



Empfehlungssysteme für Wissensgemeinschaften: Ein Social Recommender für eine Community of Practice

Dirk Westrup M.Sc., Marcel Vervenne M.Sc., Prof. Dr. Michael Kerres

Lehrstuhl für Mediendidaktik und Wissensmanagement
Universität Duisburg-Essen
Forsthausweg 2
47057 Duisburg
dirk.westrup@uni-due.de
marcel.vervenne@uni-due.de
michael.kerres@uni-due.de

Abstract: Web 2.0- Ansätze und Technologien werden immer häufiger Bestandteil von Lernplattformen und verwandeln diese von klassischen Systemen der Datendistribution in virtuelle, soziale Lernräume, in denen die Lernenden selbst zu aktiven Konstrukteuren von User Generated Content werden und Lernplattformen zu Kommunikationsumwelten für Wissensgemeinschaften werden. Da dies auch zu einer größeren und schneller wachsenden Menge an Informationen führt, besteht die Herausforderung darin, dem Nutzer in einer solchen Wissensgemeinschaft den für ihn relevanten Content ad hoc zur Verfügung zu stellen. Um diese Adaption der Lernumgebung an den Nutzer zu realisieren, werden Methoden des Information Retrieval eingesetzt, um einen *Social Recommender* in eine Lern- und Kommunikationsumgebung für das informelle Lernen zu integrieren. Der vorliegende Artikel beschreibt solche Empfehlungsdienste und stellt die Implementation in einer „Community of Practice“ für das Handwerk vor.

1 Relevanz von Empfehlungssystemen für Wissensgemeinschaften

Der traditionelle Einsatz von Lernplattformen beschränkt sich oftmals darauf, einzelne Dokumente zum Download einzustellen und einer beschränkten Gruppe von Personen zugänglich zu machen. Zunehmend wird Online-Lernen jedoch auch als sozial-kommunikative und kollaborative Lernaktivität didaktisch organisiert. Mit Web 2.0-Techniken und Ansätzen, die zunehmend auch in Lernplattformen verfügbar werden, wird die Lernumgebung zu einer sozialen Wissensgemeinschaft [Ke06]. Online-Lernumgebungen werden dann immer mehr als soziale Räume verstanden, in denen sich die Lernenden aktiv über Themen austauschen und (gemeinsam) an Artefakten arbeiten, Kommentare hinterlassen, Beiträge bewerten etc. Die Lernenden entwickeln dabei eine andere Beziehung zu ihrer "Lernplattform", sie ist nicht mehr nur ein Ort für den Download von Materialien, sondern sozialer Ort einer Wissensgemeinschaft.

In solchen Wissensgemeinschaften wächst die Menge an Nachrichten und Informationen durch User Generated Content wesentlich an, und es entsteht die Frage, wie die Orientierung der User unterstützt werden kann und wie die Artefakte, die im Rahmen von kommunikativen und kollaborativen Aktivitäten entstehen, für die weiteren Lern- und Kommunikationsprozesse nutzbar gemacht werden können. Eine Plattform für eine Wissensgemeinschaft wird dann attraktiv, wenn sie die Erfahrungen und Erkenntnisse, die die Akteure in zurückliegenden Gesprächen und Projekten entwickelt haben, bei neuen Anforderungen und Projekten nutzbar bzw. neuen Mitglieder der Community zugänglich gemacht werden können.

Hier setzen Recommender Systeme an, die Informationen für Lernende in Communities entsprechend aufbereiten. Die Idee an sich ist nicht neu: Im Rahmen der Forschung über "intelligente tutorielle Systeme" wurde der Ansatz verfolgt, auf der Basis von KI-Technologien, den Lernfortschritt des einzelnen Lernalters zu erfassen, eine Diagnose über die Kompetenz(-defizite) des Lernalters zu erstellen und - daraus abgeleitet, eine Lerneinheit zu präsentieren bzw. Lernmaterial vorzuschlagen. Diese Systeme haben im Kern das Problem adressiert, wie die Folge von Lerninhalten optimal zu sequenzieren ist, die aus einem Pool von Ressourcen ausgewählt werden. Auch neuere Arbeiten zu Recommender Systemen im Technology Enhanced Learning, wie sie in Cress et al. [CDS09] und Nejdil et al. [Ne08] berichtet werden, fokussieren insbesondere Empfehlungen für Lerninhalte und die Sequenzierung von Materialien, die aus zunehmend umfangreicheren Repositorien von Lernobjekten gezielt ausgewählt und präsentiert werden (s.a. das Handbook on Recommender Systems von Kantor et al. [Ka10]). Mödritscher [Mö10] diskutiert Recommender für Personal Learning Environments, auch unter der Perspektive der Suche und Präsentation vorgefertigter Lerninhalte.

