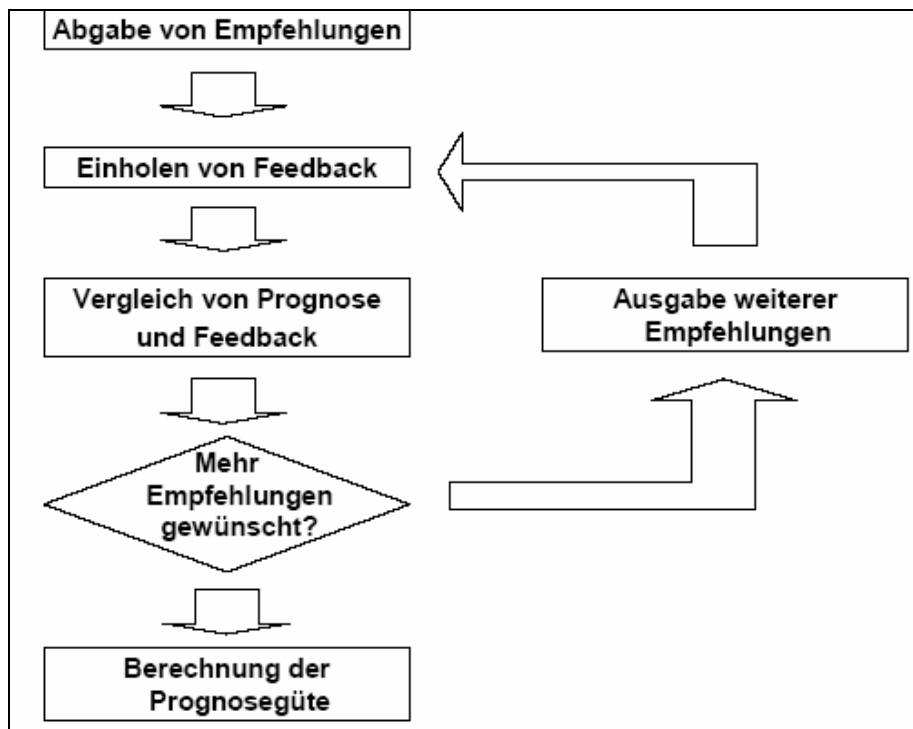


Bild 12 Vorgehensweise zur experimentellen Messung der Prognosegüte [Runt00]

4.2.2 Simulative Messung der Prognosegüte

Die Vorgehensweise bei der simulativen Messung der Prognosegüte wird im Bild 13 dargestellt. Die simulative Messung kann anhand von Simulationsrechnungen durchgeführt werden. Nach der Eliminierung einzelner Bewertungen (sog. Ratings) eines Benutzers wird ein Prognosewert berechnet. Anschließend wird dieser berechnete Prognosewert mit dem tatsächlichen (eliminierten) Rating-Wert verglichen. [Runt00]

Wenn diese Berechnung für alle vorliegenden Rating-Werte durchgeführt wird, kann ein mittlerer Prognosefehler ermittelt werden. Zu den Prognosefehlern wird im Kapitel 4.4 eingegangen.

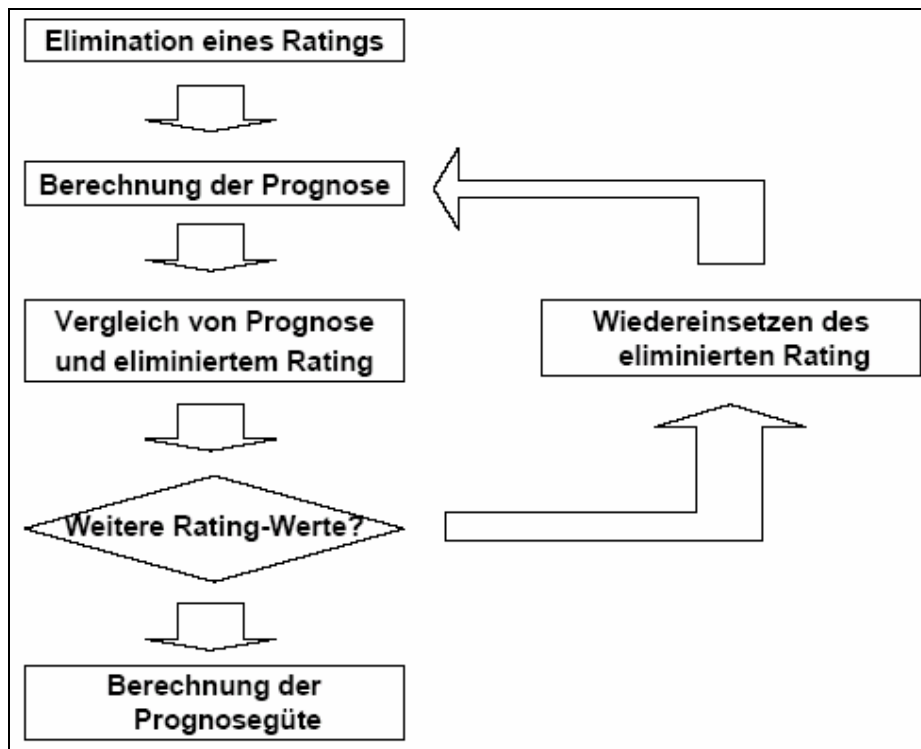


Bild 13 Vorgehensweise zur simulativen Messung der Prognosegüte [Runt00]

