

Ein konzeptionelles Model auf Basis von Markov-Ketten zur Berechnung und Bewertung von persönlichen Kompetenzen in sozialen Netzwerken

Axel Winkelmann¹, Till Haselmann²

*¹Institut für Wirtschafts- und Verwaltungsinformatik,
Professur für Betriebliche Anwendungssysteme,
Universität Koblenz-Landau*

*²European Research Center for Information Systems,
Lehrstuhl für Wirtschaftsinformatik und Informationsmanagement,
Westfälische Wilhelms-Universität Münster*

1 Einleitung

Bewertungen und Evaluationen sind sehr wichtig für Menschen, besonders um Vertrauen zwischen Geschäftspartnern aufzubauen. Der Vorteil von Onlinebewertungen sind die Skalierbarkeit und Formalisierung von Bewertungen (Bolton et al. 2004, Dellarocas 2003). Skalierbarkeit heißt, dass Einschätzungen unabhängig von Zeit und Raum von verschiedenen Parteien gesammelt und an diese kommuniziert werden können (Resnick et al. 2000). Benutzer können leicht und kosteneffizient auf viele Bewertungen z. B. von Produkten zugreifen, die von anderen Nutzern bereitgestellt werden (Cheung et al. 2007).

Seit dem Aufkommen von Social Software wird nicht mehr nur die Evaluation von virtuellen Profilen relevant, sondern auch die Evaluation von realen Fähigkeiten im Internet. Dies hat seinen Grund darin, dass die Zahl der sozialen Aktivitäten im Internet mit Aufkommen des Web 2.0-Phänomens massiv gestiegen ist (Efimova 2004; Kelleher und Miller 2006).

In sozialen Netzwerken (SN) wie XING, Plaxo oder LinkedIn können Benutzer ihre Fachkompetenzen in Freitextfeldern in ihren Profilen benennen. Allerdings sind diese Eingaben ungeprüft. Sie haben weder eine feste Struktur noch kann der Betrachter auf ihre Vertrauenswürdigkeit schließen. Dies reduziert die Nützlichkeit der Angaben signifikant. So erlauben z. B. Internetseiten wie RateMDs.com für medizinischen Service oder RateMyTeacher.com für Lehrer

zwar die einfache Bewertung von Fachkompetenzen. Als Hindernis erweist sich jedoch, dass dabei nicht die Bewertungsqualität, die Beziehung zwischen Bewertendem und Bewertetem sowie die Kompetenz des Bewertenden für eine Bewertung berücksichtigt werden.

Mit dem Aufkommen von SNs ist es möglich, die Beziehungen zwischen einzelnen Menschen im Internet zu analysieren. Im Lichte dieser Entwicklung schlagen wir in dem vorliegenden Artikel einen neuen Ansatz für die unbeaufsichtigte Bewertung von Fachkompetenzen in einem SN vor, der eine strukturierte Präsentation der Fachkompetenzen eines Benutzers zusammen mit einer berechneten „Glaubwürdigkeit“ der Aussagen bietet. Wir leiten dabei die Glaubwürdigkeit von der zugrunde liegenden Graphenstruktur basierend auf dem PageRank-Algorithmus ab.

2 Theoretischer Hintergrund der Bewertung von Eigenschaften im Internet

Die grundlegende Idee von Online-Bewertungssystemen ist die Möglichkeit, dass Benutzer Entitäten mit Hilfe von Web-Applikationen bewerten können und damit Bewertungen sammeln, aggregieren und verteilen können (Resnick et al. 2000). Die aggregierten Bewertungen über eine bestimmte Entität, wie etwa eine Person oder seine oder ihre Eigenschaften, können zur Ableitung eines Wertes, wie z. B. eines Vertrauens- oder Reputationswertes, genutzt werden. Diese können wiederum an andere Parteien kommuniziert werden. Die Werte können diese Parteien bei der Entscheidung unterstützen, ob sie oder ob sie nicht in Zukunft mit bestimmten anderen Parteien zusammen arbeiten sollten (Jøsang et al. 2007).

