

# Kontaktanbahnung in Lernplattformen

Tim Reichling<sup>1</sup>, Andreas Becks<sup>2</sup>, Oliver Bresser<sup>2</sup>, Volker Wulf<sup>1,2</sup>

<sup>1</sup>Institut für Wirtschaftsinformatik der Uni Siegen, Hölderlinstr. 3, Siegen

<sup>2</sup>Fraunhofer Institut für Angewandte Informationstechnologie (FhG-FIT),  
Schloss Birlinghoven, Sankt Augustin

## Zusammenfassung

Die soziale Vernetzung menschlicher Akteure spielt eine zentrale Rolle in Prozessen des Lernens und des Wissensmanagements. Traditionelle Lernplattformen bieten allerdings keine Möglichkeiten zur sozialen Vernetzung der Lernenden. Deshalb wird zur Ergänzung bestehender Lernplattformen ein System einwickelt, das Lerner bei der gezielten Kontakthanbahnung im virtuellen Raum unterstützt. Dazu werden personenbezogene Daten über Fähigkeiten, Interessen oder Bedürfnisse von Lernern algorithmisch miteinander abgeglichen. Dies wird in diesem Aufsatz am Beispiel zweier Algorithmen beispielhaft verdeutlicht. Das Ergebnis des Abgleichs, eine Menge potenziell interessanter Nutzer, wird den Lernern angezeigt.

## 1 Einleitung

Cohen und Prusak (2001) argumentieren, dass Netzwerke informeller Beziehungen eine interessante neue Perspektive bieten, um Wissensprozesse in Organisationen zu verbessern. Auch in der lerntheoretischen Diskussion gewinnen Ansätze an Bedeutung, die auf den kollektiven Charakter von Wissensprozessen abstellen. Soziokulturelle Theorien betonen die Bedeutung gemeinsamer Praxis und kollektiver Identität für Lernprozesse (vgl. Lave und Wenger 1991; Brown und Duguid 1991; Wenger 1998).

Akzeptiert man den durch die sozialwissenschaftliche Forschung nahegelegten Wert informeller sozialer Netzwerke für Wissenskonstruktion und -verbreitung, so muss die angewandte Informatik diese Perspektive bei der Gestaltung technologischer Lösungen in Betracht ziehen (vgl. Ackerman, Pipek und Wulf 2003; Huysman und Wulf 2004). Diesbezüglich soll im Folgenden untersucht werden, wie die Funktionalität von Lernplattformen die soziale Vernetzung von Lernenden fördern kann. Durch spezielle Funktionen sollen Studierende miteinander im virtuellen Raum der Lernplattform bekannt gemacht werden, die über ähnliche oder sich ergänzende Fähigkeiten, Interessen oder Bedürfnisse verfügen. Dazu müssen personenbezogene Daten der Lerner erfasst, modelliert und evaluiert werden.

Im Folgenden soll zunächst der aktuelle Stand der Forschung zur Vernetzung von Akteuren im virtuellen Raum referiert werden. Dann soll eine Anwendung dargestellt werden, die in einer E-Learning-Plattform potenziell zueinander passende Nutzer miteinander bekannt macht.

## 2 Stand der Forschung

Untersuchungen auf dem Gebiet computergestützter kooperativer Arbeit (Computer Supported Cooperative Work (CSCW) und Künstliche Intelligenz (KI)) bieten eine Basis, um Nutzer von Lernplattformen miteinander zu vernetzen. Anwendungen, die es erlauben, persönliche Expertise für Andere einfach zugreifbar darzustellen, ermöglichen die Kontaktaufnahme und erleichtern den Zugang zu explizitem und implizitem Wissen. Beim Standardverfahren werden die Akteure gebeten, die Daten selbst einzugeben, die ihr Wissen oder ihre Interessen repräsentieren („yellow page“-Systeme). Problematisch ist dabei, dass die Nutzer motiviert werden müssen, ihre persönlichen Profile einzugeben und ständig auf dem neuesten Stand zu halten. Besonders das Problem der Aktualisierung beeinträchtigt die Gültigkeit und Nützlichkeit der Profildaten (vgl. Pipek, Hinrichs und Wulf 2003). Deshalb ist es zweifelhaft, ob diese Daten allein die Kompetenzen und Interessen der Akteure hinreichend widerspiegeln.

