

Empfehlungssysteme aus informationswissenschaftlicher Sicht – State of the Art

Stefanie Höfeld und Melanie Kwiatkowski, Düsseldorf

Empfehlungssysteme tragen Inhalte individuell an Nutzer im WWW heran, basierend auf deren konkreten Bedürfnissen, Vorlieben und Interessen. Solche Systeme können Produkte, Services, Nutzer (mit analogen Interessen) uvm. vorschlagen und stellen damit – gerade im Web 2.0-Zeitalter – eine besondere Form der Personalisierung sowie des social networking dar. Damit bieten Empfehlungssysteme Anbietern im E-Commerce einen entscheidenden Marktvorteil, weshalb die Auswertung der Kundendaten bei großen Firmen wie Amazon, Google oder Ebay eine hohe Priorität besitzt. Aus diesem Grund wird im vorliegenden Artikel auf die Ansätze von Empfehlungssystemen, welche auf unterschiedliche Weise die Bedürfnisse des Nutzers aufgreifen bzw. „vorausahnen“ und ihm Vorschläge (aus verschiedenen Bereichen) unterbreiten können, eingegangen. Der Artikel liefert eine Definition und Darstellung der Arbeitsweisen von Empfehlungssystemen. Dabei werden die verschiedenen Methodiken jener Dienste vergleichend erläutert, um ihre jeweiligen Vor- und Nachteile deutlich zu machen. Außerdem wird der Ontologie- und Folksonomy-Einsatz innerhalb von Empfehlungssystemen beleuchtet, um Chancen und Risiken der Anwendung von Methoden der Wissensrepräsentation für zukünftige Forschungsarbeiten einschätzen zu können.

Recommender Systems in an Information Science View – The State of the Art

Recommender systems offer content individually to users in the WWW, based on their concrete needs, preferences and interests. Those systems can propose products, services, users (with analogous interests), etc.) and represent a special form of personalisation as well as of social networking – exactly in the Web 2.0 age. Recommender systems offer e.g. suppliers in the e-commerce a crucial market advantage. So, the evaluation of the customer data has high priority at big companies like Amazon, Google or Ebay. For this reason we engaged in recommender systems, which take up the user's needs in different ways, to "anticipate" needs and make suggestions (from different areas) to the user. This review article achieves a definition and representation of operations and methods of recommender systems. Exactly the different methodologies of those services should be expounded comparatively on that occasion in order to represent advantages and disadvantages. The use of ontologies and folksonomies as implementations in recommender systems is portrayed in order to be able to take into consideration chances and risks of the application of knowledge representation methods for future researches.

Empfehlungssysteme

Im vorliegenden Artikel wird ein Forschungsüberblick über das Gebiet der Empfehlungssysteme gegeben [vgl.: Höfeld, Kwiatkowski 2007]. Empfehlungssysteme arbeiten kollaborativ und erweisen sich damit als sehr effektiv. Sie arbeiten auf der Basis von Ähnlichkeitsmetriken, um Empfehlungen für ihre Nutzerchaft abzugeben. Dabei analysiert das System Nutzerprofile oder Produkte mit dem Ziel, Ähnlichkeiten zu erkennen, auf deren Basis Vorschläge generiert werden. Empfehlungen werden bei bestimmten Arten von Empfehlungssystemen

auf der Basis von Nutzungsdaten anderer Nutzer gegeben. Ihnen ist die Eigenschaft des sozialen Vorgehens inhärent, bei der Nutzer von Aktivitäten anderer profitieren. Des Weiteren können Ontologien und Folksonomies in derartige Systeme integriert werden, welche dann mittels semantischer Strukturgebung bzw. sozialem Taggen elaborierte Such- und Navigationsverfahren zulassen.

Um den Nutzen von Empfehlungssystemen zu erkennen, bedarf es einer Sichtung der Veränderungen des Internet in den vergangenen Jahren. Seit den 1990er Jahren entstand eine immense Datenflut

im WWW. Die Größe des Web wächst seither rapide an. Produktpaletten im Bereich des E-Commerce werden täglich um ein Vielfaches vergrößert und es gibt kaum etwas, das nicht via Internet bezogen werden kann; so stellt die Bestellung von Kleidung, Autos und sogar Medikamenten über das Internet heute kein Problem mehr dar. Allerdings steigt mit der großen Vielfalt des Angebots auch die Anzahl der Entscheidungsmöglichkeiten für den Nutzer ins Unermessliche; Loren Terveen und Will Hill sprechen in diesem Zusammenhang von einem „Universe of Alternatives“ [Terveen, Hill 2001, 3]. Die Menschen verspüren deshalb ein wachsendes Bedürfnis nach Berücksichtigung ihrer individuellen Situation. Gefordert werden Systeme, die einen Überblick verschaffen und personalisierte Angebote machen können, um dem Nutzer eine Entscheidungshilfe zu geben, die mit einer enormen Zeitersparnis verbunden ist. Auch der wirtschaftliche Vorteil von Personalisierungen ist hervorzuheben:

[Die] Personalisierung [...] dient dem Hersteller eines Produktes als Argument und Instrument der Vermarktung. Dem Verbraucher eines personalisierbaren Produktes hilft sie hingegen, Arbeitsabläufe effektiver zu gestalten. Beide Sichten zeigen, dass Personalisierung in der modernen Zeit ein wichtiges Werkzeug ist, um den Erfolg eines Produktes positiv zu beeinflussen, indem letztlich die Wünsche seines Verbrauchers beachtet werden. [Aehnel 2003, 130]

Empfehlungssysteme („Recommender Systems“) sollen hierzu einen Beitrag leisten. Abbildung 1 zeigt die groben Züge eines Empfehlungssystems. Demnach kann ein Nutzer, der eine Empfehlung wünscht, eine direkte Anfrage an das System stellen. Das System kann Empfehlungen jedoch auch unaufgefordert geben. Die Vorschläge basieren stets auf Präferenzen, welche vom Nutzer freiwillig abgegeben werden können oder nach Aufforderung des Systems seitens des Nutzers preisgegeben werden. Das Empfehlungssystem kann – je nach Implementierung – darüber hinaus mittels Ähnlichkeitsmetriken Nachbarschaften zu anderen Nutzerprofilen ermitteln und

diese in die Abgabe bestimmter Empfehlungen einbeziehen. Das bedeutet, dass ein Empfehlungssystem mit den Präferenzen des aktiven Nutzers oder aber mit Präferenzen von anderen Nutzern arbeiten kann. Tapestry gilt als das erste System, das basierend auf der Technik des kooperativen Filterns agiert. Die Erfinder dieser Empfehlungsweise sind Goldberg, Nichols, Oki und Terry [Goldberg et al. 1992].



Abbildung 1: Der Prozess eines Empfehlungssystems.

Quelle: Terveen, Hill 2001, 4.

Empfehlungssysteme können – ähnlich den Profildiensten – im Bereich der Informations- und Nachrichtenportale eingesetzt werden. Darüber hinaus finden sie bei E-Learning-Systemen Verwendung, wo sie personalisierte Lernstrategien und individuelle Empfehlungen liefern, die auf dem Kenntnisstand einzelner Personen fundieren; sie können damit Lerneinheiten vorschlagen [vgl.: Aehnel 2003, 136]. Außerdem werden Expertensysteme mit dieser Technik ausgestattet. Im Bereich des E-Commerce finden sich viele Facetten von Empfehlungssystemen wieder. Die Vorteile für den Einsatz in diesem Bereich sind bei Schafer et al. [1999] zusammengestellt. Sie reichen von der Kundenbindung über die Neuentwicklung von Produkten bis hin zu kontext-/kundenabhängigem Marketing durch personalisierte Entscheidungshilfen und Vorschläge. Empfehlungstechniken können darüber hinaus bei E-Mail-Systemen (im Bereich der Spam-Erkennung) eingesetzt werden [vgl.: Stock 2007, 490].

Klärung der Terminologie

Der Begriff „Recommender System“ bzw. zu Deutsch „Empfehlungssystem“ oder auch „Vorschlagssystem“ wird in der einschlägigen Literatur häufig gleichgesetzt mit dem Begriff „collaborative filtering“, zu Deutsch kooperatives Filtern. Dies ist unserer Ansicht nach – übereinstimmend mit Resnick und Varian [1997] – nicht ganz korrekt bzw. unscharf. Ein Empfehlungssystem kann sehr unterschiedliche Komponenten und damit einhergehende Vorgehensweisen beinhalten. Im vorliegenden Artikel wird „Empfehlungssystem“ als Oberbegriff für alle Vorschlags-/ bzw. Empfehlungssysteme gebraucht; das bedeutet: Der Terminus „Empfehlungssystem“ im Kontext dieses Artikels bezieht sich ganz allgemein auf Systeme,

die Nutzern Empfehlungen aussprechen. Diese können dann – wie im Organigramm (Abbildung 2) gezeigt – personalisiert oder nicht-personalisiert sein. Erst auf dieser Stufe werden dann unterhalb der personalisierten Empfehlungssysteme verschiedene Techniken, wie z.B. regelbasiert, kooperativ oder nutzerzentriert usw. unterschieden. Nicht-personalisierte Systeme bieten allen Kunden identische Empfehlungen an. Dies ist

zum Beispiel bei Information Retrieval-Systemen wie den herkömmlichen Suchmaschinen der Fall. In diesem Artikel liegt jedoch auf personalisierten Empfehlungssystemen.

In jenem Bereich existieren einige Ansätze, wobei kooperatives Filtern („collaborative filtering“) sowie inhaltsbasiertes Filtern am geläufigsten sind und terminologisch recht einheitlich gebraucht werden.




Abbildung 2: Einordnung der personalisierten Empfehlungstechniken.