4.3 Messung der Klassifikationsgüte

Zur Bestimmung der Klassifikationsgüte wird eine Klassifikationsmatrix erstellt, die aus den Werten „relevant – irrelevant“ und „präsentiert – nicht präsentiert“ besteht. Zu diesem Zweck wird eine Rating-Skala auf ein binäres Niveau transformiert. Eine Gesamtmenge wird in lediglich vier Gruppen {a;b;c;d} eingeteilt. Die Tabelle 8 zeigt die Dichotomisierung in *relevante* und *irrelevante* Objekte. [Runt00]

	relevant	irrelevant	
präsentiert	a	b	a+b
nicht präsentiert	c	d	c+d
	a+c	b+d	N

Tabelle 8 Klassifikationsmatrix für Empfehlungssysteme [Runt00]

Die Gruppen a und d präsentieren die richtig klassifizierte Fälle. Auf die Gruppen b und c entfallen falsch klassifizierte Fälle. Die Wahrscheinlichkeit, dass ein relevantes Objekt gefiltert wird um dem Benutzer das Objekt anschließend zu präsentieren, wird in der Literatur *Sensitivität* genannt. Unter *Spezifizität* ist die Wahrscheinlichkeit, dass ein irrelevantes Objekt gefiltert wird, zu verstehen. Das Verhältnis zwischen Sensitivität und Spezifizität hängt vom festgelegten Schwellenwert ab. Im Bild 14 ist der Schwellenwert anhand der Quadrate gekennzeichnet. Liegt der Schwellenwert hoch, wird von einer besseren Spezifizität ausgegangen. Vice versa sinkt der Schwellenwert, verbessert sich die Sensitivität. Dieser Sachverhalt wird anhand der ROC-Curve (Receiver Operational Characteristic Curve) anschaulich dargestellt. [Runt00]

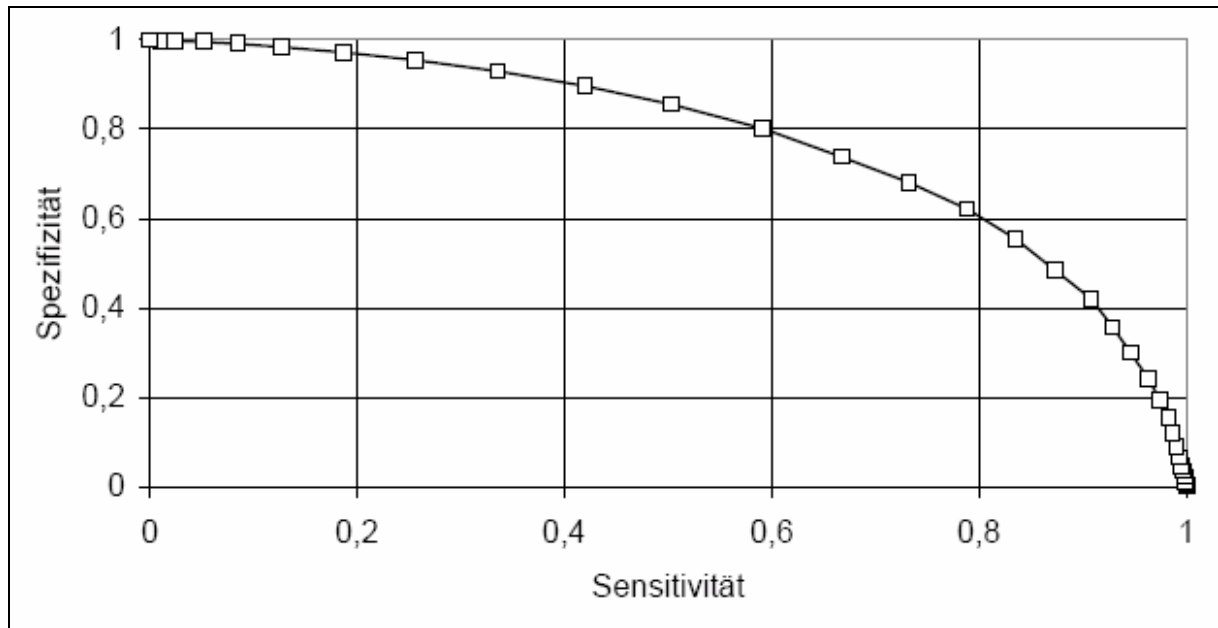


Bild 14 Beispiel für eine ROC-Curve [Runt00]