Brusilovsky & Henze [BH07] beschreiben dabei drei Arten der Adaption in Lernanwendungen: (a) adaptive Inhaltsauswahl, (b) adaptive Unterstützung der Navigation und (c) adaptive Präsentation. Der erste Ansatz basiert im Wesentlichen auf Techniken des Information Retrieval. Der zweite Ansatz bezieht sich auf Techniken, wie sie in adaptiven Lernanwendungen (bzw. intelligenten tutoriellen Systemen) realisiert wurden, und thematisiert insbesondere die zeitliche Sequenzierung von Information. Im dritten Ansatz geht es dagegen um unterschiedliche Präsentationsvarianten, wie z.B. Präferenzen für eine textuelle Darstellung von Inhalten vs. einer Video-Aufzeichnung eines Vortrages (vgl. auch [Ab09] [Br10]). In Anlehnung an Herlocker et. al. [He04] können grundsätzlich folgende Varianten von Empfehlungen in Lernkontexten differenziert werden:

- "mehr Information": Empfehlungen für weiterführende Informationen, die zu dem aktuellen thematischen Fokus der Lerninhalte passen,
- "****": Empfehlungen für besonders relevante, besonders positiv bewertete Informationen etc.
- "Tipps": Empfehlungen (vom Lehrenden / System oder anderen Lernenden), die allgemeiner Art sind, und sich nicht auf den thematischen Fokus beziehen,
- "To Do's": Empfehlungen für noch abzurufende Information / zu bearbeitende Arbeitsschritte, die der Lernende noch abrufen bzw. bearbeiten sollte,
- "als nächster Schritt": Empfehlungen für den oder die nächsten Schritt(e) in einer Folge von Bearbeitungs- bzw. Lernschritten (Lernweg)

Bereits in den 1980er Jahren wurde in der Tradition der "intelligenten tutoriellen Systeme" versucht, mithilfe von KI-Technologie, die Abfolge von Lernschritten während der Laufzeit, auf der Basis von Analysen des Lernverhaltens, zu generieren. Statt einer „fest verdrahteten“ Folge, mit der Inhalte präsentiert werden, wird in "intelligenten tutoriellen Systemen" eine flexiblere Anpassung des Lernwegs angestrebt. Entsprechend der o.g. Klassifikation kann hier von einer "Empfehlung" für den Lernweg gesprochen werden. In der Praxis haben sich Ansätze für "intelligente tutorielle Systeme" aus mehreren Gründen wenig durchsetzen können [Ke01]. Zum einen bleiben sie teilweise einem streng behavioristischen Lernansatz verhaftet, wenn sie statt vorab programmierten linearen Folgen von Lernschritten lediglich eine systemgenerierte Abfolge des Lernweges präsentieren. Für Lernende bleibt ein starres Korsett bestehen, das wenig Spielraum für aktives Handeln und Exploration bietet. Anders verhält es sich in sozialen Lernumgebungen, in denen ein wesentlicher Teil der Aktivitäten auf diskursiven oder kollaborativen Interaktionen beruht. Im Rahmen der thematisch gebundenen oder ungebundenen Interaktionen entstehen Artefakte, die unterschiedliche Arten von "Wissen" beinhalten, die auch für künftige Interaktionen nutzbar gemacht werden können. In traditionellen Ansätzen des Wissensmanagement versucht man, die User dazu zu motivieren, ihr Wissen und ihre Kommunikation in vorgegebene Themenstrukturen einzubetten und durch vorgegebene Taxonomien zu klassifizieren. Durch Web 2.0-Anwendungen sozialisiert, haben User zunehmend die Erwartung, dass sie Einträge und Anfragen ohne vorgegebene Strukturen und Meta-Daten "posten" und "taggen", sondern dass vielmehr "intelligente" Prozeduren aus der "Datenspur" der Interaktion Schlussfolgerungen über sachliche Zusammenhänge und semantische Tiefenstrukturen erschließen.