Verschiedene Ansätze im Bereich der Empfehlungssysteme

Neben den zwei geläufigsten Ansätzen gibt es weitere Ansätze; eine Übersicht der unterschiedlichen Herangehensweisen bietet Burke [2002]. In Abbildung 3 sind – neben dem kooperativen und dem inhaltsbasierten Filtern – drei weitere Ansätze, deren Begrifflichkeiten und Bezeichnungen in der Wissenschaft nicht homogen verwendet werden, aufgeführt. Burke [2002] wählt seine Klassifizierung im Hinblick auf Hintergrund- und Inputdaten sowie den Empfehlungsprozess (in dem Hintergrund- und Inputdaten kombiniert werden). Hintergrunddaten sind Informationen, die seitens des Systems zur Verfügung gestellt werden, Inputdaten gibt der Nutzer ein, um Empfehlungen zu erhalten. Andere mögliche Klassifizierungen für Empfehlungssysteme wählen als Kriterien bspw. die Art der Benutzerschnittstelle oder aber die Eigenschaften der Interaktion von Nutzer und System [vgl.: Burke 2002, 332]. Eine einheitliche Einteilung der Techniken und Ansätze sowie eine standardisierte Terminologie wären wünschenswert, um einen Über-

blick über bestehende Herangehensweisen erlangen zu können.

Zur Erläuterung von Burkes Kürzeln in Abbildung 3: **I** ist die Menge aller Objekte, die empfohlen werden können, **U** steht für die Menge der Nutzer, deren Präferenzen bekannt sind, **u** ist der Nutzer, dem etwas empfohlen werden soll, und **i** präsentiert ein bestimmtes Objekt, für das die Präferenz für den Nutzer **u** vorausgesagt werden soll [vgl.: Burke 2002, 332].

Die wesentlichen Unterschiede und Akzentsetzungen werden anhand von Burkes Tabelle sehr gut ersichtlich. So lässt sich etwa schnell erkennen, dass beim kooperativen Filtern (collaborative filtering) die Menge aller Nutzer eine Rolle spielt, wohingegen das inhaltsbasierte Filtern auf den Bewertungen eines Individuums beruht.

Demografische Empfehlungssysteme teilen Nutzer nach festgelegten Stereotypen in Gruppen ein, basierend auf persönlichen Eigenschaften. Solche Stereotypen können bspw. sein: Mutter, Unternehmer,

Student. Aufgrund der demografischen Klassen werden dann Empfehlungen gegeben [vgl.: Rich 1979; Krulwich 1997; Pazzani 1999; Montaner et al. 2004]. Nutzenbasierte Empfehlungsansätze versuchen nicht, langfristige Verallgemeinerungen bezüglich

der Nutzer zu entwickeln, wie dies beim demografischen Filtern der Fall ist; die Empfehlungen beruhen hier vielmehr auf Übereinstimmungen zwischen den geäußerten Bedürfnissen der Nutzer und den Eigenschaften und Attributen der Objekte. Es werden also Berechnungen bezüglich des Nutzens eines Objekts für den jeweiligen Nutzer durchgeführt [vgl.: Guttman, Maes 1998].

Wissensbasierte Empfehlungssysteme ziehen Schlussfolgerungen, um aus den Präferenzen der Nutzer funktionales Wissen über die Korrelation der Bedürfnisse des Nutzers und bestimmter Objekte abzuleiten. Das funktionale Wissen solcher Systeme ermittelt bspw. den Nutzen eines bestimmten Produkts für eine Person. Im Gegensatz zu der Herangehensweise bei nutzenbasierten Empfehlungssystemen werden bei wissensbasierten Techniken nicht nur die Eigenschaften der Produkte in der Wissensbasis hinterlegt, es wird darüber hinaus ein Profil über den Bedarf des Nutzers erstellt, um diesen dann mit verschiedenen Produkteigenschaften abgleichen zu können. Die Wissensbasis spielt damit eine äußerst wichtige Rolle [vgl.: Burke 2000; Towle, Quinn 2000].

Loren Terveen und Will Hill [2001] beschreiben einen weiteren Ansatz für Empfehlungssysteme, der bei Burkes Klassifizierung unerwähnt bleibt: den Ansatz des sozialen Data Mining. Solche Systeme fangen implizite Präferenzen ein, indem sie Daten zur Nutzer-Aktivität analysieren. Kauf-, Navigations- oder Klickhistorien werden ausgewertet, um darin mittels Mustererkennung Regelmäßigkeiten aufzuspüren, die für die Empfehlungen genutzt werden können.

Ansatz	Hintergrund	Input	Prozess
Kooperativ	Bewertungen von U in den Objekten I.	Bewertungen von u zu Objekten in I.	Identifikation von ähnlichen Nutzern in U und Einbeziehung ihrer Bewertungen von I.
Inhaltsbasiert	Merkmale der Objekte in I.	Bewertungen von u zu Objekten in I.	Generierung eines Klassifizierers, der das Bewertungsverhalten von u berücksichtigt, um es auf I anzuwenden.
Demografisch	Demografische Informationen über U und deren Bewertungen von Objekten in I.	Demografische Informationen über u.	Identifikation von demografisch ähnlichen Nutzern von u und Einbeziehung ihrer Bewertungen von I.
Nutzenbasiert	Merkmale der Objekte in I.	Nützlichkeitsfunktion über Objekte in I, die die Präferenzen von u beschreibt.	Abgleich der Nützlichkeitsfunktion mit den Objekten und Festlegung des Ranges von I.
Wissensbasiert	Merkmale der Objekte in I. Wissen darüber, ob diese Objekte im Interessensfeld des Nutzers liegen.	Beschreibung der Bedürfnisse und Interessen von u.	Entscheidung zwischen I und dem Interesse von u finden.

Abbildung 3: Einteilung der verschiedenen Techniken von personalisierten Empfehlungssystemen nach Burke.

Quelle: Burke 2002, 332.

Die folgenden Ausführungen beschränken sich auf die beiden wichtigsten, konkurrierenden Ansätze im Bereich der Empfehlungssysteme.

Kooperatives Filtern (collaborative filtering)

Das kooperative Filtern wird bei Empfehlungssystemen am häufigsten eingesetzt. Kooperative Systeme geben einzelnen Nutzern Empfehlungen zu Objekten auf der Basis zuvor gesammelter Bewertungen anderer Nutzer. Diese Bewertungen können binär (mögen/nicht mögen) oder aber metrisch skaliert sein. Ziel ist entweder die Voraussagung des Nutzens eines bestimmten Objekts *i* für den aktiven Nutzer *u*, oder aber die Empfehlung einer Liste von mutmaßlich interessanten Objekten aus der Menge *I*, basierend auf den Beurteilungen des Nutzers und den Bewertungen anderer Nutzer mit ähnlichen Profilen. Damit werden Ähnlichkeiten von Nutzerprofilen aufgespürt, um Prognosen für die personalisierten Empfehlungen geben zu können. Von den Präferenzen und Beurteilungen der nächsten, d.h. also dem Profil am ähnlichsten Nutzern – den sog. „Nachbarn“ – werden die Empfehlungen für den Nutzer *u* abgeleitet. Es wird dazu eine gewichtete Kombination der Beurteilungen der Nutzergruppe, deren Mitglieder als Nachbarn in Frage kommen, berechnet und auf Basis dessen eine Empfehlung für den aktiven

Nutzer generiert. Schafer et al. [1999, 161] reden in diesem Sinne von einer „Mensch-zu-Mensch-Korrelation“. Gemeinsamkeiten in Nutzerprofilen können mittels des Vektorraummodells realisiert werden, wie Stock schreibt:

Man kann solch ein System beispielsweise im Rahmen des Vektorraummodells konstruieren, in dem die Nutzer durch Vektoren und die Dokumente als Dimensionen dargestellt werden. Der konkrete Vektor des Nutzers *N* ergibt sich durch die angesehenen (oder die gekauften oder die als positiv bewerteten) Dokumente bzw. Produkte. Die Ähnlichkeit zu anderen Nutzern ergibt sich durch die Berechnung des Cosinus der jeweiligen Vektoren. Über einen Schwellenwert der Ähnlichkeit (Cosinus) erkennt das System diejenigen anderen Nutzer, die dem Ausgangsnutzer am ähnlichsten sind.

Alles das, was diese ansehen, kaufen oder als positiv bewerten, wird dem Ausgangsnutzer als Empfehlung angezeigt. [Stock 2007, 491]

Abbildung 4 soll den Prozess des kooperativen Empfehlens noch einmal veranschaulichend darstellen.




Abbildung 4: Der Prozess des kooperativen Empfehlens.

Quelle: Sarwar 2001, 288.

Das Ergebnis ist also entweder eine Liste von Objekten, im Sinne einer Empfehlung mehrerer Objekte, oder aber eine Berechnung der Wahrscheinlichkeit, dass ein bestimmtes Objekt Gefallen finden könnte. Es existieren in dem Modell *m* Nutzer $U = \{u_1, u_2, \dots, u_m\}$ und eine Liste von *n* Objekten *I*. Jeder Nutzer *u_i* besitzt eine Liste von Objekten, über die das Profil des Benutzers errechnet wird. I_{ui} stellt eine Teilmenge von *I* dar und kann auch die Nullmenge sein. Für den aktiven Nutzer *u_a* (als Teil der gesamten Nutzergruppe *U*) soll dann eine Empfehlung ausgesprochen werden, die aufgrund des oben erwähnten Nachbar-Algorithmus durchgeführt wird.

Kooperatives Filtern kann auf zwei unterschiedliche Herangehensweisen zurückgreifen: es gibt eine modell- und eine speicherbasierte Variante. Bei der spei-

cherbasierten Variante werden alle Berechnungen mittels Kosinus- oder Korrelationsbasiertem Ähnlichkeitsmaß direkt auf einer Datenmatrix ausgeführt. Bei der modellbasierten Variante hingegen wird offline ein Modell gelernt, auf das dann online zurückgegriffen werden kann. Es muss nicht mehr die komplette Datenmatrix aufgerufen werden. Bei dieser Form werden u.a. Techniken, wie die Neuronalen Netzwerke, Latente Semantische Analyse, Clusteranalyse oder Bayessche Netzwerke eingesetzt. Der Nachteil der modellbasierten Variante ist die stets zu wartende Aktualität des Modells sowie der einhergehende Informationsverlust bei der Reduktion auf ein Modell. Allerdings sind die Berechnungszeiten zur Laufzeit wesentlich kürzer, als dies bei speicherbasierten Verfahren der Fall ist, bei denen das komplette Datenmaterial aufgerufen werden muss.