4.4 Messung der Prognosefehler

Im Folgenden werden jene Messgrößen dargestellt, in denen die Differenz zwischen den vorhergesagten Ratings und den tatsächlichen Ratings eingeht. [Runt00]

4.4.1 Absolute und quadrierte Prognosefehler

Die absolute Prognosefehler oder „Mean absolute error“ (MAE) stellt die absolute Abweichung der Prognose vom tatsächlichen Rating dar. Die quadrierte Prognosefehler oder „Mean squared error“ (MSE) zeigt die quadrierte Abweichung der Prognose vom tatsächlichen Rating. Die Messgrößen werden aggregiert um den arithmetischen Mittelwert zu bilden. Dieser Mittelwert entspricht theoretisch dem mittleren absoluten Prognosefehler (MAE_f) bzw. mittleren quadrierten Prognosefehler (MSE_f). Die Formel 1 und 2 stellen die unterschiedliche Vorgangsweise der Aggregation dar. [Runt00]

$$MAE_f = \frac{1}{|P|} \sum_{(i,j) \in P} |f_{ij} - u_{ij}|$$

Formel 1: Aggregation auf Basis der absoluten Abweichung [Runt00]

$$MSE_f = \frac{1}{|P|} \sum_{(i,j) \in P} (f_{ij} - u_{ij})^2$$

Formel 2: Aggregation auf Basis der quadrierten Abweichung [Runt00]

Zur Ermittlung von Prognosefehlern kann auch der *mean absolute percentage error* (MAPE) herangezogen werden. Dieser Wert stellt den prozentuellen Prognosefehler dar, indem es die absoluten

Prognosefehler auf die tatsächlichen Werte bezieht. Diese Maßgröße dient der Vergleichbarkeit bei der Ermittlung der Leistungsfähigkeit von Prognoseverfahren bei unterschiedlichen Anwendungen und Datensätzen. [Runt00]

4.4.2 Absolute und quadrierte Mittelwertabweichung

Die Beurteilung der Prognosegüte basiert auf dem Vergleich mit den arithmetischen Mittelwerten (MEANS). Beim MEANS-Verfahren wird bestimmt, ob die Abweichung zwischen tatsächlichem Rating und Prognose kleiner oder größer ist als die Abweichung zwischen Mittelwert und tatsächlichem Rating. Die Formel 3 und 4 stellen die beiden Aggregationsmöglichkeiten für das MEANS-Verfahren dar, wobei MAE_m die absolute Mittelwertabweichung und MSE_m die quadrierte Mittelwertabweichung darstellt. [Runt00]

$$MAE_m = \frac{1}{|P|} \sum_{(i,j) \in P} |\tilde{u}_j - u_{ij}|$$

Formel 3: Aggregation auf Basis der absoluten Mittelwertabweichung [Runt00]

$$MSE_m = \frac{1}{|P|} \sum_{(i,j) \in P} (\tilde{u}_j - u_{ij})^2$$

Formel 4: Aggregation auf Basis der quadrierten Mittelwertabweichung [Runt00]

4.4.3 Absolute und quadrierte Prognosefehlerverbesserung

Anhand der absoluten bzw. quadrierten Prognosefehler und Mittelwertabweichung lässt sich die relative Prognosefehlerverbesserung bestimmen. In Formel 5 und 6 wird zwischen *mean absolute improvement* (MAI) und *mean squared improvement* (MSI) unterschieden. [Runt00]

$$MAI = \frac{MAE_m - MAE_f}{MAE_m}$$

Formel 5: absolute Prognosefehlerverbesserung [Runt00]

$$MSI = \frac{MSE_m - MSE_f}{MSE_m}$$

Formel 6: relative Prognosefehlerverbesserung [Runt00]

5 Fazit

Verfolgt ein Unternehmen die Philosophie des Customer Relationship Management, hat es verschiedene Möglichkeiten diese auch umzusetzen. Eine von besonderer Bedeutung relevante Technologie ist das Empfehlungssystem. Verschiedene Experimente zur Qualitätsmessung haben erwiesen, dass die Methode des Item-based Collaborative Filtering für Empfehlung von Filmen, Büchern, Videos etc. vorteilhaft ist. Daher wurde in der vorliegenden Seminararbeit auf diese Methode eingegangen. Diese Arbeit ist selbst auch eine Empfehlung an Unternehmen ihre Marketingstrategie durch systemgestützte Technologie zu erweitern bzw. zu ergänzen. Die Nutzenpotentiale, die sich für den Kunden und das Unternehmen ergeben, sind gleichwertig anzusehen. Im Endeffekt will das Unternehmen zufriedene Kunden und der Kunde dementsprechendes Angebot, das ihn zufrieden stellt.