Der Betrieb von Online-Bewertungssystemen setzt ein passendes Design der zugrunde liegenden Mechanismen voraus. Nach Chen et al. (2004) liegt eine der Hauptentscheidungen im Sammeln der Informationen. Betreiber solcher Systeme müssen festlegen, welche Benutzer welche Entitäten bewerten dürfen. Besonders die Fähigkeit des Bewertenden zur Bewertung der Entität und seine Beziehung zu der bewerteten Entität müssen betrachtet werden. Außerdem müssen absichtliche Manipulationen von einzelnen Benutzern vermieden werden (Dellarocas 2003). In ihrer State-of-the-Art-Studie von 102 Bewertungsmechanismen haben Winkelmann et al. (2009) analysiert, dass existierende Bewertungsmechanismen grundsätzlich sehr einfach auf Basis von Skalen gehalten werden. In einigen wenigen Fällen werden relative Bewertungen benutzt (Bewertung von Charakteristiken einer Entität im Vergleich zu denen einer anderen). Grundsätzlich fanden sich bei der Untersuchung keine passenden Mechanismen zur Bewertung von persönlichen Kompetenzen im Internet. Erste konzeptionelle Ideen finden sich in Winkelmann et al. (2008).

Der Begriff *Kompetenz* kann als differenziertes System von Fähigkeiten, Eigenschaften und Wissen interpretiert werden. Kompetenzen ermöglichen es Individu-

en, Teams oder auch vollständigen Organisationen, effektiv mit den Anforderungen des täglichen privaten und beruflichen Lebens umzugehen. Es gibt viele verschiedene Wege, um Kompetenzen zu klassifizieren und zu kategorisieren. Eine bekannte Unterscheidung ist die zwischen Hard Skills (Fachkompetenzen) und Soft Skills (Sozialkompetenzen), wobei sich Hard Skills, anders als Soft Skills aufgrund ihrer Unendlichkeit nur begrenzt im Vorwege antizipieren bzw. allgemeingültig klassifizieren lassen.

3 Forschungsmethode und Artefakt-Anforderungen

Die gestiegene Relevanz und Verbreitung von Bewertungs- (sowie Empfehlungs-) Systemen bildet ein neues eigenes Forschungsfeld. In diesem Kontext bieten sozio-technische Systeme, wie sie im Web 2.0-Kontext genutzt werden, neue Möglichkeiten (Vossen und Hagemann 2007). Nach Peters und Reitzenstein (2008) gibt es ein gesteigertes Bedürfnis nach Erforschung der Formen, Effekte und der Geltung von Bewertungssystemen. So haben Winkelmann et al. (2009) innerhalb ihrer aktuellen Analyse keine Mechanismen identifiziert, die explizit die Möglichkeiten der Evaluation von Kompetenzen mit der Hilfe von sozialen Graphen und somit der Beziehungen zwischen verschiedenen Benutzern im Internet bieten. Der hier vorgestellte Bewertungsmechanismus ist daher ein Beitrag zur Erforschung des zukünftigen Designs von Bewertungsmechanismen zur Kompetenzbewertung.

Das verwendete Forschungsdesign folgt dem Design-Science-Forschungsansatz (Hevner et al. 2004). Wegen der Ähnlichkeiten von Link-Strukturen zwischen Webseiten und sozialen Strukturen wurde die Forschung mit einem Blick auf den PageRank-Mechanismus und den ursprünglichen Artikel von Bomze und Gutjahr (1995) begonnen. Basierend auf diesen Erkenntnissen wurde ein neuartiger Mechanismus zur Kompetenzevaluation entworfen, implementiert und evaluiert.

Zur Bewertung des Prototyps wurden sechs grundlegende Anforderungen festgelegt. Der Bewertungsmechanismus sollte absichtliche Manipulation verhindern oder zumindest erschweren (Dellarocas 2003) und Beleidigungs- und Rachebewertungen, wie von Resnick und Zeckhauser (2001) beobachtet, unterdrücken. Als dritte Anforderung musste der Mechanismus die Bewertungsfähigkeit des Bewertenden (Winkelmann et al. 2009), als vierte Anforderung die Nähe des Bewertenden zum bewerteten Objekt beachten (Chen et al. 2004). Die Anforderungen eins bis vier stellen sicher, dass der Ansatz verlässliche, d. h. „objektive“, Ergebnisse liefert, die für ein seriöses SN zu gebrauchen sind. Wie erwähnt muss ein derartiger Mechanismus darüber hinaus eine unbegrenzte Anzahl von Kompetenzen zur Bewertung verarbeiten. Als sechste Anforderung muss der Ansatz automatisierbar sein, da der Einsatz von Moderatoren in großen SNs nicht mehr realistisch ist.