Experten-Recommend-Systeme wurden entworfen, um das Auffinden menschlicher Akteure zu unterstützen. Systeme wie beispielsweise „Who knows“ (Streeter und Lochman 1988) oder Yenta (Foner 1997) extrahieren Personaldaten über menschliche Interessen automatisch aus Dokumenten, die von den Akteuren erstellt wurden, und erlauben so eine Suche über die gewonnenen Profildaten. Vivacque und Lieberman (2000) haben ein System entwickelt, das Daten bezüglich des Qualifikationsniveaus eines Programmierers aus dem von ihm entwickelten Java-Code extrahiert. Basierend auf diesen personenbezogenen Daten erlaubt das System, Fragen zu stellen oder Akteure miteinander bekannt zu machen. Diese Ansätze basieren jeweils auf einem Vergleichsalgorithmus, der speziell für einen bestimmten Typ personenbezogener Daten konzipiert werden muss.

McDonald (2000) entwickelte eine Architektur für Recommender-Systeme, die die Lokalisierung von Akteuren unterstützt, die Expertise auf einem speziellen Gebiet vorweisen können. Im Gegensatz zu den oben erwähnten allgemeinen Ansätzen zur Auswahl von Experten erlaubt es diese Architektur ganz speziell an den individuellen organisatorischen Kontext angepasste Heuristiken zu entwickeln. Diese Heuristiken müssen durch eine vorhergehende ethnografische Studie im Anwendungsfeld aufgedeckt werden.

### 3 Technisch moderierte Kontakthanbahnung in Lernplattformen

Das Identifizieren, Sammeln und Auswerten von personenbezogenen Daten zum Zwecke der Vernetzung menschlicher Akteure kann mit erheblichen Schwierigkeiten verbunden sein. Im Hinblick auf die technisch moderierte Kontakthanbahnung in Lernplattformen sind wir dabei in einer vorteilhaften Position. Die Kursstruktur, die Navigationshierarchie über den Lerninhalten sowie weitere Metadaten zur Klassifikation von Lerninhalten können dazu verwendet werden, automatisch aufgezeichnete Daten semantisch anzureichern. Spezielle Funktionen einer Lernplattform, wie die Erfassung von Testergebnissen, erlauben es persönliche Profile automatisch zu aktualisieren. Viele, teilweise komplementäre Typen personenbezogener Daten, die in Lernplattformen anfallen, können für die Kontakthanbahnung ermittelt und genutzt werden. So können Metadaten über die Erstellung oder Aktualisierung von Kursinhalten verwendet werden, um Autoren oder Editoren als Experten für bestimmte Fachgebiete zu identifizieren. Zusätzlich können Rollenmodelle helfen, Akteure zu finden, die tutorielle Aufgaben für spezielle Inhalte erfüllen oder erfüllt haben. Ergebnisse und Inhalte von Online-Tests charakterisieren das Fachwissen von Lernern auf bestimmten Gebieten und Interaktionshistorien dokumentieren die aktuelle oder vergangene Nutzung bestimmter Lernmaterialien: Akteure, die in bestimmten Inhalten der Plattform navigiert haben oder navigieren, haben Interesse an diesem Gebiet gezeigt oder verfügen sogar über gewisse Kenntnisse.

Im Folgenden bezeichnen wir die technisch moderierte Kontakthanbahnung in einer Lernplattform als *Expert Finding*. Damit ist der algorithmische Abgleich von persönlichen Daten (oder einer explizit formulierten Anfrage) eines Benutzers mit den Profilen anderer Benutzer gemeint. Dieser Abgleich erfolgt mit dem Ziel, jeweils passende Wissensträger einander vorzuschlagen. Dabei unterscheiden wir zwei verschiedene Arten der Benutzung der Expert Finding-Komponenten (vgl. Becks, Reichling und Wulf 2003):