5.1 Signifikanz der Empfehlungssysteme

Aus der Perspektive des Unternehmens dienen Empfehlungssysteme denselben Zielen wie die zugrunde liegende Unternehmensphilosophie. Als Mittel zum Zweck stellt die Methode des Automated Collaborative Filtering eine stabile Grundlage für die Empfehlungssysteme dar. Anhand der Empfehlungssysteme lassen sich Ziele der Unternehmensphilosophie effizient umsetzen und gleichzeitig wird dem Kunden personalisierte Kundenbetreuung geboten. Laut Literatur hat systemgestützte Kundenbetreuung zudem den Vorteil, dass es vom Ort und Zeit unabhängig eingesetzt werden kann. Der Kunde entscheidet selbst ob und wann er die Webseite des Unternehmens aufsucht. Die systemgestützte Personalisierungsstrategie stiftet dem Kunden bei der Anwendung des Systems den entsprechenden Nutzen. Für das Unternehmen kann der Nutzen in Form von zufriedenen Kunden und einer Absatzsteigerung identifiziert werden. Im Bild 15 ist das Empfehlungssystem als das Bindeglied zwischen dem Unternehmen, das eine Customer Relationship Management Philosophie verfolgt, und den Kunden dargestellt.




Bild 15 Empfehlungssystem als Bindeglied

5.1.1 Wechselbeziehung zwischen Unternehmen und Kunden

Die Annahme des Gleichgewichts zwischen dem Nutzen des Unternehmens und des Kunden stellt die Grundlage für den Zufriedenheitsgrad dar, da sich keiner der Akteure benachteiligt fühlt. Das gewinnorientierte Unternehmen ist bestrebt mit seiner Unternehmensphilosophie den Kunden personalisierte Betreuung zu bieten und seine Kunden zufrieden zu stellen. Der Nutzen des Kunden liegt in der qualitativen Bedürfnisbefriedigung und in der systemgestützten Entscheidungshilfe durch die Anwendung des Empfehlungssystems. Dem Kunden ist es überlassen ob er seine Entscheidung auf der Grundlage der Empfehlungen trifft. Das Ziel der Erklärungskonzepte ist es jedoch, die Kunden von der Vorteilhaftigkeit zu überzeugen und Vertrauen zu erzeugen. Das Bild 16 stellt das Gleichgewicht zwischen dem Nutzen des Unternehmens und des Kunden dar.




Bild 16 Gleichgewicht des Nutzens

Erfolgreiche Empfehlungssysteme führen zu zufriedenen Kunden und erfüllen somit die Ziele der CRM-Philosophie. Zufriedene Kunden bleiben dem Unternehmen treu. Der Kunde ist an einem individuellen Service interessiert um sein Bedürfnis nach einem Produkt zu befriedigen. Bei Erreichung des notwendigen Zufriedenheitsgrades werden von Kunden bei Bedarf Folgekäufe getätigt. Der dazu ausschlaggebende Zufriedenheitsgrad kann von Person zur Person schwanken.

Ein wesentliches Hindernis stellt die Bevorzugung von Neukunden, die durch Schnäppchenangebote überzeugt werden, dar. Bereits bestehende Kunden können sich dabei benachteiligt fühlen, da sie oft nicht in den Genuss derselben Schnäppchen kommen. Dieser Aspekt beeinflusst zwar den Aspekt der Kundenbindung, dient aber ausschließlich der Neukundengewinnung und wird daher hierbei vernachlässigt.

5.1.2 Wechselbeziehung zwischen ACF und CRM

Ein besonderer Aspekt ist die Korrelation zwischen der Unternehmensphilosophie und der Unternehmenstechnologie. Das Unternehmen verfolgt seine Ziele gemäß seiner Unternehmensphilosophie. Die Ziele sind u.a Kundenbindung, Kundenzufriedenheit und vor allem die individualisierte Kundenbetreuung. Diese Ziele lassen sich anhand diverser Methoden und Technologien erreichen. In dieser Seminararbeit wurde die Methode des Item-based Collaborative Filtering vorgestellt. Das Bild 17 zeigt den beschriebenen Sachverhalt.




Bild 17 Wechselbeziehung zwischen CRM und ACF

5.2 Verbesserungspotentiale

In diesem Kapitel wird bewusst nicht auf den Gewinn sondern auf den Nutzen eingegangen. Der Nutzen ist im Unterschied zum Gewinn umfassend definierbar. Im Zusammenhang mit der Fallstudie Mobilkom Austria wird der Nutzen in vielfältigerem Angebot und somit in einer höheren Auswahl an Produkten identifiziert. Folglich entsteht ein höherer Nutzen in Bedürfnisbefriedigung und Zufriedenheitssteigerung seitens der Kunden. Dieser Nutzenzuwachs resultiert im besten Fall im unternehmerischen Gewinnzuwachs durch Absatzsteigerung.