4 Konzeptionelles Model

Um diese Anforderungen zu erfüllen, wird ein neuartiger Ansatz vorgeschlagen, der auf *Bestätigungen* und nicht auf direkten Bewertungen basiert. Somit wird die Kompetenzbewertung an den Benutzer selbst delegiert. Jeder Benutzer kann ein eigenes Kompetenzportfolio mit für ihn relevanten Fähigkeiten (z. B. Programmierkenntnisse) erstellen. Diese Fähigkeiten werden durch *Erfahrungen* konkretisiert, die der Benutzer zusammen mit einem Kompetenzniveau veröffentlicht. Die Erfahrungen repräsentieren überprüfbare Situationen, mithilfe derer sich die Fachkompetenz des Benutzers auf einem bestimmten Leistungsstand einschätzen lässt (z. B. ein konkret durchgeführtes Projekt). Der Benutzer kann die Situation dabei in seinen eigenen Worten beschreiben. Zum Beispiel möchte ein Programmierer sein Java-Fachwissen anpreisen, das er u. a. aus einem aktuellen Programmierprojekt gewonnen hat. Er erstellt somit die Fähigkeit „Java-Programmierung“ und eine Erfahrung, die das Programmierprojekt beschreibt. Verbunden mit der Erfahrung spezifiziert er das Niveau „Experte“, da das Projekt sehr schwierige Java-Programmierung beinhaltete. Kollegen oder Teammitglieder können diese Erfahrung nun *bestätigen*. Die Bestätigung enthält eine direkte Referenz zu Namen und Profildatei des bestätigenden Benutzers im SN, um auch dessen Reputation verifizieren zu können. In einer kurzen Notiz kann der Bewerter noch zusätzliche Informationen über die bestätigte Erfahrung beifügen. Diese kann abgelehnt werden, um ungewünschte Kommentare über die eigenen Fähigkeiten zu verhindern und sich damit vor Rachebewertungen schützen.

Sind die Kompetenzportfolios erstellt, kann das aktuelle Kompetenzniveau von den damit verbundenen, bestätigten Einzelerfahrungen und dem jeweiligen Erfahrungsniveau durch einen gewichteten Durchschnitt berechnet werden. Der Benutzer selbst ist also nicht fähig, das Niveau festzulegen. Er kann vielmehr nur „Vorschläge“ für das Niveau jeder Erfahrung machen und andere Menschen können diese Vorschläge gut genug finden, um sie mit ihrem eigenen Namen zu bestätigen. In diesem Artikel beschränken wir unsere Erörterungen auf die drei Erfahrungslevel Anfänger, Fortgeschrittener und Experte. Sei $C = C_{\text{Anf}} \cup C_{\text{For}} \cup C_{\text{Exp}}$ die Menge von bestätigten Erfahrungen. Das aktuelle Kompetenzniveau eines Benutzers ist dann definiert als $l = (|C_{\text{Anf}}| + 2 |C_{\text{For}}| + 3 |C_{\text{Exp}}|) / |C|$. Das ergibt ein Kompetenzniveau $l \in [1;3]$, welches folgendermaßen interpretiert werden kann. Wenn $l = 1$, dann ist der Benutzer absoluter Anfänger. Das Level $l = 2$ zeigt einen fortgeschrittenen Benutzer an, und $l = 3$ besagt, dass der Benutzer ein Experte ist. Zwischenwerte sind ebenfalls möglich. Zum Beispiel kann ein Benutzer mit einem Java-Niveau von $l = 2.4$ als fortgeschrittener Programmierer mit ordentlichem Expertenwissen interpretiert werden, der auf halbem Wege zum Java-Experten ist.