Inhaltsbasiertes Filtern (content-based filtering)

Beim inhaltsbasierten Filtern handelt es sich um eine Objekt-zu-Objekt-Korrelation. Dem Nutzer werden Objekte angeboten, die seinem Nutzerprofil zufolge passend wären. Dieses Wissen wird von den Profilen des einzelnen Nutzers abgeleitet und bezieht nicht – wie beim kooperativen Filtern – die Profile und Bewertungen anderer Nutzer mit in die Berechnung ein. Empfehlungen werden auf der Basis von Objekten, die der Nutzer in der Vergangenheit bewertet hat, gegeben. Daher werden Algorithmen eingesetzt, die anhand von Nutzerprofilen lernen, welche Produkte noch interessant sein

könnten. Das System lernt Präferenzen von Nutzern zu analysieren, indem diese ein Feedback abgeben, welches implizit oder explizit sein kann. Anhand der gewonnenen Daten wird ein Profil erstellt, das durch Nutzer-Feedback weiter modifiziert werden kann. Wird dem Nutzer eine Webseite vorgeschlagen, so können die Wörter jenes Dokuments mit ihren Gewichtungen – sofern er die Empfehlung als positiv erachtet – in sein Nutzerprofil aufgenommen werden [vgl.: Balabanovic, Shoham 1997, 67].

Entstanden ist diese Form der Empfehlungssysteme aus der Technik der Informationsfilterung. Die Merkmale der Objekte spielen hier die größte und wichtigste Rolle. Ein inhaltsbasiertes Empfehlungssystem lernt anhand der Merkmale, die Nutzerprofile zu analysieren. Die Lernmethodiken entscheiden über die

Art des Nutzerprofils, mögliche Anwendungen sind Entscheidungsbäume, Neuronale Netze oder vektorbasierte Repräsentationen [vgl.: Burke 2002, 333]. Inhaltsbasierte Empfehlungsansätze eignen sich i.d.R. eher für Texte als für Musik oder Bilder, weil der Inhalt von Texten einfacher analysiert und dargestellt werden kann. Bestimmte Worte innerhalb der Texte werden gewichtet, um die Relevanz eines Dokuments für einen bestimmten Nutzer feststellen zu können, indem die gewichteten Wörter mit seinen Präferenzen abgeglichen werden. Inhaltsbasierte Empfehlungsansätze eignen sich auch bedingt für die Empfehlung von Produkten. Dies ist aber nur dann der Fall, wenn der Benutzer das Angebot eines Online-Shops regelmäßig nutzt und seine Präferenzen in Form von Produktbewertungen abgibt. Der News-Alert-Service von Google ist ein Beispiel für inhaltsbasiertes Filtern. Nach Eingabe verschiedener Suchwörter durch den Nutzer wird dieser informiert, wenn es im Nachrichtenbereich Meldungen gibt, die die angegebenen Suchwörter enthalten.

Vergleich von inhaltsbasiertem und kooperativem Filtern

Auf dem Feld der Empfehlungssysteme gibt es diverse Probleme, die Aussagen über die Qualifizierung einzelner Ansätze zulassen. Ein Problem, das viele Ansätze betrifft, ist der potentielle Eingriff in die Privatsphäre. Stock betont:

[...] beim Recommending [wird] eindeutig die Privatsphäre des Nutzers berührt. Je mehr Informationen über einen Nutzer vorliegen, desto besser werden die Vorschläge für ihn – desto mehr wissen die Anbieter der Vorschlagsysteme aber auch über ihn. [Stock 2007, 493]

Der Erwerb impliziter Bewertungen birgt in diesem Fall eine große Gefahr. Bei der expliziten Angabe von Präferenzen besteht darüber hinaus immer das Problem der Motivierung der Nutzer, um Angaben derselben zu erhalten. Wenn sich auf den ersten Blick kein direkter Vorteil für den Nutzer zeigt, ist die Wahrscheinlichkeit sehr hoch, dass er keine Angaben macht bzw. wenig Zeit in seine Tätigkeit investiert, was die Authentizität der Daten beeinflusst. Anonyme oder unter Pseudonymen abgegebene Profile wären in diesem Fall ein Lösungsvorschlag, bei dem für den Nutzer allerdings auf den ersten Blick kein positives Aufwand-Nutzen-Verhältnis erkennbar ist, es besteht folglich die Gefahr fehlerhafter expliziter Bewertungen.

Generell eignen sich Empfehlungssysteme (je nach Ansatz) nur bei vorhandenen, großen Datenmengen oder einer

hohen Nutzeranzahl. Kooperative Empfehlungssysteme sind auf eine hohe Anzahl nutzerbezogener Daten angewiesen, während bei inhaltsbasierten Systemen präzise und umfangreiche semantische Beschreibungen unablässig sind [vgl.: Hayes et al. 2002]. Inhaltsbasierte Ansätze sind auf dem genannten Gebiet durch die deskriptiven Merkmale, die mit den zu empfehlenden Objekten zusammenhängen, beschränkt. Beispielsweise ist eine Empfehlung im Bereich Musik-CDs abhängig von festgelegten Eckdaten: Genre, Band, Sänger usw. Kooperative Systeme sind hingegen nur auf die Nutzer-Bewertungen angewiesen; sie sind unabhängig von deskriptiven Beschreibungen. Hier zeigt sich die größte Stärke kooperativer Systeme, weil sie unabhängig von maschinenlesbaren Repräsentationen und dennoch für die Empfehlung komplexer Objekte, wie z.B. Musik oder Film geeignet sind. Es ist ein geringerer Initialaufwand notwendig, weil die zu empfehlenden Objekte – im Gegensatz zum inhaltsbasierten Ansatz – nicht beschrieben werden müssen. Am sinnvollsten einsetzbar sind kooperative Systeme dort, wo persönliche Vorlieben und individueller Geschmack als Entscheidungskriterien dienen [vgl.: Burke 2002, 332].

Bei inhaltsbasierten Techniken muss der Datenbestand fortlaufend gepflegt werden, weil neue Produkte sonst nicht empfohlen werden können. Es entsteht ein großer Aufwand, da alle Objekte stets deskriptiv beschrieben werden müssen, bevor sie dem System zur Verfügung stehen. Allerdings ergibt sich dadurch der Vorteil, dass die Empfehlungen auch inhaltsbezogen umgesetzt bzw. realisiert werden können. Die Beschreibung des Inhalts ist bei Textdokumenten unter Umständen noch realisierbar, bei Objekten aus den Bereichen Musik, Film oder Bild entsteht allerdings eine große Hürde. Außerdem können Kriterien wie Ästhetik, Aktualität oder Qualität der Information sowie Ladezeiten der Seiten oder aber Text, der in Bildern integriert ist, nicht berücksichtigt werden [vgl.: Balabanovic, Shoham 1997, 67].

Oftmals leiden inhaltsbasierte Empfehlungen auch an dem Problem der Überspezialisierung, weil nur Objekte, die hoch bewertet wurden, empfohlen werden – nicht-bewertete Dokumente werden ignoriert, obwohl sie relevant sein könnten. Burke spricht in diesem Zusammenhang von dem „banana problem“. Es beruht auf der Beobachtung, dass Bananen sehr beliebt sind und in den meisten amerikanischen Lebensmittelgeschäften vorrätig sein sollten. Ein Empfehlungssystem würde aus marktbasierter Gründe ständig Bananen empfehlen, weil diese oft gekauft werden. Burke zeigt die Problematik jenes Kontextes auf:

These drawbacks are not significant for some large e-commerce sites, such as Amazon.com, with a very large customer base, and a large and diverse product line that lends itself to multi-item purchases. A more difficult challenge is presented for a product such as an automobile that is bought much less frequently and one at a time. For an automobile, a home loan or any other infrequently purchased item, the system will not be able to use marketbasket or purchase history to make recommendations. A recommender system would never be able to say „people who bought a Geo Metro also bought a Ford Escort,“ because that is not how people buy cars. [Burke 1999, 69]

Im Gegensatz zu kooperativen Systemen sind inhaltsbasierte Systeme nicht sehr flexibel und beruhen nicht auf subjektiven Kriterien. Dafür ist der Empfehlungsprozess für den Nutzer transparent und damit auch beeinflussbar. Anders als beim kooperativen Filtern muss nicht unbedingt eine Mindestmenge an Nutzern vorhanden sein, um passende Vorschläge machen zu können.

Ein sehr bekanntes Problem beider Empfehlungssysteme, der kooperativen wie der inhaltsbasierten ist das sog. „Kaltstart-Problem“. Der Begriff umfasst zwei unterschiedliche Probleme, die miteinander in Beziehung stehen. Es geht zum einen um neue Nutzer (New-User-Problem): Diese müssen in ausreichender Anzahl Bewertungen besitzen, um kategorisiert werden zu können, da Empfehlungen lediglich auf Bewertungen von Objekten basieren. Eine äquivalente Problematik besteht in dem Kontext neuer Objekte (New-Item-Problem): Ein Objekt, das noch nicht viele Bewertungen erhalten hat, kann auch nicht ohne weiteres mittels Empfehlungstechnik vorgeschlagen werden. Die angesprochenen Probleme sind auch unter dem Begriff des „ersten Bewerters“ („early rater“) bekannt. Diese Begrifflichkeit manifestiert sich in dem Zusammenhang eines initialen Nutzers, der nicht von anderen Nutzern profitieren kann, indem er seine Bewertungen abgibt. Empfehlungssysteme sind demnach gefordert, Anreize für die Abgabe von Bewertungen zu geben [vgl.: Burke 2002, 333 f.].