5.2.1 Nutzenmaximierung für den Kunden

Für den Kunden liegt der Nutzen vor allem darin anhand der Technologie des Item-based Collaborative Filtering ein Produkt zu finden, das ihn interessiert. Irrelevante Produkte werden von Automated Collaborative Filtering Systemen sofort aussortiert. Der Kunde spart Zeit und bekommt von Empfehlungssystemen das Produkt wonach er sucht und im besten Fall auch das Produkt, das er konsumieren will.

5.2.2 Nutzenmaximierung für das Unternehmen

Mit dem Einsatz der Item-based Collaborative Filtering Technologie hat das Unternehmen die Möglichkeit die erstellten Profile seiner Kunden auszuwerten und Prognosen zu erstellen. Diese Prognosen dienen primär der Erzeugung von Empfehlungen. Sekundär können sie auch zur Berechnung von aktuellen Trends und Zukunftsprognosen herangezogen werden. Auf Grundlage dieser Trends können weitere Produkte ins Sortiment aufgenommen werden. Das Unternehmen stärkt seine Konkurrenzfähigkeit in dem es als erstes Unternehmen in seiner Vertriebsregion jene Produkte anbietet, nach denen aufgrund der vorhersehbarer Trends Nachfrage prognostizierbar ist.

5.3 Hypothesen

Das Unternehmen ist bestrebt auf dem Markt konkurrenzfähig zu bleiben. Der immense Wettbewerb fordert höhere Leistungen im Sinne einer besseren Qualität und individueller Bedürfnisbefriedigung. Daher ist das Unternehmen bestrebt einen *echten* Mehrwert zu bieten durch den sich das Unternehmen von der Konkurrenz abhebt. Mit der Qualitätssteigerung und qualitativen Individualbetreuung der Kunden steigt die Qualität der Marktleistung. [Schm01]

Die Kundenbindung und Kundenbetreuung erfordern Maßnahmen, die den Kunden zu Folgekäufen anspornen und den Kunden letztendlich zufrieden stellen. Qualitativ hochwertige Empfehlungssysteme bieten dem Kunden individuelle Betreuung mit entsprechendem Grad an Zufriedenheit.

Im Folgenden werden auf Basis der vorangegangenen Kapitel relevante Hypothesen zusammengefasst.

- ⇒ Die Berücksichtigung volkswirtschaftlicher Aspekte führt zur Gewinnung von Nutzenpotentialen. In der Fallstudie Mobilkom Austria wurden Nutzenpotentiale auf der volkswirtschaftlichen Annahme, dass vielfältigeres Angebot höhere Nachfrage hervorruft, erarbeitet.
- ⇒ Die Empfehlungssysteme realisieren Flexibilität, da sie unabhängig vom Ort oder von der Zeit anwendbar sind. Die Fallstudie United Cinemas International zeigt die Nutzenpotentialen im verbesserten Servicegrad durch Flexibilität und ökonomische Terminplanung. Letzteres kann auf Grundlage der Informations- und Kommunikationstechnologie ausgeschöpft werden.
- ⇒ Empfehlungssysteme können effektiv als Marketinginstrument eingesetzt werden.
- ⇒ Erklärungskonzepte steigern das Vertrauen in das Empfehlungssystem.

Die Bedeutung der Empfehlungssysteme wird aufgrund ihrer Nutzenpotentialen signifikant ansteigen. In diesem Zusammenhang werden Anforderungen hinsichtlich der Gewinnung von Vertrauen in das System gestellt. „Dies kann einerseits durch Gewöhnung und andererseits durch etablierte Standards in den Bereichen Datenschutz, Datensicherheit und Handelsrecht geschehen.“ [EgTu00]

6 Resümee

Die Philosophie des Customer Relationship Management verfolgt unternehmerische Ziele und bedient sich verschiedener Personalisierungsstrategien. Die theoretische Grundlage für diese Seminararbeit bildete die präferenzbasierte Personalisierungsstrategie.

In der Einführung wurde ein theoretischer Überblick über Collaborative Filtering gebracht. Es wird darauf hingewiesen, dass der Begriff Collaborative Filtering ein Oberbegriff für Active und Passive (Automated) Collaborative Filtering ist, der jedoch in der Literatur häufig für Automated Collaborative Filtering verwendet wird. In der vorliegenden Seminararbeit wurde *Collaborative Filtering* nur dann verwendet wenn auch tatsächlich Active und Passive Collaborative Filtering gemeint waren.

Im Kapitel 2 folgte ein Beitrag speziell zu Erklärungsmodellen des Item-based Collaborative Filtering. Darauf aufbauende Fallstudien zeigen für zwei ausgewählte Unternehmen den bedeutenden Nutzenzuwachs und damit den begründeten Einsatz der Empfehlungssysteme.