Zukünftige E-Learning Szenarien werden vermehrt soziale Settings beinhalten; zunehmend integrieren Lernplattformen Feeds und Informationen aus Web 2.0-Anwendungen. Damit eine solche Umgebung für Wissensgemeinschaften attraktiv bleibt und sinnvoll nutzbar wird, sind Social Recommender erforderlich, die bei Anfragen die "richtigen" Informationen aus dem System zur Verfügung stellen und je nach aktuellem thematischen Fokus Hinweise für weiterführende Informationen präsentieren. Anders als die bisher primär diskutierten Recommender beziehen sich diese nicht mehr auf die Auswahl von vorliegenden (von einem Autor entwickelten) Lernmaterialien oder -objekten, sondern auf User Generated Content, die die Lernenden selbst in ihren Lernaktivitäten als "Verhaltensspur" erzeugen.

Mit Bezug auf Vygotsky [Vy78] kann mit einem Empfehlungssystem eine Lernumgebung realisiert werden, die dem Prinzip der "zone of proximal development" folgt: Das System bietet - basierend auf dem aktuellen Lernverhalten - Informationen und Hilfen an, die für den Kompetenzerwerb des Lernenden als nächstes relevant sein könnten. Statt ein engmaschiges System von Lernschritten zu konzipieren, das den Lernfortschritt zu überwachen versucht, sind solche Umgebungen jedoch offener gehalten, und überlassen den Lernenden die Entscheidung, ob sie der Empfehlung folgen wollen oder nicht. Lave & Wenger [LW91] beschreiben die Möglichkeiten des Lernens in „Communities of Practice“: Durch die Beobachtung und schrittweise Partizipation am Diskurs erfahrener „Professionals“ wächst der Novize in die Wissensgemeinschaft hinein, nimmt Wissen auf, übernimmt Einstellungen und einen berufstypischen Habitus.

Es gibt verschiedene Wissensgemeinschaft im Internet, die als solche „Communities of Practice“ bezeichnet werden können. Sie sind teilweise in Intranets innerhalb von Organisationen realisiert, in denen Wissenskommunikation und Erfahrungsaustausch stattfindet, und teilweise öffentlich oder nach Vorlegen eines Nachweises zugänglich.

2 Die Community des Handwerks: Q-Online

Im Rahmen des BMBF-Projektes "Web 2.0 im Handwerk"¹ besteht die Herausforderung, ein System für eine Wissensgemeinschaft zu entwickeln, das die Interaktion der User anregt, zugleich aber auch gezielt vorliegende Daten und Wissensbestände den Usern zur Verfügung stellt. Die Plattform Q-Online bietet einen Ort, an dem sich Handwerker unterschiedlicher Gewerke treffen und über Fragen, die sie beruflich oder privat beschäftigten austauschen. Ziel ist es, den Austausch überregional sowie Gewerke übergreifend zu fördern. Ferner soll der Zugang zu formalen Weiterbildungsangeboten erleichtert und Werkzeuge zum informellen Lernen und zum Wissens- und Erfahrungsaustausch bereitgestellt werden. Das System ist angelegt an die Struktur typischer Web 2.0-Anwendungen und ist realisiert auf der Basis des Community CMS Drupal 6.0², ein PHP-basiertes Entwicklungsframework. Über einen einzigen Eingabeschlitz können registrierte Nutzer/innen Fragen stellen oder nach Antworten suchen.



Abbildung 1: Kontext basierte Suche in Q-Online

Darüber hinaus können Gruppen gebildet, Bildungsangebote eingesehen und ein eigenes Netzwerk aus Kontakten zu anderen Nutzer erstellt werden. Die Herausforderung besteht nun darin, Benutzenden die „richtigen“ Informationen zu präsentieren und dazu vorliegende Inhalte – seien sie bereitgestellt oder User generiert – auszuwerten im Hinblick auf eine User-Anfrage.

¹ Förderkennzeichen 01PF08004A und B, Laufzeit: von 01.03.2009 bis 29.02.2012

² <http://www.drupal.org>



Abbildung 2: Suchergebnisse für das Schlagwort "Meister"

Die Menge an Informationen, die durch die verschiedenen Nutzer generierten Inhalte erzeugt wird, kann selbst bei einer geringen Nutzeranzahl nur noch schwer überblickt werden. Dort setzt das Empfehlungssystem an und verfolgt das Ziel, einem Benutzer aus den vorliegenden Informationen und Beiträgen „relevante“ Information kontextbezogen bereitzustellen. Im Folgenden wird beschrieben, wie in Q-Online vorgegangen wird, um eine „richtige“ Information während der Laufzeit auszuwählen.