Während dieser Ansatz eine Bewertung des Kompetenzniveaus des Benutzers ermöglicht, ist es jedoch unklar, wie glaubhaft die Darstellung ist. Um die Glaubhaftigkeit der Behauptung zu schätzen, wurde Googles PageRank-Algorithmus (Page et al. 1999) adaptiert, welcher die Wichtigkeit von Webseiten basierend auf

der rekursiven These misst (Langville und Meyer 2006, S. 28): *Eine Webseite ist wichtig, wenn sie von anderen wichtigen Webseiten verlinkt wird.*

Das Internet kann als gerichteter Graph bestehend aus Webseiten (Knoten) und Links zwischen ihnen (Kanten) gesehen werden. Eine PageRank-Berechnung kann dann als Fixpunktproblem für Markov-Ketten ausgedrückt werden. Der resultierende PageRank-Vektor ist die Wahrscheinlichkeitsverteilung über die Webseiten, welcher die relative Wichtigkeit jeder Seite enthält und somit eine Rangfolge der Webseiten enthält.

Für die PageRank-Berechnung wird der Graph durch seine Adjazenz-Matrix $A = [a_{ij}]$ repräsentiert, wobei a_{ij} gleich 1 ist, wenn die Seite i einen Link zu Seite j enthält, andernfalls 0. Als Beispiel kann der Graph in Abb. 1 herangezogen werden. Da z. B. Seite 4 auf Seite 2 verlinkt, ist $a_{42} = 1$. Wenn A Zeilen-normalisiert ist, d. h., die Summe jeder Zeile von A normalisiert ist zu 1 oder 0, dann ergibt sich die sub-stochastische Matrix H , die *Hyperlink-Matrix*. Die Hyperlink-Matrix ist eine dünn besetzte Matrix und ist die Basis für die PageRank-Berechnung. Da sie dünn besetzt ist, kann sie effizient bearbeitet werden, selbst wenn sie sehr groß wird (wie es bei Google der Fall ist).

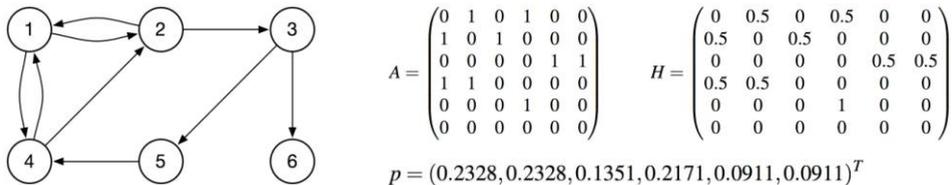


Abbildung 1: Beispielgraph mit Adjazenz- und Hyperlink-Matrix

Für den endgültigen PageRank werden zwei zusätzliche Anpassungen an H vollzogen, welche in der sog. Google-Matrix G resultieren. Zunächst werden alle Elemente einer Zeile, deren Summe 0 ist, mit dem Wert $1/n$ gefüllt, wobei n die Anzahl von Knoten im Graph ist (somit ist die Zeilensumme nun 1). Dann wird ein Dämpfungsfaktor α angewandt, um das Ergebnis zu stabilisieren. Der PageRank-Vektor p kann nun basierend auf G als $p^T = p^T G$ ausgedrückt werden. Für die Berechnung wird die Formel meist rekursiv formuliert als $p^{(k+1)T} = p^{(k)T} G$ und iteriert bis die Veränderung kleiner als ein Schwellenwert ϵ ist. Der sich ergebene PageRank für den Beispielgraphen bei der Benutzung von $\alpha = 0.9$ ist ebenfalls in Abb. 1 zu sehen.