- *Filterfunktionalität*: In diesem Modus wird das Expert Finder-System benutzt, um andere Benutzer zu finden, deren persönliche Daten (bzw. relevante Teile davon) den eigenen ähneln. Diese Funktionalität ist geeignet, wenn Lerner andere Lerner mit ähnlichem Hintergrund, Wissensstand oder ähnlichen Interessen suchen, um sich als Lerngruppen zu organisieren. Alternativ kann ein Lerner anstelle seines eigenen Profils ein eigens definiertes „Wunschprofil“ als Suchparameter angeben, um Akteure zu finden, die speziellen Anforderungen genügen, beispielsweise bei der Suche nach einem Experten auf einem bestimmten Gebiet, der bei der Lösung eines Problems helfen kann.
- *Cluster-Funktionalität*: Hier wird das Expert Finder-System benutzt, um auf allen vorhandenen Benutzerprofilen nach Gruppen ähnlicher Expertisen zu suchen. Diese eignen sich zur Analyse der fachlichen Community-Struktur und kann auch als Grundlage zur Visualisierung einer „Kompetenzlandschaft“ dienen.

Der Begriff der „persönlichen Daten“ ist bewusst allgemein gewählt und kann den Lern- und Trainingsstatus, Interessensangaben, Selbsteinschätzungen bzgl. eigener Fähigkeiten, bestimmte History-Informationen (z.B. Historien aus der Lernumgebung oder aus dem Un-

ternehmen) und ähnliche Daten über den Benutzer beinhalten, die den Experten-Status des Benutzers beschreiben.

Unser algorithmisches Rahmenmodell ermöglicht die gemeinsame Verwendung verschiedener Module für das Matching personenbezogener Daten und erlaubt damit, jeweils problemorientierte Vergleichsalgorithmen für bestimmte Teilmengen der Profildaten zu realisieren. Dabei wird auch der Grad der Vollständigkeit der verwendeten Profildaten berücksichtigt, beispielsweise die Menge von Historiendaten in einem Profil. Ist nämlich ein Benutzer neu für die Lernplattform eingeschrieben, so stehen nur wenige (oder keine) Historiendaten zur Verfügung. In einem solchen Fall könnte eine Vergleichsfunktion über Historiendaten einen hohen Wert für die Übereinstimmung der verglichenen Profile erreichen, der jedoch auf einer sehr geringen Menge von Daten beruht. Eine entsprechende Vollständigkeitsfunktion gleicht diesen Wert dann wieder aus.

Das Rahmenmodell sieht auch vor, dass jeder Benutzer die Anteile der verschiedenen Vergleichskriterien am Gesamtergebnis des Vergleichs selbst bestimmen kann. Auch kann er seine Privatsphäre schützen: Wenn ein Benutzer nicht möchte, dass das System auf bestimmte Teile seines Profils zugreift, so hat er die Möglichkeit, die entsprechenden Vergleichsmodule zu deaktivieren. Ein Modul hat lediglich dann Einfluss auf das Gesamtergebnis, wenn alle beteiligten Benutzer der Verwendung ihres Profils bei der Berechnung des Vergleichswertes zustimmen. Becks, Reichling und Wulf (2003) beschreiben Details und eine Formalisierung dieses Rahmenmodells.

## 4 Ein prototypisches Expert Finder-System für die eQF-Lernplattform

Basierend auf dem methodischen Ansatz, der in diesem Papier vorgestellt wurde, haben wir ein Experten Suchsystem für das Fraunhofer e-Qualification Framework – eine e-Learning-Umgebung, die extensive technische, methodische und didaktische Unterstützung sowohl für die Autoren von webbasierten Lektionen als auch die Lernenden anbietet – implementiert.

### 4.1 Verfahren zum Matching

Im Folgenden werden zwei Strategien zum Vergleich von Benutzern beschrieben (Matching-Strategien). Diese unterscheiden sich in erster Linie durch die Natur der Benutzerdaten, die zur Charakterisierung der Benutzer herangezogen werden. Im ersten Fall (*Profile Matching*) werden Benutzer aufgrund der von ihnen angegebenen Daten bezüglich Schul- und Ausbildungsstands sowie Berufs- und Managementenerfahrung verglichen. Diese Daten werden als statisch betrachtet, da sie sich auf Merkmale der Benutzer beziehen, die weitgehend unveränderlich sind. Im zweiten Fall (*History Matching*) werden die aktuellen Benutzerinteressen und Kenntnisse zum Vergleich verwendet. Diese werden als dynamisch betrachtet, da sie aus den Inhalten der Lernplattform abgeleitet werden, die der Benutzer konsumiert (Historie).