Um die Auswahl einer Information zu generieren, wird die folgende allgemeine Nutzwertfunktion einer Information herangezogen [K109; S.1]:

$$\max(\text{Nutzwert}(B, K, T)) \text{ mit } K = (P, M, S)$$

Dies beschreibt grundlegend die Maximierung des Nutzwerts für einen Benutzer (B) in einem konkreten Kontext (K) und einer empfohlenen Teilmenge (T) der zugrunde liegenden Informationsmenge (M). Dabei definiert sich der Kontext über die Parameter Benutzerprofil (P), Informationsmenge und Situation (S). Um den Nutzwert in Q-Online erfolgreich zu maximieren, können verschiedene Verfahren verfolgt werden (wie Collaborative Filtering, Content Based Filtering und hybride Verfahren, s. [K109; S.2]).

3 Mechanismen des Q-Online Empfehlungssystems

Das in Q-Online realisierte Empfehlungssystem besteht aus drei Komponenten. Die *Inhaltsanalyse* reichert alle erzeugten Inhalte mit Metadaten an und versucht ähnliche Inhalte zu identifizieren. Im Rahmen der Bestimmung von *Nutzerpräferenzen* wird das Verhalten eines Nutzers ausgewertet, um Rückschlüsse auf präferierte Inhalte des Nutzers ziehen zu können. Außerdem kann jeder Nutzer eigene Schwerpunkte über die Vergabe von Schlagworten im Profilbereich setzen. Die dritte Komponente bildet der eigentliche *Empfehlungsprozess*. Er definiert das Vorgehen von der Anfrage bis zur Systemantwort.

3.1 Ähnlichkeiten identifizieren

Der Social Recommender von Q-Online vergleicht die Ähnlichkeit von Informationen, in dem die jeweils zugewiesenen Tags unter Nutzung des Jaccard Index [Kl09] ausgewertet werden. Dieser gibt einen prozentualen Überschneidungswert zwischen 0 und 1 zurück:

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|}$$

Dabei wird die Schnittmenge über die Tag-Menge A des Inhalts A und der Tag-Menge B des Inhalts B bestimmt und dividiert durch deren Vereinigungsmenge. Der Jaccard Index benutzt jedoch nur eindeutige Übereinstimmungen zur Definition der Schnittmenge. Dies ist im vorliegenden Fall leicht modifiziert worden. Begründet ist dies durch die hohe Wahrscheinlichkeit, dass zwei Tags rein formal *nicht* übereinstimmen, es jedoch verwandte Begriffe sind (z.B. Haus und Häuser). Um dem entgegen zu wirken, wird bei der Bestimmung der Schnittmenge darüber hinaus die *Ähnlichkeit* der Tags untereinander berücksichtigt. Wenn eine Ähnlichkeit hinreichend gegeben ist, werden diese Tags als Teil der Schnittmenge betrachtet. Damit dies nicht zu einer Verfälschung des Prozentwertes führt, erfolgt die Erhöhung der Schnittmenge nur um eins, entsprechend muss die Vereinigungsmenge um eins reduziert werden. Daraus ergibt sich die folgende Anpassung der oben verwendeten Formel, wie sie im Recommender von Q-Online Einsatz findet:

$$J_{d_w}(A, B) = \left(\frac{|A \cap B|}{|A \cup B|} \right)_{d_w}$$

Die *Termähnlichkeit* wird darüber hinaus über die Jaro-Winkler Distanz ermittelt [Wi90]:

$$d_j = \frac{1}{3} \left(\frac{m}{|s_1|} + \frac{m}{|s_2|} + \frac{m-t}{m} \right)$$

m: Anzahl der exakt Übereinstimmenden Zeichen (Zeichen und Position)

t: Anzahl der Übereinstimmenden Zeichen (nur das Zeichen, nicht die Position)
Die beiden Beträge ergeben sich aus den beiden Zeichenlängen.

Die Erweiterung sieht wie folgt aus:

$$d_w = d_j + (l \cdot p \cdot (1 - d_j))$$

l: Länge des Präfixes

p: Gewichtung des Präfixes

Zur Optimierung des Ergebnisses wird eine Ähnlichkeit nur bei den Wortpaaren bestimmt, bei denen die *längere* Zeichenkette nicht um mehr als ein Drittel größer ist im Vergleich zur *kürzeren* Zeichenkette. Ähnliche Inhalte werden anhand der Überschneidung ihrer jeweiligen Tag Menge bestimmt, welche sich aus den direkten inhaltsbezogenen Schlagworten sowie deren Synonyme besteht. Die Berechnung des Ähnlichkeitswerts erfolgt nun analog zum direkten Vergleich zweier Inhalte.