A Anhang

1 Rechtliche Aspekte

1.1 Allgemeine Geschäftsbedingungen der Mobilkom Austria

Allgemeine Geschäftsbedingungen der Mobilkom Austria AG & Co KG für die Inanspruchnahme von Kommunikationsdiensten und damit im Zusammenhang stehender Leistungen (AGB Mobil) können unter http://www.a1.net/CDA/navigation/nav_frame/0,2756,286-376-html-de,00.html abgerufen werden.

1.2 UCI-Online Nutzungsbedingungen

Die Nutzungsbedingungen für die UCI-Webseite können unter <http://www.uci-kinowelt.at/> nachgelesen werden.

2 Lizenz für die freie Nutzung unveränderter Inhalte

Die Lizenzbedingungen stehen unter <http://www.uvm.nrw.de/opencontent> zur Verfügung. Die Lizenz kann bei der Geschäftsstelle des Kompetenznetzwerkes schriftlich angefordert werden.

Geschäftsstelle: Universitätsverbund MultiMedia NRW, Universitätsstraße 11, D-58097 Hagen

3 Formatierungs- und Zitierregel

Die Formatierungs- und Zitierregel für diese Seminararbeit wurden den Vorgaben der Zeitschrift Wirtschaftsinformatik entnommen. Die genauen Formatierungsregeln stehen online unter <http://www.wirtschaftsinformatik.de/printpage.php?pid=29> zur Verfügung.

Literaturverzeichnis

- [BaSh97]
Balabanovic, Marko; Shoham, Yoav: Content-Based, Collaborative Recommendation.
http://www.ischool.utexas.edu/~i385q-dt/readings/Balabanovic_Shoham-1997-Fab.pdf, 1997,
Abruf am 2005-05-21.
- [Bohn03]
Bohnert, Fabian: Einsatz von Collaborative Filtering zur Datenprognose.
<http://www.mathematik.uni-ulm.de/sai/ws03/dm/arbeit/bohnert.pdf>, 2003, Abruf am 2005-04-18.
- [BrHe98]
Breese, John. S; Heckerman, David; Kadie, Carl: Empirical Analysis of Predictive Algorithms for Collaborative Filtering.
<http://www.csee.umbc.edu/~msmith27/readings/public/breese-1998a.pdf>, 1998, Abruf am 2005-05-21.
- [CaTe05]
Cambridge Technology Partners: CRM Glossar.
<http://www.cambridge-germany.com/index.php?mid=23>, 2005, Abruf am 2005-04-19.
- [ClRu99]
Clement, Michel; Runte, Matthias: Intelligente Software Agenten.
<http://www.runte.de/matthias/publications/agents498.pdf>, 1999, Abruf am 2005-05-19.
- [CoHe99]
O'Connor, Mark; Herlocker, J.: Clustering Items for Collaborative Filtering.
http://web.engr.oregonstate.edu/~herlock/papers/sigir99_workshop_clustering.pdf, 1999,
Abruf am 2005-05-21.
- [Coll00]
Collischonn Nils: Personalisierung auf Basis von Collaborative Filtering.
http://www.ecommerce.wiwi.uni-frankfurt.de/lehre/00ws/seminar/Seminararbeiten/14_collischonn.pdf, 2000, Abruf am 2000-05-19.
- [Desi05]
desig-n.de: Glossar – Werbung und Marketing. http://www.desig-n.de/werbung_c.htm, 2005,
Abruf am 2005-04-19.
- [EgTu00]
Eggimann, Andreas; Tüller, Silvio: One-to-One Marketing und Collaborative Filtering.
[http://dwi.fhbb.ch/eb/publications.nsf/0/4e3cef63d46cf2d3c1256c5d0042f6cf/\\$FILE/EggimannTueller2000.pdf](http://dwi.fhbb.ch/eb/publications.nsf/0/4e3cef63d46cf2d3c1256c5d0042f6cf/$FILE/EggimannTueller2000.pdf), 2000, Abruf am 2005-04-19.
- [EnDi05]
Encyclopaedic Dictionary Marketing - definitions and explanations. <http://medialine.focus.de>,
2005, Abruf am 2005-05-20.
- [FaSt02]
Fabrizek, Stephan: Personalisierung und Recommender Systeme – Einführung und Überblick.
http://www11.informatik.tu-muenchen.de/lehre/seminare/seminarRS-WS0203/01_fabrizek.pdf, 2002, Abruf am 2005-04-19.
- [GNOT92]
Goldberg, D.; Nichols, D.; Oki, B.M.; Terry, D.: Using Collaborative Filtering to Weave an Information Tapestry, Communications of the ACM. 1992.
- [GSKB99]
Good, N.; Schafer, J.B.; Konstan, J.; Borchers, A.; Sarwar, B.; Herlocker, J.; Riedl, J.: Combining Collaborative Filtering with Personal Agents for Better Recommendations.
<http://web.engr.oregonstate.edu/~herlock/papers/aaai-99.pdf>, 1999, Abruf am 2005-05-21.