Für die Bewertung von Kompetenzen formulieren wir die rekursive These wie folgt: *Die Behauptung einer Person, dass sie eine bestimmte Fähigkeit auf einem gegebenen Niveau besitzt, ist glaubhaft, wenn andere Personen, die glaubhaft für dieselbe Fähigkeit sind, dies bestätigen.*

Diese Aussage führt zu einem gerichteten bipartiten Graph für jede Fähigkeit mit Benutzer- und Erfahrungsknoten (vgl. Abb. 2). Ein Benutzerknoten ist die

Repräsentation eines Benutzers. Ein Erfahrungsknoten ist die Repräsentation seiner Erfahrung auf einem bestimmten Niveau. Eine Kante von einem Erfahrungsknoten zu einem Benutzerknoten ordnet der Erfahrung ihren Inhaber zu. Zum Beispiel zeigt die Kante von Erfahrungsknoten $E1$ zu Benutzerknoten A , dass $E1$ zu A gehört. Eine Kante von einem Benutzerknoten zu einem Erfahrungsknoten repräsentiert eine Bestätigung der Erfahrung durch den Benutzer. Zum Beispiel stellt die Kante von Benutzerknoten B zu dem Erfahrungsknoten $E1$ von A eine Bestätigung von A s Erfahrung durch B dar. Um die gleiche Graphenstruktur wie beim PageRank zu erhalten, ist es möglich das Problem zu vereinfachen (vgl. Abb. 2 b). Dafür werden alle Erfahrungsknoten für einen Benutzer nur implizit als Teil des Benutzerknotens modelliert. Der resultierende Graph enthält nur Benutzerknoten und Kanten $A \rightarrow B$, die A s Bestätigung einer oder mehrerer von B s Erfahrungen repräsentieren. Nach dieser Vereinfachung hat das Problem der Glaubwürdigkeitsbewertung die gleiche Struktur wie die PageRank-Berechnung. Der Ansatz wird nachfolgend als *SkillRank* bezeichnet. Der PageRank – und somit auch der SkillRank – sind Varianten der Eigenvektorzentralität.

Die Ergebnisse unserer ersten Berechnungen zeigen, dass sich grundsätzlich die erwarteten Ergebnisse ergeben. Fasst man den Graphen aus Abb. 1 als Fähigkeitsgraph auf (analog zur Abb. 2 b), so bestätigt der SkillRank-Vektor p z. B. die Intuition, dass die Benutzer (Knoten) 1, 2 und 4 die glaubwürdigsten sind, da sie die meisten Bestätigungen haben.

Die oben erwähnten zwei Anpassungen an die Hyperlink-Matrix H basieren auf folgenden zwei Annahmen (Langville und Meyer 2006, S. 37):

- Alle *hängenden Knoten*, d. h. Knoten, die keine ausgehenden Kanten haben (wie z. B. Knoten 6 in Abb. 1), werden behandelt als wären sie mit allen Knoten im Graph verbunden.
- Der *Dämpfungsfaktor* α wird benutzt, um das Ergebnis zu stabilisieren, indem der Einfluss der Graphenstruktur durch eine zufällige Komponente reduziert wird.

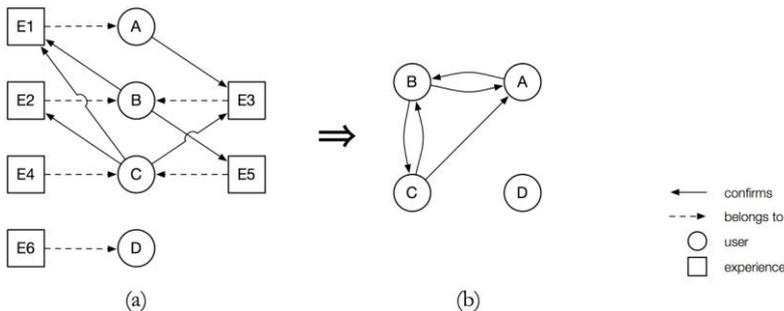


Abbildung 2: Beispiel Fähigkeitsgraph (a) und die vereinfachte Version (b)

Die erste Annahme ist für das vorliegende Problem unkritisch, da sie nur dem technischen Zweck der Elimination von *Rangsenken* dient, d. h. Knoten, die einen unberechtigterweise hohen Rang anhäufen (Langville und Meyer 2006, S. 37). Bildlich gesprochen wird der angesammelte Rang durch die Maßnahme in der fairsten Art und Weise abgeschöpft und umverteilt.