3.2 Aufbereitung der Beiträge

Content Based Filtering Verfahren beschäftigen sich mit der Inhaltsanalyse der Information. Dabei wird versucht, ein Element mit Metadaten zu versehen, um so auf der Basis der Inhalte zweier Elemente eine Aussage darüber treffen zu können, inwieweit beide Elemente eine inhaltliche Beziehung aufweisen, also als zusammengehörig und *nützlich* in einem bestimmten Kontext bewertet werden können.

Diese Analyse wird über ein Skript zeitgesteuert gestartet. Dabei handelt es sich um ein Stapelverarbeitungsprogramm, welches die Einstiegsfunktion aufruft und den Prozess startet. Das bietet den Vorteil, dass die Analyse weder direkt im Anschluss an die Erzeugung des Inhalts gestartet werden muss, was zu Performanceeinbußen führen kann, noch in Aktualisierungsprozesse des Basissystems einbezogen zu sein, wodurch die Lastspitze aufgrund der größeren Verteilungsmöglichkeiten verkleinert werden kann. Die Anzahl der in jedem Durchgang zu verarbeitenden Inhalte wird über eine Konfigurationsmaske im System gesteuert. Zu Beginn werden allgemeine Informationen ausgewertet und entsprechend reagiert. Dort werden umgangssprachlich Fragen beantwortet wie: Kann noch ein weiterer Durchlauf gestartet werden oder ist ein Limit erreicht? Liegen Inhalte vor, die entweder noch nicht verarbeitet oder seit der letzten Verarbeitung geändert wurden?

Im Anschluss wird die Inhaltsanalyse wie in Abbildung 1 dargestellt durchgeführt. Die Eigenschaftsextraktion in Form von Schlagworten wird an den Dienst TagThe.Net³ ausgelagert. Über eine Schnittstelle wird anonymisierte Textversionen an den Dienst über-

³ URL: <http://www.tagthe.net/>

mittelt und die rückgemeldeten Schlagworte weiterverarbeitet. Danach wird ein zweiter Dienst: „Wortschatz Leipzig“⁴ genutzt, um Synonyme aufzufinden.

Somit werden zwei Content Based Filtering Verfahren an externe Dienstleister ausgelagert und belasten nicht die lokale Infrastruktur. Diese Metainformationen werden den zum einen den einzelnen Inhalten zugeordnet, und, zum anderen, in Relation zu den in der Datenbank bereits vorhandenen Metainformationen gesetzt. Es wird dabei geprüft, welche Term Kombinationen häufig auftreten. Diese Basis wird in späteren Schritten als zusätzlicher Hinweis zur Kontextbildung verwendet, da ein Term nicht mehr ausschließlich alleine betrachtet werden muss, sondern Beziehungen zu anderen Termen aufweist. Tritt beispielsweise der Term „Bank“ bei mehreren Inhalten in Kombination mit dem Term „Konto“ auf, so werden diese inhaltlich als verwandt betrachtet. Aus diesen Term-Kombinationen werden dann Term-Pattern abgeleitet, die als Schablone dienen, um das Problem mehrfacher Wortbedeutungen zu lösen, z.B. um etwa Term Kombinationen, die „Bank“ und „Park“ enthalten, weiter entfernt zu Inhalten mit den Term Kombinationen „Bank“ und „Konto“ anzuordnen. Darüber hinaus wird bei jedem Inhalt geprüft, inwiefern er mit anderen Inhalten verwandt ist. Dazu werden die zuvor beschriebenen Ähnlichkeitsmaße verwendet. Ist ein Schwellenwert überschritten, wird dies in einer Datenbank-tabelle erfasst und bereitet auf diese Weise Suchoperationen nach ähnlichen Inhalten vor. Nach der Ähnlichkeitsbestimmung erfolgt die Prüfung, inwieweit aus bestehenden Pattern Kategorien und Cluster erzeugt werden können. Primär muss dazu die Ähnlichkeit zwischen Pattern hoch genug sein, so dass ein Pattern möglichst eindeutig von anderen Pattern abgegrenzt werden kann.

3.3 Einbeziehung des Nutzerverhaltens

Collaborative Filtering Verfahren versuchen schließlich Empfehlungen anhand des Benutzerverhaltens zu erzeugen. Es liegen dazu zwei verschiedene Ansätze vor; zum einen ein benutzerbasierter Ansatz und zum anderen ein elementbasierter Ansatz. Der *benutzerbasierte* Ansatz versucht, Elemente zu empfehlen, die vom aktuellen Benutzer noch nicht betrachtet wurden, aber von möglichst vielen anderen Benutzern mit einem ähnlichem Navigationsverhalten. Der *elementbasierte* Ansatz hingegen versucht für ein konkretes Element die Wahrscheinlichkeit zu errechnen, dass es vom aktuellen Benutzer als relevant eingestuft wird. Grundlage dazu ist ebenfalls die Analyse des Navigationsverhaltens aller Benutzer. Präferenzen können von jedem Nutzer im System hinterlegt werden und können so bei Generierung der Empfehlung unmittelbar genutzt werden. Darüber hinaus versucht das System eigenständig, Präferenzen der Nutzer zu identifizieren auf der Grundlage von Tracking Daten, die während einer Session für den Nutzer gespeichert werden.