#### 4.1.1 Profile Matching

Durch das *Profile Matching* wurde ein Matchingverfahren realisiert, das den *Fit* zweier Benutzer aufgrund ihres Ausbildungsstandes und ihrer Berufserfahrung errechnet. Dabei werden von Benutzern folgende Daten ermittelt, die das Benutzerprofil bilden:

1. *Schulbildung/Schulabschluss* (durch Auswahl vorgegebener Möglichkeiten die von „keine formale Ausbildung“ über „Abitur“ bis „Promotion“ reichen).
2. *Beschäftigungsfeld* (durch Auswahl aus einer umfassenden Zahl vorgegebener Kategorien, die durch eigene Angaben ergänzt werden können).
3. *Erfahrung in Beruf und Management* (durch Angabe der Jahre, in denen sie Erfahrung gesammelt haben).

Die Beschäftigungsfelder sind grob in Kategorien zusammengefasst, die für das Matching von Bedeutung sind, beispielsweise „Vertrieb, Handel und Einkauf“ oder „Finanzen, Banken und Versicherungen“. Auf diese Weise können Ähnlichkeiten zwischen Benutzern ermittelt werden, auch wenn keine exakte Übereinstimmung zwischen Beschäftigungsfeldern auftritt.

Der Matching-Algorithmus *Profile Matching* ermittelt ein Ähnlichkeitsmaß zwischen zwei Benutzern der Lernplattform (*Co-Learner*) durch Vergleiche auf den drei verschiedenen Bereichen ihres Profils, die dann zu einem Gesamtergebnis aufsummiert werden. Da wir davon ausgehen, dass die einzelnen Profilmerekmale je nach Lernumgebung unterschiedliches Gewicht für das Matching der Akteure haben, fließen sie mit unterschiedlichen prozentualen Anteilen in das Gesamtergebnis ein. Die einzelnen Gewichte können dabei einfach angepasst werden. Auf Grundlage einer empirischen Untersuchung wurden die Gewichte mit 50% für das Berufsfeld, mit 25% für die Berufserfahrung, mit 15% für die Ausbildung und mit 10 % für die Managementenerfahrung vorgelegt. Die Vergleichsstrategien für drei Profilschnitte werden im Folgenden erläutert.

Beim Matching der Berufsfelder werden zunächst die (Ober-) Kategorien der Berufsfelder miteinander verglichen. Sind dort identische Einträge in beiden Benutzerprofilen verzeichnet, werden auch die entsprechenden Berufsfelder direkt miteinander auf Ähnlichkeiten verglichen. Sowohl bei Berufskategorien als auch bei Berufsfeldern werden *Ähnlichkeitsmatrizen* herangezogen, um nicht identische Kategorien und ggf. Felder beider Benutzerprofile bewerten zu können. Diese enthalten Werte zwischen 0 und 1, die die Verwandtheit zweier Berufskategorien bzw. Berufsfelder beinhalten. Dabei werden identische Einträge mit dem Wert 1 bewertet. Das Ergebnis dieses ersten Vergleiches ist die Summe des Vergleiches der Kategorien und des Vergleiches der Berufsfelder.

Der zweite Teil des Matchings vergleicht die Angaben über die Ausbildung der Benutzer. Hierfür wurden den verschiedenen Abschlüssen Werte zwischen 1 und 30 zugewiesen (1 für „keine formale Ausbildung“ und 30 für „Promotion“). Das Ergebnis des Vergleiches ist 1, falls die Abschlüsse der verglichenen Benutzer übereinstimmen, und sinkt mit dem Betrag der Differenz der beiden Werte, der durch den höheren der beiden Werte dividiert wird. Somit liegt auch hier das Ergebnis zwischen 0 und 1 und spiegelt die „Nähe der Abschlüsse“ beider Benutzer wider.

Für das Matching der Berufs- und Managementenerfahrung wird analog vorgegangen. Der Abstand der beiden Angaben in Jahren wird durch die maximale Angabe geteilt und von eins abgezogen. So liegt das Ergebnis zwischen 0 und 1. Mit größer werdendem Abstand sinkt das Ähnlichkeitsmaß. Benutzer mit nah beieinander liegender Berufs- bzw. Managementenerfahrung werden also als ähnlicher angesehen.