Kooperative Empfehlungssysteme greifen nur bei Überschneidungen zwischen Nutzer-Bewertungen und haben demnach Schwierigkeiten, wenn dem System nur wenige Bewertungen zur Verfügung stehen; dieser Fall kann bspw. eintreten, wenn Nutzer bestimmte Objekte mehrfach bewerten, andere Objekte hingegen überhaupt nicht. Burke redet daher auch von einem „sparsity problem“. Bei kooperativen Systemen sollte demnach im Idealfall eine relativ kleine, statische Menge an Objekten sowie eine hohe An-

zahl an Nutzern vorhanden sein. Im Falle einer dynamischen Menge von Objekten bestünde das Problem, dass ältere Bewertungen für neue Nutzer nicht mehr von Interesse sein könnten. Wenn der Anteil der Objekte sehr hoch ist und die Nutzerinteressen hingegen klein sind, dann besteht die Gefahr, dass Überlappungen mit anderen Nutzern selten sind [vgl.: Burke 2002, 334].

Burke betont, dass kooperative Empfehlungssysteme am besten in bestimmten Nischen verwendet werden können:

Collaborative recommenders work best for a user who fits into a niche with many neighbors of similar taste. The technique does not work well for so-called „gray sheep“ [...] who fall on a border between existing cliques of users. [Burke 2002, 334]

Eine sehr große Stärke von kooperativen Empfehlungssystemen ist die Möglichkeit, verschiedene Genres zu empfehlen („Cross-Genre-Empfehlungen“). Burke redet in diesem Zusammenhang von „quer denken“ („outside the box“) [vgl.: Burke 2002, 334]. Es bedeutet, dass einem Jazz-Liebhaber bspw. auch Vorschläge aus dem Bereich der Rock-Musik gemacht werden können. Dies dient dazu, den Nutzer auf unbekannte Führten zu bringen, die er ohne Unterstützung nicht gefunden hätte [vgl.: Terveen, Hill 2001, 7 f.]. Inhaltsbasierte Systeme würden an dieser Stelle scheitern, da sie lediglich von den Präferenzen der Nutzer ausgehen.

Kooperative Empfehlungssysteme sind nur einsetzbar bei einer angemessenen Menge von Einträgen. Diese darf nicht zu klein, aber auch nicht zu groß sein. Bei zu großen Datenmengen würden speicherbasierte Verfahren an ihre Kapazitätsgrenzen hinsichtlich der Laufzeit stoßen, modellbasierte Verfahren erleiden unter solchen Bedingungen einen Mangel an Qualität, sobald die Datenmenge sehr groß ist. Ab einer bestimmten Größenordnung müssen demnach Abstriche im Hinblick auf die Qualität oder aber die Geschwindigkeit gemacht werden. Das Kaltstart-Problem hat den negativen Effekt, dass gelegentliche Nutzer des Systems nicht vollständig profitieren können. Bei inhaltsbasierten und kooperativen Systemen können den Nutzern höchstens einfache, marktbasiertere Empfehlungen gegeben werden. Lernbasierte Techniken sind am ehesten bei Nutzern anzusiedeln, die fähig und willig sind, Zeit und Mühe zu investieren, um im System individuelle Präferenzen zu hinterlegen.

Bei inhaltsbasierten Systemen liegt i.d.R. eine Beschränkung auf textuelle Dokumente vor. Komplexe Objekte wie z.B. Bilder lassen sich nur unzureichend beschreiben. Bei dem Ansatz entsteht zusätzlich die Gefahr, dass dem Nutzer solche Objekte empfohlen werden, die

denjenigen Objekten ähneln, die ihm bereits zuvor empfohlen worden sind [vgl.: Balbanovic, Shoham 1997, 67]. Des Weiteren gibt es beim inhaltsbasierten Filtern das Start-Problem, das darin besteht, dass genügend Objekt-Bewertungen vorliegen müssen, um einen leistungsstarken Klassifizierer zu etablieren.

Beim Vergleich des inhaltsbasierten und des kooperativen Empfehlungsansatzes fällt auf, dass sie sehr gegensätzlich sind. Jene Beobachtung äußert sich darin, dass die Schwächen des einen Ansatzes die Stärken des anderen darstellen und umgekehrt. Eine Kombination beider Techniken im Sinne eines Hybrid-Verfahrens drängt sich daher auf.

Hybride Empfehlungstechniken

Hybride Empfehlungssysteme kombinieren zwei oder mehr Techniken. Viele hybride Ansätze verbinden die Vorteile des kooperativen und des inhaltsbasierten Filterns, um einige grundlegende Probleme, wie das New-User-Problem (neuer Benutzer) oder das Sparsity-Problem (leere Nutzer-Objekt-Bewertungsmatrix) anzugehen. Den Nutzen solcher Verfahren untermauern Terveen und Hill:

[...] suppose one user has rated the NBA page from ESPN.com favorably, while another has rated the NBA page from CNN.com favorably. Pure collaborative filtering would find no match between the two users. However, content analysis can show that the two items are in fact quite similar, thus indicating a match between the users. [Terveen, Hill 2001, 14]

Ein Beispiel für diese Kombination ist das kooperative Objekt-zu-Objekt-Filtern („item-to-item collaborative filtering“), wie es von Amazon betrieben wird. Hier werden Empfehlungen der Form: „Nutzer die X gekauft haben, interessieren sich auch für Y“ geleistet. Der Ansatz geht maßgeblich auf Gregory D. Linden zurück [Linden et al. 1998/Linden et al. 2003]. Hauptkriterium ist die Einbeziehung der persönlichen Präferenzen des Nutzers sowie anderer Nutzer.

Der Empfehlungsprozess besteht bei Amazon (siehe Abbildung 5) aus einer Online- und einer Offline-Phase. Offline werden Ähnlichkeiten zwischen Objekten mittels der Nutzer-Objekt-Bewertungsmatrix errechnet. Es wird eine Ähnlichkeitstabelle für alle bewerteten Objekte erstellt. Die Ähnlichkeiten werden mittels des Kosinus ermittelt. In der Online-Phase können dem Nutzer dann ähnliche Produkte empfohlen werden [vgl.: Linden et al. 2003, 78 f.]. Beim traditionellen kooperativen Filtern fände an dieser Stelle nicht eine Berechnung ähnlicher Objekte, sondern ähnlicher Nutzerprofile

10 Dinge, mit denen wir uns auskennen

GUI, CMS, Podcast, Web 2.0, AJAX, XHTML, TYPO3, BITV, Load Balancing, IPTV

3-point concepts

Agentur für Kommunikation

3-point concepts GmbH

Chausseestraße 56

10115 Berlin

Tel.: +49-(0)30-28 51 98-0

Fax: +49-(0)30-28 51 98-28

info@3-point.de

www.3-point.de

trol over the amount of personal information supplied to the system, but require an investment in time and effort to yield connections. Implicit approaches, on the other hand, minimize effort, collect copious amounts of (sometimes noisy) data, and make the social element to recommender systems salient, but raise ethical issues. The secretive nature of these approaches often makes users feel as if they are under a microscope. [Perugini et al. 2004, 114]

Ein weiteres Problem beim expliziten Präferenz-Ausdruck liegt darin, dass der Nutzer keine Objekte beurteilen und bewerten kann, die er nicht kennt. Hayes et al. schreiben in diesem Zusammenhang:

However [...] the user is often not able to express an opinion on new items because he does not know them. A partial solution might be to provide a preview of the items in the recommendations, something Swearingen and Sinha found was appealing to users of recommendation systems. Ultimately the user is only able to evaluate the item after he has experienced it (listened to

a song, read an article, watched a movie ...). [Hayes et al. 2002, 8].

Alle Daten können (unabhängig von der Art des Erwerbs) als Vektoren dargestellt werden und damit das Nutzerinteresse repräsentieren. Um dem Nutzer Objekte zu empfehlen, werden mithilfe von Ähnlichkeitsmaßen (wie z.B. dem Kosinus) Äquivalenzen und Überschneidungen verschiedener Vektoren errechnet. Selbstverständlich können an dieser Stelle auch demografische Daten, wie bspw. Alter, Geschlecht, Nationalität etc. in die Berechnung einfließen. Diese müssten dann allerdings aktiv vom Nutzer eingegeben werden (explizite Profilerstellung).

Der Einsatz von Ontologien bei Empfehlungssystemen

Middleton et al. [2001] schlagen einen Ansatz zur Integration von Ontologien bei der Profilerstellung von Empfehlungssystemen vor. Mittels der Ontologie wird dabei Domänen-Wissen für die Akquise von Nutzer-Präferenzen genutzt. Die Forscher gebrauchen ihr Empfehlungssystem

tem *Quickstep*, das sich gemäß eines hybriden Verfahrens, wie wir es bereits vorgestellt haben, die Vorteile des inhaltsbasierten sowie des kooperativen Filterns zu Nutze macht. Die verwendete Ontologie basiert auf der *dmoz*-Taxonomie für computerlinguistische Themen.²

Die Profile der Nutzer werden durch das Beobachten der Nutzeraktionen im Hintergrund analysiert. Dabei werden Webseiten, die vom Nutzer häufig frequentiert werden, gesondert berechnet, um daraus ein Interessenprofil zu erstellen. Die positiv eingeordneten Seiten gehen außerdem in einen Pool von Beispielen ein, um auch für neue Nutzer Empfehlungen in definierten Themengebieten geben zu können. Maschinenlern-Techniken werden eingesetzt, um effizient von dem Monitoring profitieren zu können, dabei werden URLs, die der Nutzer „durchbrowst“, mittels eines Algorithmus klassifiziert und gespeichert.