Die aktuelle Version in Q-Online realisiert einen *elementbasierten* Ansatz des Collaborative Filtering. Es wird ermittelt, welche Inhalte wie oft von einem Benutzer angefragt wurden, wodurch über die zugehörigen Metadaten bestimmt wird, wie gut ein anderer Inhalt zu diesem Muster passt. Die Erweiterung des Recommenders um einen nutzerbasierten Ansatz ist geplant und wurde strukturell bereits vorbereitet.

⁴ URL: <http://wortschatz.uni-leipzig.de/>

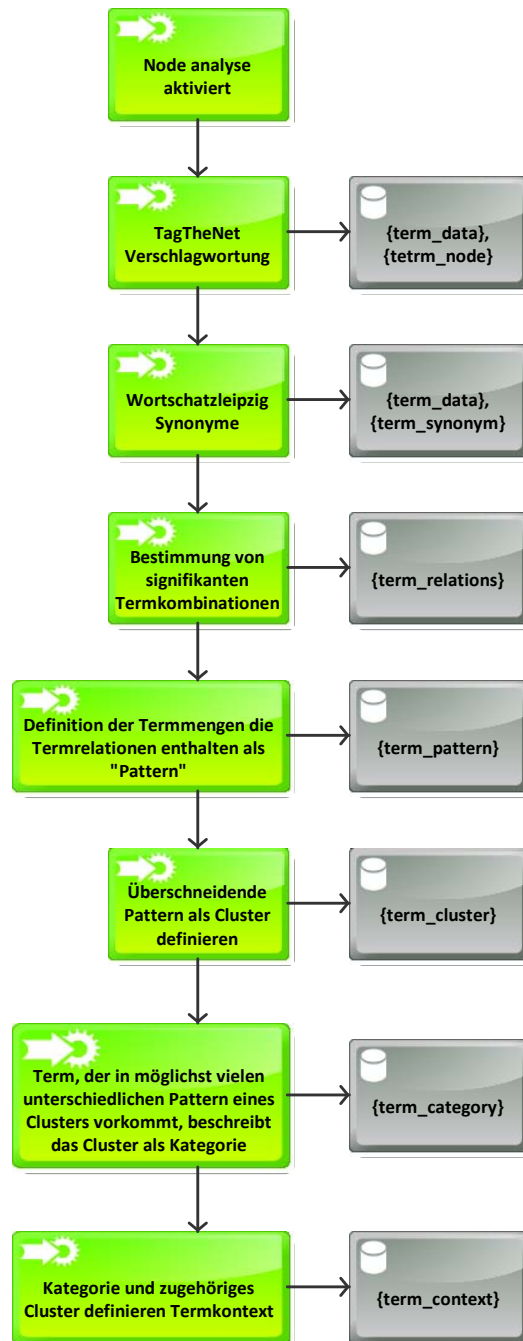


Abbildung 3: Ablauf Inhaltsanalyse

3.4 Verzahnung der Komponenten des Empfehlungssystems

Durch die Verzahnung der beschriebenen Komponenten kann eine Empfehlung generiert werden. In Testläufen mit den einzelnen Verfahren zeigt sich, dass sie einzeln angewendet für die Wissensgemeinschaft von Q-Online keine ausreichende Qualität liefern und den Benutzern keine „nützliche“ Zusatzinformation liefern. Dies liegt zum Beispiel daran, dass formale Bildungsangebote aufgrund der gut definierten Zielgruppe sowie einem standardisierten Weiterbildungsrahmen häufig eine hohe Ähnlichkeit zueinander aufweisen. Durch eine reine Inhaltsanalyse lässt sich die Informationsmenge nicht sinnvoll einschränken. Erst wenn Nutzerattribute - wie Gewerk oder Wohnort - und das Verhalten im Sinne von Kontakten und betrachteten Beiträgen hinzukommen, kann ein passender Kontext hergestellt werden, der als Grundlage dienen kann, um „relevante“ Informationen für den Nutzer selektieren zu können.