Die Zusammenfassung der Ergebnisse der einzelnen Module zu einer Gesamtbewertung hängt von der oben definierten Gewichtung ab. Diese Gewichtungen sind somit sehr wichtig und haben einen zentralen Einfluss auf die Ergebnisse. Für die Berechnung der Empfehlung von Co-Lernern, für einen ausgewählten Benutzer, wird dieser Wert mit dem aller anderen Lerner verglichen. Die Benutzer, für die das Matching eine „Ähnlichkeit“ liefert, die über einem Schwellenwert liegt, werden als Co-Lerner empfohlen.

#### 4.1.2 History Matching

Das *History Matching* arbeitet im Gegensatz zum Profile Matching auf dynamischen Benutzerinformationen, die im Laufe der Zeit gewonnen werden, während der Benutzer die Lernplattform benutzt, also dort verschiedene Inhalte abrufen. Über die abgerufenen Inhalte wird eine Benutzerhistorie gepflegt, über die auf die Benutzerinteressen geschlossen wird<sup>1</sup>. De facto werden also nicht Verweise auf die Inhalte selbst verwaltet, sondern die daraus extrahierten Stichwörter, die als einzelne Benutzerinteressen interpretiert werden. Diese werden in gewichteter Form durch das System verwaltet. Die Gewichtung einzelner „Benutzerinteressen“ steigt mit jeder erneuten Eingabe derselben und kann dadurch in ihrer Bedeutung steigen.

Werden nun zwei Benutzerprofile über das History Matching miteinander verglichen, so werden deren gewichtete Benutzerinteressen herangezogen (siehe unten). Werden Übereinstimmungen hinsichtlich eines Stichwortes entdeckt, so geht das Produkt der beiden Gewichtungen in das Gesamtergebnis ein. Dieses wird für ein Benutzerpaar also durch die Summe der Produkte der Gewichte übereinstimmender Benutzerinteressen gebildet. Formell lässt sich dieser Sachverhalt wie folgt beschreiben:

Sei  $N$  die Gesamtzahl aller gespeicherten Benutzerinteressenprofile und  $k \neq l$  die Indizes zweier zu vergleichender Profile. Weiter seien  $I_i(k)$  bzw.  $g_i(k)$  die  $i$ -te Interesse des  $k$ -ten Benutzers bzw. deren Gewicht. Das Gesamtergebnis  $S_{k,l}$  der des Vergleiches des  $k$ -ten und  $l$ -ten Profils errechnet sich nach der folgenden Formel:

$$S_{k,l} = \sum_{i=1}^n g_i(k,l), \text{ wobei } g_i(k,l) = g_i(k) \cdot g_i(l), \text{ falls } I_i(k)=I_i(l), \text{ und } 0 \text{ sonst.}$$

Da die hier zustande kommenden Gesamtergebnisse außerhalb des Intervalls  $[0, 1]$  liegen können, werden diese wie folgt normiert: Ist  $S$  das Gesamtergebnis, so ist

<sup>1</sup> Das Expert Finding Framework basiert auf der Annahme, dass die Inhalte der Anwendungsplattform Stichwörter über sich selbst preisgeben. Diese können explizit angegeben werden wie bei HTML-Meta-Tags oder sich mithilfe linguistischer Verfahren aus Texten extrahieren lassen (Heyer et al., 2002).

$$N(S) := 1 - \frac{1}{1+S}$$

der normierte Wert von  $S$ . Da für  $S$  nur Werte in Frage kommen, die größer als oder gleich 0 sind, liegen die Werte  $N(S)$  innerhalb von  $[0, 1]$ . Zudem gilt  $N(0)=0$ , und  $[a < b] \Rightarrow [N(a) < N(b)]$ , also monotonen Wachstum, was zu den (intuitiven) erforderlichen Eigenschaften dieser Funktion gehört. Die Normfunktion  $N$  wird auch für die Feststellung des Completeness-Wertes verwendet: Dieser berechnet sich für jeden Benutzer als Summe  $C$  der Gewichte aller seiner Interessen. Als normierter Completeness-Wert geht  $N(C)$  in die Bewertung ein.