Für jede Seite werden Merkmalsvektoren errechnet, die die thematischen Inhalte repräsentieren. Dabei zeigen Termvektoren

² Quelle: www.dmoz.com/Computers/Computer_Science



Herbstlehrgang 2007 für Informationsassistenten

Berufsbegleitende Fortbildung der DGI in Frankfurt am Main

Zum fünften Mal bietet die DGI ihre Berufsbegleitende Fortbildung Informationsassistent/in an. Der Intensiv-Lehrgang, der von Informationsexperten betreut wird, vermittelt in nur vier Wochen Mitarbeitern aus Wirtschaft, Handel, Medien und Verwaltung alle relevanten theoretischen Grundlagen und vertieft ihre praktischen Kenntnisse für eine erfolgreiche Tätigkeit im Bereich Information und Dokumentation. Die Schulung ist besonders für Nicht-Akademiker geeignet. Teilnahmevoraussetzungen sind Englischkenntnisse, EDV-Grundlagen, erste Erfahrungen im Umgang mit Datenbanken und Internet- bzw. Online-Diensten und möglichst Berufspraxis im Bereich Information und Dokumentation (oder eine vergleichbare Tätigkeit)

Inhalte der Fortbildung

- Beschaffen und Erschließen von Medien, Daten und Informationen
- Information Retrieval / Recherche
- Informationsaufbereitung / Informationsvermittlung
- Informationsdienstleistungen / Information Management
- Elektronische Zeitschriften / Portale
- Internet und Webseitengestaltung
- Medien- und Informationsmarkt / Fachinformationspolitik
- Urheberrecht / Datenschutz

Termine und Kosten

Die Fortbildung findet von Oktober bis November 2007 in zwei kompakten Lehrblöcken statt. Sie umfasst insgesamt vier Wochen Schulung, und zwar vom 22. Oktober bis 2. November und vom 19. November bis 30. November 2007, sowie einen zusätzlichen Tag am 14. Dezember 2007 für die Prüfung/Zertifizierung. Nach bestandener Abschlussprüfung erhalten die Teilnehmer das DGI-Zertifikat Informationsassistent. An der Fortbildung Informationsassistent/in können bis zu 15 Personen teilnehmen. Die Vergabe der Teilnehmerplätze erfolgt in der Reihenfolge des Eingangs der Anmeldungen. Veranstaltungsort ist die moderne und zentral gelegene Deutsche Nationalbibliothek in Frankfurt am Main. Dort stehen ein Schulungsraum mit PC-Arbeitsplätzen und alle Angebote der Nationalbibliothek (u.a. Cafeteria, Lesesaal) zur Verfügung. An einem Tag ist eine Exkursion zum Deutschen Institut für Internationale Pädagogische Forschung in Frankfurt am Main vorgesehen. Die Lehrgangsgebühr beträgt 1.250,- EUR (DGI-Mitglieder erhalten 20 Prozent Rabatt).

Kontakt und Anmeldung

Deutsche Gesellschaft für Informationswissenschaft und Informationspraxis e.V., Hanauer Landstraße 151-153, 60314 Frankfurt am Main, Tel.: (0 69) 43 03 13, Fax: (0 69) 4 90 90 96, informationsassistent@dgi-info.de, www.dgi-info.de/ausbildung/infass.html

ren mittels einer Liste von gewichteten Worten an, wie oft ein Wort in dem Dokument vorkommt. Die Vektoren indizieren damit eine thematische Relevanz/Irrelevanz bezüglich eines bestimmten thematischen Komplexes. *Quickstep* nutzt die ontologische Repräsentation von wissenschaftlichen Forschungspapieren als „Multiklassen-Repräsentation“, in der jede Klasse ein Forschungsthema repräsentiert. Ein Klassifizierer ordnet dann mittels Berechnungen zur Wahrscheinlichkeit während des Browsing-Vorgangs des Nutzers jedes Forschungspapier einer Klasse in der thematisch kategorisierten Ontologie zu. Die Ähnlichkeiten zwischen Klasse und Dokument werden mithilfe des oben beschriebenen Verfahrens der Merkmalsvektoren abgeglichen. Das Dokument, dessen Merkmalsvektoren denen der Klasse am ähnlichsten sind, wird in die Klasse eingeordnet. Basierend auf den dargestellten Berechnungen erhalten die Nutzer dann Empfehlungen [vgl.: Middleton et al. 2001, 102]. Das jeweilige Nutzerprofil setzt sich dann aus einem expliziten Feedback seitens des Nutzers sowie den Themenbereichen, in die die klassifizierten Links eingeordnet wurden, zusammen. Das System berechnet somit in regelmäßigen Abständen Korrelationen zwischen Nutzerprofilen und klassifizierten Themenbereichen und gibt Empfehlungen. Dabei konzentriert sich *Quickstep* auf wissenschaftliche Artikel – womit der thematische Bereich eingedämmt und die Klassifizierung präziser ist. Sobald der Nutzer einer Empfehlung nachgeht, wird diese Aktion aufgezeichnet und geht wiederum mit in die Berechnung ein. Außerdem können die Nutzer zusätzliche Themenbereiche vorschlagen und Artikel-Klassifizierungen prüfen, falls Unstimmigkeiten mit der Klassifikation aufgetreten sind. Damit wird das Trainingsmaterial stets neu bearbeitet und modifiziert [vgl.: Middleton et al. 2001, 101]. Die Verwendung von ontologischem Wissen innerhalb eines Empfehlungssystems stellt einen weiteren großen Vorteil dar: Das Kaltstart-Problem, das viele herkömmliche Systeme besitzen, kann behoben werden. Wie bereits erläutert, können Empfehlungen nur auf der Basis von bereits existierenden Bewertungen generiert werden, da Empfehlungssysteme auf Lernphasen basieren, mittels derer Nutzerprofile erstellt werden können. Wenn kein Nutzer Bewertungen abgegeben hat, scheitert ein kooperatives Empfehlungssystem bereits zu Beginn. Ein inhaltsbasiertes System hingegen ist auf die Bewertung von Objekten angewiesen. Liegen für bestimmte Inhalte keine derartigen Bewertungen vor (dies ist z.B. bei neuen Produkten in der Datenbasis der Fall), so können in Folge dessen auch

keine Empfehlungen für den Inhalt gegeben werden:

Content-based and hybrid recommender systems perform a little better since they need just a few examples of user interest in order to find similar items. No recommender system can cope alone with a totally cold-start however, since even content-based recommenders require a small number of examples on which to base recommendations. We propose to link together a recommender system and an ontology to address this problem. The ontology can provide a variety of information on users and their publications. [Middleton et al. 2001, 101]

Ontologien, die semantische Wissensstrukturen darstellen, können das Kaltstart-Problem bei Empfehlungssystemen lösen, indem sie Domänenwissen und Nutzerinformationen zur Verfügung stellen [vgl.: Middleton et al. 2001, 101]. Middleton et al. schlagen daher in einem späteren Artikel [Middleton et al. 2002] die Symbiose des Ontologieeinsatzes und ihrem Empfehlungssystem für Forschungspapiere vor.

In ihrem Ansatz wählen sie eine Ontologie, deren Informationen automatisch aus Web-Datenbanken verschiedener Forschungsabteilungen extrahiert wurden. Damit sind dem System Nutzerpräferenzen bezüglich einer Domäne und das Nutzerverhalten bekannt. Zwischen Ontologie und Empfehlungssystem findet hier eine Symbiose statt: Mittels der Ontologie wird das Kaltstart-Problem des Empfehlungssystems gelöst, da jene bereits Input-Daten liefert. Auf der anderen Seite behebt das Empfehlungssystem die Schwierigkeit des Erkennens von Interessen [Middleton et al. 2002, 2].

Das mittels Monitoring beobachtete Verhalten der Nutzer wird also durch Wissen über bestimmte Nutzer in bestimmten Domänen ergänzt. Das Wissen, das aus Publikationen extrahiert wurde, kann etwa Aufschluss darüber geben, welche Interessengebiete ein Nutzer in der Vergangenheit hatte, um daraus Wissen über spezifische Domänenzusammenhänge ziehen zu können. Middleton et al. berechnen Ähnlichkeiten zwischen Nutzern, um somit dem „New-User“-Problem entgegenzuwirken [Middleton et al. 2002, 2].

Für das Vorhaben implementieren sie [2002] wiederum das Empfehlungssystem für Forschungspapiere: *Quickstep*. Als Ontologie dient eine aus dem akademischen Forschungsbereich generierte Wissensrepräsentation. Zusätzlich setzen sie *OntoCoPI* ein; die Architektur des Gesamtsystems ist in Abbildung 6 dargestellt. Jenes System soll Communities hinsichtlich eines thematischen Komplex-

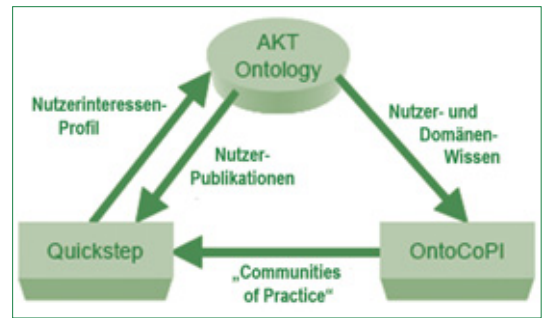


Abbildung 6: Die Integration einer Ontologie in einem Empfehlungssystem.

Quelle: Middleton et al. 2002, 5

xes aufspüren, um ähnliche Nutzer zu finden [Middleton et al. 2002, 4 ff.].