Die zweite Annahme ist in diesem Kontext problematischer. Die Idee hinter dem Dämpfungsfaktor ist ein „gelangweilter Nutzer“. Mit der Wahrscheinlichkeit α wird der Benutzer den Links auf der Webseite folgen und mit der Wahrscheinlichkeit $1 - \alpha$ wird er manuell eine neue URL in die Adresszeile seines Browsers eingeben. Dies ist relativ intuitiv für die PageRank-Berechnung, aber im Falle des SkillRank heißt das, dass ein Anteil von $1 - \alpha$ der Glaubwürdigkeit per Zufall berechnet wird, was nicht gut zu begründen ist. Somit wäre es die offensichtliche Lösung, $\alpha = 1$ zu setzen. Jedoch hat der Dämpfungsfaktor auch den Zweck, die Primitivität der Markov-Kette zu sichern, welche eine notwendige Bedingung für eine schnelle Konvergenz zu einem wohldefinierten Ergebnis ist. Im Falle des Internets zeigt die Erfahrung, dass der Graph für alle praktischen Zwecke als primitiv angesehen werden kann (Langville und Meyer 2006, S. 37). Im Falle von Fähigkeitsgraphen gibt es jedoch häufig Schleifen, die eine Primitivität verhindern. Auch vergrößert die Wahl von $\alpha \approx 1$ die Anzahl von Iterationen, die notwendig sind, um eine Lösung zu erhalten, und die Sensitivität der Lösung auf kleine Veränderungen im Graph (Langville und Meyer 2006, S. 57-62). Somit ist das Problem eine Abwägung zwischen der Berücksichtigung der Graphenstruktur und schneller, garantierter Konvergenz, also zwischen einer „richtigen“ Lösung und einer „stabilen“ Lösung. Daher schlagen wir einen Kompromiss von $0.9 \leq \alpha < 1$ vor, der ausreichend gute Ränge für alle Fälle zu liefern scheint.

Ein drittes Problem ergibt sich, wenn es keine Bestätigung für eine Fähigkeit eines Benutzers gibt. Dies ist der Fall für Knoten D in Abb. 2. Offensichtlich ist ein solcher Knoten nicht mit dem restlichen Graphen verbunden. Beim PageRank ist dies nicht möglich, da alle Knoten durch striktes Folgen von Hyperlinks (Crawlen) gefunden werden. Beim Fähigkeitsgraphen werden alle Benutzer mit einbezogen, die diese Eigenschaft haben, inklusive unbestätigten Behauptungen. Die sich ergebenden unverbundenen Knoten können dennoch nicht in die SkillRank-Berechnung einbezogen werden und werden somit mit einem SkillRank-Wert von 0 versehen. Dies ist auch intuitiv sinnvoll, da die vorliegende Behauptung offensichtlich nicht innerhalb des SN bestätigt werden kann und somit nicht glaubhaft ist.

5 Implementierung des konzeptionellen Modells

Entsprechend den oben dargelegten Betrachtungen wurde ein SkillRank-Prototyp basierend auf OpenSocial (OSo)¹ implementiert (Häsel und Rieke 2009). OSo ist

¹ <http://www.opensocial.org>

eine API für SN-Webseiten, die das Schreiben von kleinen portablen Programmen, sog. *Gadgets*, erlaubt. Der Hauptgrund für die Wahl von OSo als Basis für das Hard-Skill-Bewertungsgadget ist die potentielle Portabilität, die es theoretisch erlaubt, dass die Anwendung in jedem SN eingebunden wird, das OSo unterstützt.