Der Empfehlungsprozess kann durch verschiedene Einstiegspunkte gestartet werden. Wenn ein Nutzer eine Suche durchführt oder Inhalte betrachtet, interagiert er indirekt mit dem Empfehlungssystem. Jede Interaktion wird zuerst in eine Suchanfrage umgewandelt, welche an die interne Suchmaschine übermittelt wird. Dies passiert unabhängig zur Inhaltsanalyse sowie der Nutzerpräferenzbestimmung. Dieses Vorgehen optimiert den Suchprozess, reduziert erneut das Lastaufkommen und bietet die Möglichkeit bei höheren Nutzerzahlen die Infrastruktur flexibel zu erweitern. Das reine Suchergebnis wird danach bezüglich der Nutzerpräferenzen und den Ergebnissen der Inhaltsanalyse restrukturiert und ggf. ergänzt. Dadurch wird das Suchergebnis personalisiert und bei Bedarf soweit aufbereitet, dass zum Beispiel bei Übersichtsseiten eine Durchlässigkeit zu weiteren Themen hergestellt werden kann.

Allerdings hat sich bereits gezeigt, dass ab einer gewissen Inhaltmenge mit erheblichen Ressourcenbelastungen zu rechnen ist. Hier wird bei der Weiterentwicklung besonders auf Optimierungs- und Cachingstrategien Wert gelegt werden müssen. Da sich die Integration eines Social Recommenders somit nachhaltig auf die technischen Anforderungen eines Systems auswirkt hat dies auch Konsequenzen für den ökonomischen Betrieb einer solchen Plattform.

4 Fazit

Lernarrangements werden durch den Einsatz von Web 2.0- Ansätzen und Technologien zu sozial-kommunikativen und kollaborativen Lernräume für „Communities of Practice“, in denen sich Lernen in einer Wissensgemeinschaft vollzieht. In einer solchen Umgebung, die auf Web 2.0-Ansätzen basiert, sind die Benutzer gewohnt, Beiträge „frei“ einzustellen und zu verschlagworten, also ohne Nutzung vorgegebener Kategorien oder Taxonomien. Hier zeigt sich, dass ein Social Recommender notwendig ist, um den User Generated Content erschließbar zu machen. Für die „Community des Handwerks“ Q-Online konnte – auf Grundlage der Kombination mehrerer Verfahren – ein Mechanismus implementiert werden, der den User Generated Content für Nutzer erschließt und die Präsentation von Informationen in der Wissensgemeinschaft in Abhängigkeit vom Benutzerverhalten steuert.

Das System ist funktionsfähig implementiert und wird, im nächsten Schritt, im Feldtest erprobt. Die bisherigen Ergebnisse deuten darauf hin, dass die Parameter des *Nutzerverhaltens* im Vergleich zur *inhaltlichen Ähnlichkeit* für die Auswahl von Informationen einen höheren Stellenwert in der Empfehlungsfindung haben sollte, weil dies aus Sicht der Nutzer zu besseren Empfehlungen führt. Im Rahmen eines Feldtestes wird erprobt werden, inwieweit die User die Empfehlungen des Recommenders tatsächlich aufrufen und wie sie die einzelnen Empfehlungen bewerten. Dabei wird zu prüfen sein, welche der Komponenten die besten Empfehlungen liefert und wie sich diese – auch in ihrem Zusammenwirken – weiter verbessern lassen. Denn bei der Entwicklung eines Social Recommenders für Wissensgemeinschaften, der wesentlich auf User Generated Content setzt, werden solche Parameter im Rahmen von Feldtests grundsätzlich sehr genau analysiert und angepasst werden müssen, um dem Nutzer die „richtigen“ Informationen zu empfehlen.