OntoCoPI (Ontology-based Communities of Practice Identifier) ist ein System, das, basierend auf der AKT-Ontologie³, Communities of Practice (CoP) aufspüren soll, welche als das Umfeld einer Person bezeichnet werden können. Dazu gehören die – bezüglich bestimmter, gemeinsamer Merkmale – engsten Personen. Middleton et al. definieren CoPs als

[...] informal group of people who share some common interest in a particular practice. [Middleton et al. 2002, 4]

Mittels des *OntoCoPI*-Tools werden Instanzen und Relationen analysiert, um Muster zwischen Entitäten und deren Beziehungen zu entdecken. Beziehungen können spezifische Informationen freilegen, so z.B. über Personen, die am selben Projekt teilnahmen, derselben Organisation angehören oder aber über Mitautorschaften etc. Über transitive Beziehungen könnten hier wiederum Interessenspartner gefunden werden. Dies ist z.B. der Fall, wenn A mit B publiziert hat, und B mit C zusammenarbeitet. Hier ließe sich mithilfe von formalen Ontologiesprachen ableiten, dass auch zwischen A und C unter Umständen eine Interessensbeziehung besteht. Der Vorteil der ontologischen Repräsentation, im Gegensatz zu anderen Informationsnetzwerken, besteht darin, dass die Beziehungen unterschiedlich gewichtet werden können und damit die relative Relevanz indiziert wird [vgl.: Middleton et al. 2002, 5].

Der Einsatz von Folksonomies bei Empfehlungssystemen

Im Folgenden wird ein besonderer Ansatz auf dem Gebiet der Empfehlungssysteme dargestellt, der den Einsatz von Folksonomies einschließt. Es handelt sich um einen Forschungsansatz von Diedrich und Iofciu [2006], der, unseres Erachtens, großes Potenzial für die Zukunft der Empfehlungssysteme hat. Zunächst soll ein kurzer Exkurs in den Bereich der Folksonomies unternommen werden. Der Begriff „Folksonomy“ wurde von Thomas Vander Val geprägt und reprä-

3 www.aktors.org/publications/ontology

sentiert etymologisch ein Kunstwort, das sich aus den Begriffen „folk“ und „taxonomy“ zusammensetzt [vgl.: Spiteri 2005, 2]. Es geht dabei um Metadaten, die vom Nutzer erzeugt werden. Diese Metadaten sind Schlagwörter, die bspw. Bilder, Videos oder Bookmarks kennzeichnen. In Folksonomy-Systemen sind Tags (Schlagwörter) öffentlich zugänglich. Sie können also von anderen Nutzern eingesehen und verwendet werden. Die Tags dienen dann der Navigation im System oder zum schnellen Wiederauffinden von Inhalten im Web. Ein großer Vorteil von Folksonomies liegt darin, dass es keinen Unterschied zwischen der Annotierung von Texten sowie Bildern oder Videoinhalten gibt [Jäschke et al. 2006, 80].

Folksonomies werden häufig auch als „social classifications“ bezeichnet. Allerdings darf diese Begrifflichkeit nicht in die Irre führen – Folksonomies sind keinesfalls Klassifikationssysteme. Sie beinhalten weder Notationen noch Hierarchien. Dennoch können sie verwendet werden, um das Semantische Web zu erweitern, wie Jäschke et al. betonen:

Allgemein kann man Folksonomies als schwache Ontologien auffassen, wobei Tags durch Benutzer und Ressourcen miteinander verbundene Konzepte sind. Benutzer und Ressourcen können als Instanzen der Konzepte betrachtet

werden. Folksonomies stellen ein spannendes neues Feld für die Forschung dar, denn erstmals erzeugt eine sehr große Zahl von Menschen gemeinsam eine schwache Form von Metadaten und annotiert Inhalte. Es gilt, dieses Potential zu nutzen, um ausgehend von einfachen Strukturen, den Aufbau des SemanticWeb zu unterstützen. Ein besseres Verständnis der sozialen Struktur der Folksonomy kann dabei zum Stärken der begrifflichen Struktur beitragen. [Jäschke et al. 2006, 80]

Mittels Tags sind – selbst dokumentarisch ungeübte – Nutzer in der Lage, Schlagwörter für Einträge zu vergeben. Die Tags sollen den Inhalt des Dokuments derart beschreiben, dass er suchbar wird, wobei keinerlei paradigmatische Relationen unter den Tags existieren. Sie werden nicht von einem festgelegten Vokabular fixiert, sondern können frei kreierte Begriffe der Nutzer sein. Beispiele für den Einsatz von Folksonomies sind *Flickr*⁴ (für die Verwaltung von Fotos), *Del.icio.us*⁵ (System zum Management von Bookmarks), *Technorati*⁶ (im Bereich der Verwaltung von Weblogs), *YouTube*⁷ (für das Management von Videostreams), *Frassle*⁸, *Furl*⁹, *Simpy*¹⁰ oder *Spurl*¹¹ [vgl.: Spiteri 2005, 5; Peters, Stock 2007].

Spiteri [2005] begründet die hohe Popularität von Folksonomy-Systemen mit dem [...] desire to „democratize“ the way in which digital information is described and organized by using categories and terminology that reflect the views and needs of the actual end-users, rather than those of an external organization or body. [Spiteri 2005, 11]

Darüber hinaus argumentiert sie, dass derartige Systeme eine Chance darstellen, in der stetig ansteigenden Datenflut im WWW eine Orientierung leisten zu können sowie eine äußerst kostengünstige Alternative zu herkömmlichen Dokumentationssystemen darstellen.

Jörg Diederich und Tereza Iofciu [2006] schlagen in einem Artikel vor, Folksonomies zu nutzen, um damit CoPs (Communities of Practice) zu finden. Sie kreieren Nutzerprofile aus den Tags der Folksonomy. Die tagbasierten Nutzerprofile werden in ein Empfehlungssystem, das innerhalb der Domäne „Forschung“ ope-

4 www.flickr.com

5 <http://del.icio.us>

6 www.technorati.com

7 www.youtube.com

8 www.frassle.org

9 www.furl.net

10 www.simpy.com

11 www.spurl.com

97. Deutscher Bibliothekartag – Call for Papers

Vom 3. bis 6. Juni 2008 veranstalten der Berufsverband Information Bibliothek e.V. (BIB) und der Verein Deutscher Bibliothekare e.V. (VDB) in Kooperation mit dem Deutschen Bibliotheksverband e.V. (DBV) in Mannheim den 97. Deutschen Bibliothekartag als zentrale Fortbildungsveranstaltung für das deutsche Bibliothekswesen. Das Motto lautet: „Wissen bewegen. Bibliotheken in der Informationsgesellschaft“.

Folgende Schwerpunktveranstaltungen sind vorgesehen:

1. Wer bewegt das Wissen? – Die neuen Akteure der Informationswelt
2. Schritthalten mit dem gesellschaftlichen Wandel? – Demografische Entwicklung und Bildung
3. Kann sich das Wissen frei bewegen? – Wissen als Ware oder öffentliches Gut?

Ferner können Vorträge zu folgenden Themenkreisen eingereicht werden:

4. Wissensorganisation und Wissensvermittlung (z.B. Information Literacy, Leseförderung, (digitaler) Auskunftsdienst, Web 2.0, Bestandser-schließung)

5. Recht (z.B. Rechtemanagement, Medienrecht, Urheberrecht)
6. Wissensmarkt (z.B. Zeitschriftenproblematik, Erwerbungsfragen, Verlage, alternative Publikationsformen)
7. Technik und Technologie (z.B. Digitalisierung, Portale, Suchmaschinen, digitale Langzeitarchivierung, Bestandserhaltung)
8. Management und betriebliche Steuerung (z.B. Personalentwicklung, Strategieentwicklung und Profilbildung, Marketing und Öffentlichkeitsarbeit, Fund- und Fundraising, Benchmarking, Aus- und Fortbildung, Nutzer- und Nichtnutzeranalysen).

Firmenvorträge: Wir bitten insbesondere um die Präsentation von aktuellen oder geplanten innovativen Projekten mit Bibliotheken. Wünschenswert ist ein gemeinsamer Vortrag der Kooperationspartner.

Wir bitten alle Kolleginnen und Kollegen aus wissenschaftlichen und öffentlichen Bibliotheken sowie alle Verbände und Firmen, Vorschläge für Vortragsthemen einzureichen. Bitte stellen Sie den Inhalt des von Ihnen vorgeschlagenen Vortrags kurz, aber aussagekräftig

dar und senden Sie ihn unter Angabe von Namen, privater und dienstlicher Adresse, Telefonnummer und E-Mail – bevorzugt in elektronischer Form – an folgende Adresse:

bibliothekartag2008@bib.uni-mannheim.de oder

Universitätsbibliothek Mannheim
Ortskomitee für den 97. Bibliothekartag
Herrn Per Knudsen
Schloss, Ostflügel, 68131 Mannheim
In der Betreffzeile vermerken Sie bitte: **„Bibliothekartag 2008 – Nummer der Schwerpunktveranstaltung bzw. des Themenkreises“**.

Einsendeschluss ist der 30. September 2007.

Die Programmkommission entscheidet eigenständig über die Auswahl der Vorträge. Das Erstveröffentlichungsrecht für angenommene Vorträge liegt bei den Veranstaltern des 97. Deutschen Bibliothekartages. Details werden den Referentinnen und Referenten mit der Annahme ihres Vortrages mitgeteilt. Kontakt: bibliothekartag2008@bib.uni-mannheim.de

Per Knudsen: Tel.: 0621/181-2932

Dr. Michael Hansen: Tel.: 0621/181-3018

riert, eingebaut. Dadurch können ähnliche Forschungspapiere, Publikationen oder Personen, mit ähnlichen Forschungsinteressen, empfohlen werden – basierend auf der Analyse der Tags.