- [HeKR00]
Herlocker, J.; Konstan, J.; Riedl, J.: Explaining Collaborative Filtering Recommendations - Proceedings of the ACM 2000 Conference on Computer Supported Cooperative Work. http://web.engr.oregonstate.edu/~herlock/papers/explanations_cscw2000.pdf, 2000-12-06, Abruf am 2005-05-21.
- [HKBR99]
Herlocker, J.; Konstan, J.; Borchers, A.; Riedl, J.: An Algorithmic Framework for Performing Collaborative Filtering - Proceedings of the 1999 Conference on Research and Development in Information Retrieval. <http://web.engr.oregonstate.edu/~herlock/papers/algs.pdf>, 1999, Abruf am 2005-05-21.
- [Kinn94]
Kinnebrock, Werner: Neuronale Netze – Grundlagen, Anwendungen, Beispiele. 2. Auflage, München, Wien 1994.
- [LeMa05]
Lemire, Daniel; Maclachlan, Anna: Slope One Predictors for Online Ratings-Based Collaborative Filtering. http://www.ondelete.com/lemire/documents/publications/Lemiremaclachlan_sdm05.pdf, 2005, Abruf am 2005-05-19.
- [Lemi05]
Lemire, Daniel: Scale and translation invariant collaborative filtering systems. http://www.ondelete.com/lemire/documents/publications/sti_nrc.pdf, 2005, Abruf am 2005-05-19.
- [MoAu05]
Mobilkom Austria AG und Co KG: Webseite. <http://www.a1.net/>, 2005, Abruf am 2005-05-21.
- [Muth00]
Muther, Andreas: Electronic Customer Care - Die Anbieter-Kunden-Beziehung im Informationszeitalter. 2. Auflage, Springer Verlag, Berlin 2000.
- [OCHe99]
O'Connor, Mark; Herlocker, Jon: Clustering Items for Collaborative Filtering. http://www.csee.umbc.edu/~ian/sigir99-rec/papers/oconner_m.pdf, 1999, Abruf am 2005-05-19.
- [PaPI03]
Papagelis, Manos; Plexousakis, Dimitris: Recommendation Based Discovery of Dynamic Virtual Communities. <http://www.ics.forth.gr/isl/publications/paperlink/caiseforum-pp03.pdf>, 2003, Abruf am 2005-05-21.
- [PuNe05]
punkt.netServices: Intelligente Informationszugänge. <http://www.punkt.at/index.php?main=1&char=r&id=126&searchstr=Recommender%20System>, 2005, Abruf am 2005-04-19.
- [Runt00]
Runte, Matthias: Personalisierung im Internet - Individualisierte Angebote mit Collaborative Filtering. http://www.runte.de/matthias/publications/personalisierung_im_internet.pdf, 2000, Abruf am 2005-05-19.
- [SaKR98]
Sarwar, B.; Konstan, J.; Borchers, A.; Herlocker, J.; Miller, B.; Riedl, J.: Using Filtering Agents to Improve Prediction Quality in the GroupLens Research Collaborative Filtering System. <http://web.engr.oregonstate.edu/~herlock/papers/filterbot-CSCW98.pdf>, 1998, Abruf am 2005-05-21.
- [ScBe05]
Schafer, Ben J.: The Application of Data-Mining to Recommender Systems. <http://www.cs.uni.edu/~schafer/publications/dmChapter.pdf>, 2005, Abruf am 2005-05-21.