Ein Wert von  $n=50$  der signifikantesten Benutzerinteressen erweist sich dabei als praktikabel. Dieser Wert ist (und hier zeigt sich u.a. der experimentelle Charakter des Systems) anpassbar. Durch das Festlegen einer konstanten Anzahl von Benutzerinteressen, die zum Vergleich herangezogen werden, lässt sich das Laufzeitverhalten des Algorithmus besser kontrollieren. Andererseits sollte der Wert nicht zu klein gewählt sein, da die Aussagekraft des Ergebnisses ansonsten nicht mehr gegeben ist.

Bestandteil der Datenverwaltung ist eine zeitabhängige Reduktion der Benutzerinteressen. Ausgehend von der Annahme, dass sich Benutzerinteressen im Laufe der Zeit ändern, werden die gesamten Interessen aller Benutzer in regelmäßigen Zeitabständen (wöchentlich, aber auch dieser Wert ist anpassbar) einer *Gewichtungsreduktion* unterzogen. Dies bedeutet, dass die Gewichtung aller Interessen mit einem Faktor von  $0,95$  multipliziert wird. Dies führt zu einer exponentiellen Verminderung des Interessengewichtes im Laufe der Zeit, die sich asymptotisch dem Wert Null annähert. Hierdurch wird gewährleistet, dass unter zwei prinzipiell gleichwertigen Benutzerinteressen diejenige höher bewertet wird, deren Ermittlung später stattgefunden hat. Dies sollte der Natur der Benutzer entsprechen.

Der Vorteil dieses dynamischen Verfahrens ist, dass die Daten automatisch auf dem aktuellen Stand gehalten werden. Zudem wird davon ausgegangen, dass sich die Kombination von zeitlicher Reduktion sowie automatischer Aktualisierung die Fehlertoleranz des Verfahrens erhöht. So wird ein irrtümlich ermitteltes Benutzerinteresse zum einen durch die zeitliche Reduktion nach und nach eliminiert, zum anderen sollte ein fehlerhaftes Benutzerinteresse nicht durch wiederholte Ermittlungen „bestätigt“ werden, was bei „echten“ Interessen jedoch anzunehmen ist.

## 4.2 Architektur und Implementierung

Die Architektur des Expert Finding Systems (Abb. 1) ist so gestaltet, dass es flexibel und einfach an verschiedene Anwendungsplattformen anzupassen ist. Sie besteht aus drei Hauptkomponenten: (1) dem Expert Finding selbst, das die Implementierung des algorithmischen Frameworks darstellt, (2) der Anbindung zum Client, d.h. Web Browser und (3) der Anbindung zur Lernplattform. Da das System auf verschiedene Lernplattformen anwendbar sein soll, kann kein einheitlicher Weg des Datenaustausches mit der Lernplattform vorausgesetzt werden. Deshalb mussten wir *Plattformadapter* einführen, die schnell und einfach entwickelt

werden konnten. Diese Adapterobjekte mussten plattformspezifische Daten in ein Format übersetzen, mit dem die Expert Finding-Komponente arbeiten kann. In diesem Fall handelt es sich um Benutzerdaten, die innerhalb der Lernplattform verwaltet werden, sowie die Beschreibungen der Inhalte der Lernplattform. Zudem wird das Expert Finding-System mittels der Plattformadptoren über die Aktivitäten der Lerner „auf dem Laufenden gehalten“, um jederzeit auf aktuelle Interessenprofile zugreifen zu können (siehe Kap. 5.1.2). Für das Überstellen einer solchen Information hat sich der Begriff des *User-Moves-Ereignises* etabliert. Die Verbindung zum Client erfolgt durch ein Java™ Servlet (*EFServlet*, (2)), das mit dem Expert Finding-System interagiert und das (HTML-basierte) Benutzerinterface erzeugt.