Die Nutzer sollen bei dem Ansatz von Diederich und Iofciu lediglich die Objekte angeben, die für sie am relevantesten sind und außerdem in der Lage sein, nicht-relevante Objekte wieder aus ihrem Profil löschen sowie neue Objekte jederzeit hinzufügen zu können. Tags können den Nutzern vorgeschlagen werden, sodass Entwicklungen innerhalb einer Domäne ersichtlich werden, was gerade im Bereich der Wissenschaften von Bedeutung ist. Darüber hinaus fördert der Vorschlag von Tags die Entstehung einer Ontologie mit einheitlicher Nomenklatur. Nachdem der Nutzer das Profil erstellt hat, wird es in das RDF-Format importiert, um es bspw. auf der Homepage der Person veröffentlichen sowie mittels eines RDF-Viewers darstellen zu können. Dies ist wiederum ein Mittel zur Community-Bildung, da Überschneidungen in Profilen einfach erkannt und Nutzerprofile ausgetauscht werden können [vgl.: Diederich, Iofciu 2006, 5].

Mittels der Tags jener markierten Objekte werden dann Interessensnetzwerke aufgespürt, indem beobachtet wird, welche Ressourcen oder Sachverhalte bestimmte Tags teilen [vgl.: Diederich, Iofciu 2006, 1 f.]. Die Nutzerprofile des Empfehlungssystems basieren demnach auf den Strukturen der Tags einiger weniger Objekte, was den positiven Effekt hat, dass für die Nutzer ein geringer Arbeitsaufwand entsteht – sie müssen lediglich ein paar Objekte ihres Interesses angeben. Der Ansatz profitiert von dem starken Netzwerkcharakter der Folksonomies.

Fazit

Empfehlungssysteme leisten einen großen Beitrag zur Personalisierung in Zeiten eines exponentiell wachsenden Angebots im Internet. Der vorliegende Artikel zeigt, dass die Wahl der jeweiligen Arbeitsmethode stark von den Anforderungen und Ambitionen des verwendeten Systems bzw. der konkreten Nutzerschaft abhängt. Hybride Verfahren stellen in jedem Fall ein viel versprechendes Forschungsfeld dar, da sie einen Konsens verschiedener Methoden leisten und sich damit der Vorteile unterschiedlicher Verfahren bedienen können.

Der Einsatz von Folksonomies bei Empfehlungssystemen bietet eine kostengünstige Chance vom sozialen Charakter heutiger Web-Strukturen zu profitieren. Als Wissensrepräsentationen sind Folksonomies zu schwach. Sie sind nicht zu vergleichen mit Ontologien, in denen Wissen in komplexen Strukturen abgebildet wird, Redundanzen vermieden und einheitliche

Nomenklaturen verwendet werden. Die Ergebnisse unserer Analyse belegen allerdings, dass Folksonomies – trotz ihrer mangelnden Struktur – vielfach einsetzbar sind. Dies ist vermutlich in dem starken Netzwerkcharakter des sozialen Taggings begründet, wodurch bspw. Communities leicht aufgespürt werden können.

Diederich und Iofciu [2006] zeigen, dass auch Empfehlungssysteme von den Charakterzügen der Folksonomies profitieren. Folksonomies sind nicht derart starr wie Ontologien; durch ihre einfache und flexible Handhabung können sich Wissensstrukturen rasant entwickeln. Dem engen terminologischen „Korsett“ von Ontologien steht demnach der simple Umgang beim sozialen Tagging gegenüber, von dem auch technisch nicht-versierte Personen profitieren können. Unserem Erachten nach darf kein Vergleich zwischen dem Nutzen von Ontologien sowie dem von Folksonomies angestellt werden. Die Konzepte der Wissensrepräsentationen sind in keinem Punkt vergleichbar. Letztere stellen damit keine Alternative zu herkömmlichen Methoden des Knowledge Engineering dar; sie sind vielmehr eine Form der Ergänzung und des Einbeziehens des „gemeinen“ Nutzers unter dem Mantel der Web 2.0-Bewegung.

Literatur

[Aehnelt 2003]

Aehnelt, M.: Personalisierung als Schlüssel zum Erfolg. In: Hambach, S.; Urban, B. (Hrsg.), Fraunhofer-Institut für Graphische Datenverarbeitung - IGD-, Außenstelle Rostock -EGD: Multimedia & Bildung. Beiträge zu den 4. IuK-Tagen, Mecklenburg-Vorpommern, Stuttgart: Fraunhofer IRB Verlag, 2003, S. 129-140.

[Avery, Zeckhauser 1997]

Avery, C.; Zeckhauser, R.: Recommender Systems for Evaluating Computer Messages. In: Communications of the ACM 40(1997)3, S. 88-89.

[Balbanovic, Shoham 1997]

Balbanovic, M.; Shoham, Y.: Content-Based, Collaborative Recommendation. In: Communications of the ACM 40(1997)3, S. 66-72.

[Belkin, Croft 1992]

Belkin, N.J.; Croft, W.B.: Information Filtering and Information Retrieval: Two Sides of the Same Coin? In: Communications of the ACM 35(1992)12, S. 29-38.

[Breese et al. 1998]

Breese, J.S.; Heckerman, D.; Kadie, C.: Empirical Analysis of Predictive Algorithms for Collaborative Filtering. In: Proceedings of the 14th Annual Conference on Uncertainty in Artificial Intelligence, 1998, S. 43-52.

[Burke 1999]

Burke, R.: Integrating Knowledge-based and Collaborative-filtering Recommender Systems. In: Proc. of the Workshop on Artificial Intelligence for Electronic Commerce, AAAI Press, 1999, S. 69-72.

[Burke 2000]

Burke, R.: Knowledge-based Recommender Systems. In: A. Kent (Hrsg.): Encyclopedia of Library and Information Systems, Vol. 69, Supplement 32, 2000.

[Burke 2002]

Burke, R.: Hybrid Recommender Systems: Survey and Experiments. In: User Modeling and User-Adapted Interaction 12(2002)4, S. 331-370.

[Diederich, Iofciu 2006]

Diederich, J.; Iofciu, T.: Finding Communities of Practice from User Profiles Based On Folksonomies. In: Proc. of the 1st International Workshop on Building Technology Enhanced Learning solutions for Communities of Practice (TEL-CoPs'06), co-located with the First European Conference on Technology-Enhanced Learning, Kreta, Griechenland, Oktober 2006.

[Foltz 1990]

Foltz, P.W.: Using Latent Semantic Indexing for Information Filtering. In: R.B. Allen (Hrsg.): Proceedings of the Conference on Office Information Systems, Cambridge, MA, 1990, S. 40-47.

[Goldberg et al. 1992]

Goldberg, D.; Nichols, D.; Oki, B.M.; Terry, D.: Using Collaborative Filtering to Weave an Information Tapestry. In: Communications of the ACM 35(1992)12, S. 61-70.

[Guttman 1998]

Guttman, R.H.: Merchant Differentiation Through Integrative Negotiation in Agent-Mediated Electronic Commerce. Master's Thesis, School of Architecture and Planning, Program in Media Arts and Sciences, Boston: Massachusetts Institute of Technology, 1998.

[Guttman et al. 1998]

Guttman, R. H.; Moukas, A. G.; Maes, P.: Agent-Mediated Electronic Commerce: A Survey. In: Knowledge Engineering Review, 13(1998)2, S. 147-159.

[Guttman, Maes 1998]

Guttman, R.; Maes, P.: Agent-mediated Integrative Negotiation for Retail Electronic Commerce. In: Proceedings of the Workshop on Agent Mediated Electronic Trading (AMET'98), Minneapolis, Minnesota, April 9, 1998.

[Hayes et al. 2002]

Hayes, C.; P. Massa, P.; Avesani, P.; Cunningham, P.: An Online Evaluation Framework for Recommender Systems. In: Proceedings of the Workshop on Personalization and Recommendation in E-Commerce (RPEC). Malaga, Spanien. Springer-Verlag, 2002.

[Höhfeld, Kwiatkowski 2007]

Höhfeld, S.; Kwiatkowski, M.: Der Aufbau eines themenspezifischen Internetportals unter Verwendung von Recommender Systemen und Wikis und dem Einsatz von Ontologien, Masterarbeit, Heinrich-Heine-Universität Düsseldorf, Institut für Sprache und Information, Informationswissenschaft, 2007.

[Jäschke et al. 2006]

Jäschke, R.; Hotho, A.; Schmitz, C.; Stumme, G.: Wege zur Entdeckung von Communities in Folksonomies. In: Braß/Hinneburg (Hrsg.): Proc. of the 18th Workshop Grundlagen von Datenbanken, 2006, Martin-Luther-Universität, Halle-Wittenberg, S. 80-84.

[Kleinberg 1999]

Kleinberg, J.M.: Authoritative Sources in a Hyperlinked Environment. In: Journal of the ACM 46(1999)5, S. 604-632.

[Kobsa et al. 2001]

Kobsa, A.; Koenemann, J.; Pohl, W.: Personalized Hypermedia Presentation Techniques for Improving Online Customer Relationships. In: The Knowledge Engineering Review 16(2001)2, S. 111-155.

[Konstan et al. 1998]

Konstan, J.A.; Riedl, J.; Borchers, A.; Herlocker, J.L.: Recommender Systems: A GroupLens Perspective. In: Recommender Systems: Papers from the 1998 Workshop (AAAI Technical Report WS-98-08). Menlo Park, CA: AAAI Press, 1998, S. 60-64.

[Krulwich 1997]

Krulwich, B.: Lifestyle Finder: Intelligent User Profiling Using Large-Scale Demographic Data. In: AI Magazine, 1997, S. 37-45.

Benötigen Sie mehr Platz in Ihrer Bibliothek?
E-Books sind die Lösung. Wir helfen gern.



Ihr Partner für elektronische Fachinformationen

EBSCO ist ein führender Anbieter von E-Books. Als Partner renommierter Verlage können wir Ihnen die Fachinformation bieten, die Sie in Ihrer Bibliothek benötigen.

Profitieren Sie von unserer Zusammenarbeit mit Verlagen wie Blackwell, Cambridge University Press, Pan American Health Organization, Taylor & Francis, Wiley und natürlich mit Springer, der viele Inhalte auch in deutscher Sprache anbietet.