- [ScCh03]
Scheer, Christian; Loos, Peter: Konfiguration individualisierbarer Leistungen im Electronic Commerce.
http://chris.scheer.bei.t-online.de/docs/scheer03_konfigurator_erweitert_paper.pdf, 2003, Abruf am 2005-05-21.
- [ScHa03]
Scheer, Christian; Hansen, Torben; Loos, Peter: Erweiterung von Produktkonfiguratoren im Electronic Commerce um eine Beratungskomponente.
<http://isym.bwl.uni-mainz.de/publikationen/isym011.pdf>, 2003, Abruf am 2005-05-21.
- [Schm01]
Schmitz, Marc: Diplomarbeit: Konzepte des Online-Marketing. <http://www.marc-schmitz.de/ll/dipl/html/inhalt.html>, 2001, Abruf am 2005-05-19.
- [ScKo01]
Schafer, Ben J.; Konstan, Joseph A.; Riedl, John: E-Commerce Recommendation Application. <http://www.cs.umn.edu/Research/GroupLens/papers/pdf/ECRA.pdf>, 2001, Abruf am 2005-05-21.
- [ShMa95]
Shardanand, U.; Maes P.: Social Information Filtering: Algorithms for Automating “Word of Mouth”. Denver 1995.
- [SKBH98]
Sarwar, B., M., Konstan, J. A., Borchers, A., Herlocker, J., Miller, B., and Riedl, J.: Using Filtering Agents to Improve Prediction Quality in the GroupLens Research Collaborative Filtering System. Seattle 1998.
- [SKKR00]
Sarwar, Badrul; Karypis, George; Konstan, Joseph; Riedl, John: Analysis of Recommendation Algorithms for E-Commerce.
<http://www.grouplens.org/papers/pdf/ec00.pdf>, 2000, Abruf am 2005-05-19.
- [SKKR01]
Sarwar, Badrul; Karypis, George; Konstan, Joseph; Riedl, John: Item-based Collaborative Filtering Recommendation Algorithms.
http://www-users.cs.umn.edu/~karypis/publications/Papers/PDF/www10_sarwar.pdf, 2001, Abruf am 2005-05-19.
- [SoFu04]
Sollenborn, Mikael; Funk, Peter: Category-Based Filtering und User Stereotype Cases to Reduce the Latency Problem in Recommender System.
<http://www.mrtc.mdh.se/publications/0403.pdf>, 2004, Abruf am 2005-05-19.
- [UCIM05a]
 United Cinemas International Multiplex GmbH: Unternehmensprofil.
http://www.uci-kinowelt.de/ueber_uns/, 2005, Abruf am 2005-05-19.
- [UCIM05b]
United Cinemas International: Webseite. <http://www.uci-kinowelt.at/>, 2005, Abruf am 2005-05-21.
- [Wann04]
Wanner, Leo: Anwendungsfelder für Agenden.
<http://www.iis.uni-stuttgart.de/lehre/ss04/IA/anw.pdf>, 2004, Abruf am 2005-04-18.
- [Wiki05]
Wikipedia: die freie Enzyklopädie – Artikel: Mobilkom Austria.
http://de.wikipedia.org/wiki/Mobilkom_Austria, 2005, Abruf am 2005-05-19.
- [YSTM03]
Yu, Kai; Schwaighofer, Anton; Tresp, Volker; Ma, Wei-Ying; Zhang, HongJiang: Collaborative Ensemble Learning: Combining Collaborative and Content-Based Information Filtering via Hierarchical Bayes.
http://www.igi.tugraz.at/aschwaig/papers/uai03_collabensemble.pdf, 2003, Abruf am 2005-04-18.

Abkürzungsverzeichnis

ACF	Automated Collaborative Filtering
CF	Collaborative Filtering
CRM	Customer Relationship Management
MAE	Mean absolute error, absolute Prognosefehler
MAE _f	Mittlere absolute Prognosefehler
MAE _m	Absolute Mittelwertabweichung
MAI	Mean absolute improvement
MAPE	Mean absolute percentage error
MP	Mobilpoints
MSE	Mean squared error, quadrierte Prognosefehler
MSE _f	Mittlere quadrierte Prognosefehler
MSE _m	Quadrierte Mittelwertabweichung
MSI	Mean squared improvement
RS	Recommender Systeme
ROC-Curve	Receiver Operational Characteristic Curve

Bildverzeichnis

Bild 1 Arten von Empfehlungssystemen [Bohn03]	5
Bild 2 Active vs. Automated Collaborative Filtering [Bohn03]	6
Bild 3 Collaborative Filtering Prozess [SKKR01]	10
Bild 4 Typische Verfahrenselemente beim Automated Collaborative Filtering [Runt00]	11
Bild 5 Isolierung und Ähnlichkeitsschätzung [SKKR01]	12
Bild 6 Item-based collaborative filtering Algorithmus [SKKR01]	13
Bild 7 Leistungsvergleich zwischen den Ähnlichkeitsmaßen	15
Bild 8 A1-Impressum [MoAu05]	16
Bild 9 A1-Angebot [MoAu05]	17
Bild 10 Impressum von UCI Kinowelt [UCIM05b].....	20
Bild 11 Muster für empirische Auswertung [Runt00]	21
Bild 12 Vorgehensweise zur experimentellen Messung der Prognosegüte [Runt00]	22
Bild 13 Vorgehensweise zur simulativen Messung der Prognosegüte [Runt00]	23
Bild 14 Beispiel für eine ROC-Curve [Runt00]	24
Bild 15 Empfehlungssystem als Bindeglied	26
Bild 16 Gleichgewicht des Nutzens	27
Bild 17 Wechselbeziehung zwischen CRM und ACF	27

Tabellenverzeichnis

Tabelle 1 Überblick über die verschiedenen Arten der Personalisierung [Schm01]	8
Tabelle 2 Angebotserweiterung durch Kombination aus Preisklassen und MP	18
Tabelle 3 Angebotsvergleich.....	18
Tabelle 4 Preise für fehlende Mobilpoints [MoAu05]	18
Tabelle 5 Nutzen für den Kunden und für das Unternehmen	18
Tabelle 6 Angebotserweiterung	19
Tabelle 7 Zusammenhang zwischen CRM und Innovation.....	19
Tabelle 8 Klassifikationsmatrix für Empfehlungssysteme [Runt00]	23