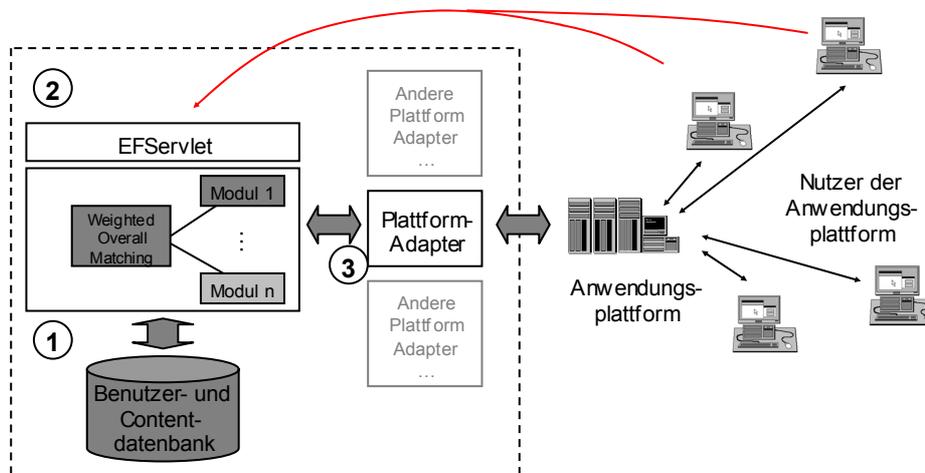


Abbildung 1: Architektur des Expert Finding-Systems

Die Hauptkomponente, das Expert Finding, besteht aus internen Datenbanken, in denen Informationen über die Benutzer und die Inhalte der Lernplattform zwischengespeichert sind („Cache“). Hierdurch soll zum einen ein schneller Zugang zu solchen Informationen ermöglicht werden, die regelmäßig vom Expert Finding genutzt werden. Zum anderen können so zusätzliche Daten über Benutzer und Inhalte gespeichert werden, die in der Datenbank der Anwendungsplattform nicht verwaltet werden. Die Hauptaufgabe des Expert Findings (d.h. das Auffinden passender Benutzer anhand von Profilvergleichen) bleibt den Expert Finder-Modulen überlassen, die jeweils eine eigene Vergleichsstrategie anwenden. Die Ergebnisse der verschiedenen Expert Finding-Module werden gemäß individueller Benutzerpräferenzen gewichtet. Im Filtermodus wird den Lernern daraus abgeleitet eine Rangfolge der am besten geeigneten Nutzer präsentiert. Im Clustermodus werden die Nutzer auf der Basis dieser Daten auf einer zwei-dimensionalen Wissenslandkarte angeordnet.

Die Implementierung des Expert Finding-Systems umfasst das Framework inklusive der beschriebenen Expert Finder-Module sowie die Web-Schnittstelle (*EFServlet*). Weiterhin

beinhaltet die Implementierung grundlegende Funktionalität zur Kommunikation zwischen Benutzern. So können andere Nutzer direkt ausgewählt werden und zu einem Chat einladen oder per Mail angesprochen werden. Das durch das EFServlet erzeugte Benutzerinterface erlaubt neben der Durchführung von „Expertise-Anfragen“ und der Kommunikation zwischen Benutzern auch die Anpassung der eigenen Profildaten: Zum einen können die persönlichen Präferenzen (individuelle Gewichtung der einzelnen Expert Finder-Module) eingestellt werden, zum anderen können jene Teile des Profils ausgewählt werden, die als „privat“ gelten sollen und nicht von den Matching-Algorithmen herangezogen werden dürfen.

## 5 Zusammenfassung

Im Gegensatz zum klassischen Präsenzlernen bieten Lernplattformen nicht die Möglichkeit, durch direkte Kontakte und soziale Netzwerke von Lernern zu bilden. Wir sind hier der Frage nachgegangen, ob es virtuelle Substitute für die Netzbildung gibt und wie diese medial gestaltet werden können. Das vorliegende Papier stellt verschiedene Typen von Profildaten und dazu passende Matching-Algorithmen zur Vermittlung geeigneter Co-Lerner vor. Es skizziert ein algorithmisches Rahmenmodell sowie eine modulare Architektur für Kontaktanbahnungssysteme in Lernplattformen. In ersten Evaluationen konnten wir feststellen, dass die beiden realisierten Verfahren zum Matching von den Nutzern als sinnvoll anerkannt werden. Insbesondere lässt sich feststellen, dass die Gestaltung des Klassifikationsschemas zur Erfassung des Ausbildungsstandes sowie der Management- und Berufserfahrung weitgehend geeignet war, das eigene Profil zufrieden stellend darzustellen. Als zusätzlich zu berücksichtigende Eigenschaften eines Profil Matchings wurde von verschiedenen Nutzern ein Zeitbezug (Lebenslauf) vorgeschlagen. Grundsätzlich ist auch bei vielen Befragten die Bereitschaft vorhanden, die erhobenen Daten zur Identifikation von Lerngruppen zur Verfügung zu stellen, wobei am ehesten die Nennung der Berufserfahrung als sensibel angesehen wird. Es zeigt sich aber auch, dass ein Ausbildungs- und Beschäftigungsprofil nur als Bestandteil eines umfangreicheren Kriterienkatalogs zur Bildung von Lerngruppen für sinnvoll gehalten wird. In einer aktuell laufenden Untersuchung entwickeln wir den hier präsentierten Ansatz zur Kontaktanbahnung in einer verteilten Lernplattform für Auszubildende eines großen deutschen Telekommunikationsunternehmens weiter.