Bieten Sie Ihren Nutzern schnelleren und einfachen Zugriff auf Informationen von hoher Qualität. Wir unterstützen Sie bei der Erwerbung, Lizenzierung und Verwaltung Ihrer E-Books.

Sind Sie interessiert? Kontaktieren Sie uns unter salesberlin@ebSCO.com

www.ebSCO.de

EBSCO
INFORMATION SERVICES

[Linden et al. 1998]

Linden, G.D.; Jacobi, J.A.; Benson, E.A.: Collaborative Recommendations Using Item-to-Item Similarity Mappings. Patent-Nr. US 6.266.649. – Patent-inhaber: Amazon.com, Seattle, WA. – Erteilt am: 24.7.2001. – (Eingereicht am 18.9.1998).

[Linden et al. 2003]

Linden, G.; Smith, B.; York, J.: Amazon.com Recommendations – Item-to-Item Collaborative Filtering. In: Internet Computing, IEEE 7(2003)1, S. 76-80.

[Melville et al. 2001]

Melville, P.; Mooney, R.J.; Nagarajan, R.: Content-Boosted Collaborative Filtering for Improved Recommendations. In: Proc. of the 18th National Conference on Artificial Intelligence (AAAI-2002), Edmonton, Canada, 2002, S. 187-192.

[Middleton et al. 2001]

Middleton, S.E.; De Roure, D.C.; Shadbolt, N.R.: Capturing Knowledge of User Preferences: Ontologies in Recommender Systems. In: Proc. of the 1st International Conference on Knowledge Capture, Victoria, British Columbia, Canada, 2001, S. 100-107.

[Middleton et al. 2002]

Middleton, S.E.; Alani, H.; De Roure, D.C.: Exploiting Synergy between Ontologies and Recommender Systems. In: Proc. of the Semantic Web Workshop, 11th International World Wide Web Conference, Hawaii, USA, 2002.

[Montaner et al. 2003]

Montaner, M.; López, M.; de la Rosa, J.L.: A taxonomy of Recommender Agents on the Internet. In: Artificial Intelligence Review 19(2003)4, S. 285-330.

[Nichols 1997]

Nichols, D.M.: Implicit Rating and Filtering. In: Proceedings of the Fifth DELOS Workshop on Filtering and Collaborative Filtering, Budapest, ERCIM, S. 31-36.

[Oard, Kim 1998]

Oard, D.W.; Kim, J.: Implicit Feedback for Recommender Systems. In: Proc. of the 1998 Workshop on Recommender Systems, S. 81-83.

[Pazzani 1999]

Pazzani, M.: A Framework for Collaborative, Content-Based and Demographic Filtering. In: Artificial Intelligence Review, 1999.

[Perugini et al. 2004]

Perugini, S.; Goncalves, M.A.; Fox, E.A.: A Connection-Centric Survey of Recommender Systems Research. In: Journal of Intelligent Information Systems 23(2004)2, S. 107-143.

[Peters, Stock 2007] S.

Peters, I.; Stock, W.G.: Web 2.0 im Unternehmen. In: Wissensmanagement (2007)4, S. 22-25.

[Resnick et al. 1994]

Resnick, P.; Iacovou, N.; Suchak, M.; Bergstrom, P.; Riedl, J.: GroupLens: An Open Architecture for Collaborative Filtering of Netnews. In: Proceedings of the Conference on Computer Supported Cooperative Work, Chapel Hill, NC, 1994, S. 175-186.

[Resnick, Varian 1997]

Resnick, P., Varian, H.R.: Recommender Systems. In: Communications of the ACM 40(1997)3, S. 56-58.

[Rich 1979]

Rich, E.: User Modeling via Stereotypes. In: Cognitive Science 3(1979)4, S. 329-354.

[Rosenstein, Lochbaum 2000]

Rosenstein, M.; Lochbaum, C.: Recommending from Content: Preliminary Results from an E-Commerce Experiment. In: Proceedings of CHI'00: conference on Human Factors in Computing, The Hague, Netherlands, 2000.

[Rucker, Polanco 1997]

Rucker, J.; Polanco, M.J.: Siteeater: Personalized Navigation for the web. In: Communications of the ACM 40(1997)3, S. 73-75.

[Sarwar et al. 2001]

Sarwar, B.; Karypis, G.; Konstan, J.; Riedl, J.: Item-based Collaborative Filtering Recommendation Algorithms. In: Proc. of the 10th International conference on World Wide Web, Hong Kong, 2001, S. 285-295.

[Schafer et al. 1999]

Schafer, J.B.; Konstan, J.; Riedl, J.: Recommender Systems in E-Commerce. In: Proc. of the 1st conference on electronic commerce, Denver, Colorado, 1999, S. 158-166.

[Schafer et al. 2004]

Schafer, J.B.; Konstan, J.; Riedl, J.: E-Commerce Recommendation Applications. In: Data Mining and Knowledge Discovery 5(2004)1-2, S. 115-135.

[Spiteri 2005]

Spiteri, L.: Controlled Vocabulary and Folksonomies. In: Canadian Metadata Forum, 27.-28. Sept. 2005, online: www.collectionscanada.ca/obj/014005/f2/014005-05209-e-e.pdf, Zugriff: 07.07.2007.

[Stock 2007]

Stock, W.G.: Information Retrieval. München; Wien: Oldenbourg, 2007.

[Terveen, Hill 2001]

Terveen, L.; Hill, W.: Beyond Recommender Systems: Helping People Help Each Other. In: Jack Carroll (Hrsg.) HCI in the Millenium, Addison-Wesley, 2001.

[Towle, Quinn 2000]

Towle, B.; Quinn, C.: Knowledge Based Recommender Systems Using Explicit User Models. In: Knowledge-Based Electronic Markets, Papers from the AAAI Workshop, AAAI Technical Report WS-00-04, Menlo Park, CA: AAAI Press, 2000, S. 74-77.

[Tran, Cohen 2000]

Tran, T.; Cohen, R.: Hybrid Recommender Systems for Electronic Commerce. In: Knowledge-Based Electronic Markets, Papers from the AAAI Workshop, AAAI Technical Report WS-00-04, Menlo Park, CA: AAAI Press, 2000, S. 78-83.

[Vozalis, Margaritis 2006]

Vozalis, M.; Margaritis, K.G.: On the enhancement of collaborative filtering by demographic data. In: Web Intelligence and Agent Systems 4(2006)2, S. 117-138.

[Wasfi 1999]

Wasfi, A.M.: Collecting User Access Patterns for Building User Profiles and Collaborative Filtering. In: IUI'99: Proceedings of the 1999 International Conference on Intelligent User Interfaces, Redondo Beach, CA, 1999, S. 57-64.

Links

www.amazon.de, Zugriff: 07.07.2007
 www.google.de, Zugriff: 07.07.2007
<http://del.icio.us>, Zugriff: 07.07.2007
 www.ebay.de, Zugriff: 07.07.2007
 www.flickr.com, Zugriff: 07.07.2007
 www.technorati.com, Zugriff: 07.07.2007
 www.frassle.org, Zugriff: 07.07.2007
 www.furl.net, Zugriff: 07.07.2007
 www.youtube.com, Zugriff: 07.07.2007
 www.simpy.com, Zugriff: 07.07.2007
 www.spurl.com, Zugriff: 07.07.2007
 www.aktors.org/publications/ontology, Zugriff: 07.07.2007
 www.dmoz.com/Computers/Computer_Science, Zugriff: 07.07.2007
 www.cs.indiana.edu/~sithakur/l542_p3/, Zugriff: 07.07.2007

Data Mining, Analyse, Ähnlichkeit, Benutzerverhalten, Empfehlung, System, Wissen, Folksonomy, Ontologie, Recommender System, kooperatives Filtern, inhaltsbasiertes Filtern,

DIE AUTORINNEN

Stefanie Höhfeld, B.A., M.A.



(geb. 1982), Absolventin des Düsseldorfer Masterstudiengangs „Informationswissenschaft und Sprachtechnologie“, vorher B.A.-Studium in den Fächern Romanistik und Informationswissenschaft. Sprachaufenthalt in Florenz 2002, Praktikum und freie Mitarbeit bei der NRZ im Jahre 2003. Tutorin für Information-Retrieval-Systeme (Convera RetrievalWare). Evaluationsstudie über Convera RW im Jahre 2005. Teilnahme an der International Security Conference 2005 (ISC 2005) mit einem Beitrag zum Einsatz von Ontologien bei Retrieval-Systemen von Intelligence Services. 2004 bis 2006 studentische Mitarbeiterin der Abteilung für Informationswissenschaft der Heinrich-Heine-Universität Düsseldorf.

stefhohfeld@web.de

Melanie Kwiatkowski, B.A., M.A.



(geb. 1978), Absolventin des Düsseldorfer Masterstudiengangs „Informationswissenschaft und Sprachtechnologie“, vorher B.A.-Studium in den Fächern

Kunstgeschichte und Informationswissenschaft. Ausbildung zur Kauffrau für Bürokommunikation bei der Henkel KGaA von 1998 bis 2001; 2001 Beschäftigung bei der Cognis Deutschland GmbH im Corporate Product Management. Tutorium für Information-Retrieval-Systeme (Convera RetrievalWare) und Evaluationsstudie über Convera RW im Jahre 2005. Teilnahme an der International Security Conference 2005 mit einem Beitrag zum Einsatz von Ontologien bei Retrieval-Systemen von Intelligence Services. Studentische Mitarbeiterin im Jahr 2002 am Seminar für Kunstgeschichte und 2005 bis 2006 bei der Abteilung für Informationswissenschaft, jeweils Heinrich-Heine-Universität Düsseldorf.

melkwiatkowski@yahoo.de

Heinrich-Heine-Universität Düsseldorf
 Institut für Sprache und Information
 Abteilung Informationswissenschaft
 Universitätsstraße 1
 40225 Düsseldorf