Literaturverzeichnis

- [Ab09] F. Abel, I. Marenzi, W. Nejdl, S. Zerr, Sharing Distributed Resources in Learn-Web2.0. In: Cress, U., Dimitrova, V., Specht, M. (eds.) Proc. of 4th European Conference on Technology Enhanced Learning (ECTEL 2009). Lecture Notes in Computer Science, Vol. 5794. Springer-Verlag (2009) 154-159.
- [Ag10] Armano, G.: Intelligent information access. Springer, Berlin, 2010.
- [BH07] Brusilovsky, P., & Henze, N. (2007). Open Corpus Adaptive Educational Hypermedia. In P. Brusilovsky, A. Kobsa & W. Nejdl (Eds.), The Adaptive Web: Methods and Strategies of Web Personalization. (Lecture Notes in Computer Science ed., Vol. 4321, pp. 671-696). Berlin Heidelberg New York: Springer.
- [Br10] Brusilovsky, P., Cassel, L. N., Delcambre, L. M., Fox, E. A., Furuta, R., Garcia, D. D., Shipman III, F. M., u. a. (2010). Social navigation for educational digital libraries. Proceedings of the 1st Workshop on Recommender Systems for Technology Enhanced Learning (RecSysTEL 2010), Procedia Computer Science, 1(2), 2889-2897.
- [CDS09] Cress, U., Dimitrova, V., Specht, M. (eds.) Proc. of 4th European Conference on Technology Enhanced Learning (ECTEL 2009). Lecture Notes in Computer Science, Vol. 5794. Springer-Verlag (2009)
- [Dr09] H. Drachler, D. Pecceu, T. Arts, E. Hutten, L. Rutledge, P.v. Rosmalen, H. Hummel, R. Koper, ReMashed — Recommendations for Mash-Up Personal Learning Environments. In: Cress, U., Dimitrova, V., Specht, M. (eds.) Proc. of 4th European Conference on Technology Enhanced Learning (ECTEL 2009). Lecture Notes in Computer Science, Vol. 5794. Springer-Verlag (2009) 788-793.
- [Fi08] Fitzgerald, B.: Drupal for Education and E-Learning. Packt, Birmingham, 2008.
- [FDB02] Fallon, C.; Dams, J. M.; Brown, S.: E-Learning Standards: A Guide to Purchasing, Developing, and Deploying Standards-Conformant E-Learning. St Lucie Pr., 2002.
- [He04] Herlocker J.L., Konstan J.A., Terveen L.G., Riedl J.T. (2004) "Evaluating Collaborative Filtering Recommender Systems", ACM Transactions on Information Systems, Vol. 22, No. 1, January 2004, Pages 5–53.
- [Hm] Hübener, M.: Suchmaschinenoptimierung kompakt. Anwendungsorientierte Techniken für die Praxis. Springer, Berlin, 2010.
- [Ka10] Kantor, P. B., Ricci, F., Rokach, L., & Shapira, B. (2010). Recommender Systems Handbook (1. Aufl.). Springer, Berlin.
- [Ke01] Kerres, M.: Multimediale und telemediale Lernumgebungen. Oldenbourg, München, 2001.

- [Ke06] Kerres, M. (2006). Potenziale von Web 2.0 nutzen. In A. Hohenstein & K. Wilbers (Hrsg.), *Handbuch E-Learning*. München: DWD-Verlag.
- [Kl09] Klahold, A.: *Empfehlungssysteme*. Vieweg+Teubner, Wiesbaden, 2009.
- [LW91] Lave, J. & Wenger, E. (1991). *Situated Learning: Legitimate peripheral participation*. New York: Cambridge University Press.
- [Mö10] Mödritscher, F. (2010). Towards a recommender strategy for personal learning environments. *Proceedings of the 1st Workshop on Recommender Systems for Technology Enhanced Learning (RecSysTEL 2010) Procedia Computer Science*, 1(2), 2775-2782.
- [Ne08] Nejdil, W., Kay, J., Pu, P., Herder, E. (eds.) *Proc. of 5th International Conference on Adaptive Hypermedia and Adaptive Web-Based Systems (AH'2008)*. Lecture Notes in Computer Science, Vol. 5149. Springer Verlag (2008)
- [Ni08] Niegemann, H. M.: *Kompodium multimediales Lernen*. Springer, Berlin, 2008.
- [VK09] Vuorikari, R., & Koper, R. Ecology of social search for learning resources. *Campus-Wide Information Systems*, 26(4), 272-286, 2009.
- [Vy78] Vygotsky, L. S. (1978). *Mind in Society: The Development of Higher Psychological Processes*: Harvard University Press.
- [Wi90] Winkler, W. E. (1990). String Comparator Metrics and Enhanced Decision Rules in the Fellegi-Sunter Model of Record Linkage. In *Proceedings of the Section on Survey Research Methods*, American Statistical Association, 1990, S. 354-359.
- [WVK10] Westrup, D.; Vervenne, M.; Kerres, M.: Die Implementierung des SCORM Standards und dessen Implikation für zukünftige Lehr-/ Lernszenarien auf Basis von Drupal. In (Schroeder, U. Hrsg.): *Interactive Kulturen Proceedings der Workshops der DeLFI 2010 – Die 8. E-Learning Fachtagung Informatik der Gesellschaft für Informatik e.V., Duisburg, 2010*. Logos Verlag, Berlin, 2010; S. 275-280.