### Literaturverzeichnis

- Ackerman, M. S.; Pipek, V.; Wulf, V. (Hrsg.) (2003): Expertise Sharing: Beyond Knowledge Management. Cambridge: MIT Press, MA 2003.
- Becks, A.; Reichling, T.; Wulf, V. (2003): Supporting Collaborative Learning by Matching Human Actors. In: Ralph H. Sprague, Jr. (ed.): Proceedings of the Thirty-Sixth Annual Hawaii International Conference on System Sciences (HICSS-36). January 6-9, 2003, Big Island, Hawaii. [ohne Seiten].

- Becks, A.; S. Sklorz; M. Jarke (2000): Exploring the Semantic Structure of Technical Document Collections: A Cooperative Systems Approach. Fifth IFCIS International Conference on Cooperative Information Systems (CoopIS'2000). September 6-8, Eilat, Israel.
- Brown, J. S.; Duguid, P. (1991): Organizational Learning and Communities of Practise: Towards a unified of Working, Learning, and Innovation. In: *Organization Science*, Vol. 2, Nr. 1, S. 40–58.
- Cohen, D.; Prusak, L. (2001): *In Good Company: How Social Capital makes Organizations Work*. Boston: Harvard Business School Press.
- Foner, L. N. (1997): Yenta: A Multi-Agent, Referral-Based Matchmaking System. In: *First International Conference on Autonomous Agents (Agent'97)*. New York: ACM-Press. S. 301–307.
- Heyer, G.; Quasthoff, U.; Wolff, Chr., (2002): Möglichkeiten und Verfahren zur automatischen Gewinnung von Fachbegriffen aus Texten. Proc. Innovationsforum „Content Management –Digitale Inhalte als Bausteine einer vernetzten Welt“. Stuttgart.
- Huysman, M.; Wulf, V. (Hrsg.) (2004): *Social Capital and Information Technology*. Cambridge: MIT-Press, MA 2004 im Druck.
- Lave, J.; E. Wenger (1991): *Situated Learning: Legitimate Peripheral Participation*. Cambridge: Cambridge University Press.
- McDonald, D. W. (2000): *Supporting Nuance in Groupware Design: Moving from Naturalistic Expertise Location to Expertise Recommendation*, PhD-thesis. University of California, Irvine.
- Pipek, V.; Hinrichs, J.; Wulf, V. (2002): Sharing Expertise: Challenges for Technical Support. In: Ackerman, M.; Pipek, V.; Wulf, V. (Hrsg.): *Expertise Sharing: Beyond Knowledge Management*. Cambridge: MIT-Press, MA 2002, S. 111–136.
- Specht, M. (1998): *Adaptive Methoden in computer-basierten Lehr-/Lernsystemen*. In: GMD Research Series. St. Augustin.
- Streeter, L. A.; Lochman, K. A. (1988): An expert/expert location system based on an automatic representation of semantic structure. In: *Proceedings of the Forth Conference on Artificial Intelligence Applications*. San Diego, CA, March 14 - 18, 1988. New York: ACM-Press. S. 345–350.
- Vivacque, A.; Lieberman, H. (2000): Agents to assist in finding help. In: *Proceedings in the Conference on Computer Human Interaction (CHI 2000)*. New York: ACM-Press. S. 65–72.
- Wenger, E. (1998): *Communities of Practice*. Cambridge: Cambridge University Press.
- Wulf, V. (2001): Zur anpassbaren Gestaltung von Groupware: Anforderungen, Konzepte, Implementierungen und Evaluationen. In: *GMD Research Series*, Nr. 10/2001. St. Augustin.