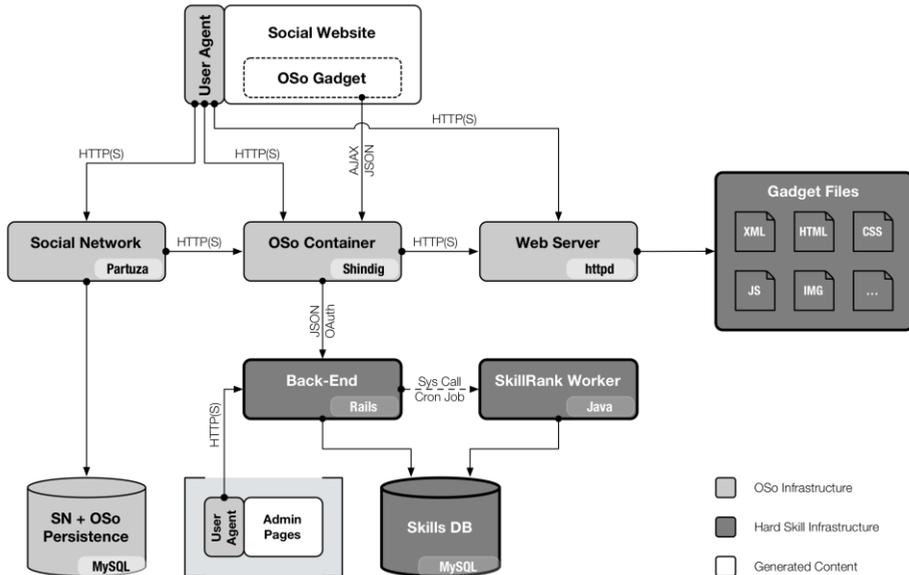


Abbildung 3: Architektur der Referenzimplementierung

Das Front-End wird von einem Back-End-Server basierend auf Ruby on Rails² unterstützt, der sich um Datenspeicherung und komplexere Berechnungen kümmert (vgl. Abb. 3 für einen Überblick über die Architektur). Die SkillRank-Implementierung ist ein nebenläufiges Java-Programm, basierend auf der Colt High-Performance Computing Library³. Es benutzt den iterativen Algorithmus von Haveliwala (1999), um die SkillRank-Werte für alle Benutzer und Fähigkeiten effizient zu berechnen. Selbst große Graphen können in kurzer Zeit berechnet werden. So kann zum Beispiel eine sehr populäre Fähigkeit mit 100.000 Benutzern und ca. 1,24 Mio. Bestätigungen in etwa 90 Sekunden berechnet werden.⁴ Ein realistischer Graph mit 10.000 Benutzern und etwa 200.000 Bestätigungen wird in etwas mehr als einer Sekunde berechnet.

² <http://rubyonrails.org>

³ <http://acs.lbl.gov/~hoschek/colt>

⁴ Die angegebenen Zeiten enthalten nicht die Zeit für das Laden der Daten aus der Datenbank (ca. 30 Sek. für 1,24 Mio. Bestätigungen). Die Messungen wurden auf einem 2 × 2.8 GHz Vier-Kern-Xeon-Computer mit 8 GB RAM, Java 1.6.0_13 und Mac OS X 10.5.7 ausgeführt. Wir haben $\alpha = 0.85$ zugrunde gelegt. Für $\alpha = 0.95$ ergeben sich geringfügig abweichende Werte (z. B. 95 Sek. für die 1,24 Mio. Bestätigungen).

Das Gadget erlaubt es, dem Benutzer eine individuelle Liste von Hard Skills zu erstellen, die als Tabelle oder *Skill Cloud*, d. h. ähnlich zu einer Tag Cloud, dargestellt wird (vgl. Screenshots in Abb. 4). Die Größe der Eigenschaften in der Skill Cloud repräsentiert das Niveau des Benutzers für die Eigenschaft, während die Intensität der Farbe anzeigt, wie glaubwürdig der Eintrag laut der SkillRank-Berechnung ist. So gehört zum Beispiel die Skill Cloud in Abb. 4 zu einem Benutzer, der von sich behauptet, ein Experte sowohl in „Microsoft Office 2007“ als auch in „SAP R/3“ zu sein. SkillRank schlägt jedoch vor, dass die erste Behauptung wenig glaubwürdig ist. Auf der anderen Seite ist die Behauptung, dass er fortgeschritten in „Java“ ist, sehr glaubwürdig. Die Skill Cloud ist ein wichtiges Werkzeug, um einen schnellen Überblick über die Eigenschaften einer Person zu bekommen. Die Listenansicht stellt eine andere Perspektive auf die Eigenschaften eines Benutzers dar, wobei hier zusätzliche Informationen wie das Datum der letzten Bestätigung und die Option zum Veröffentlichen oder Verstecken der Eigenschaft bereitgestellt werden. So wird zum Beispiel die Eigenschaft „Katamaran bauen“ nicht in der Skill Cloud und im öffentlichen Benutzerprofil angezeigt.

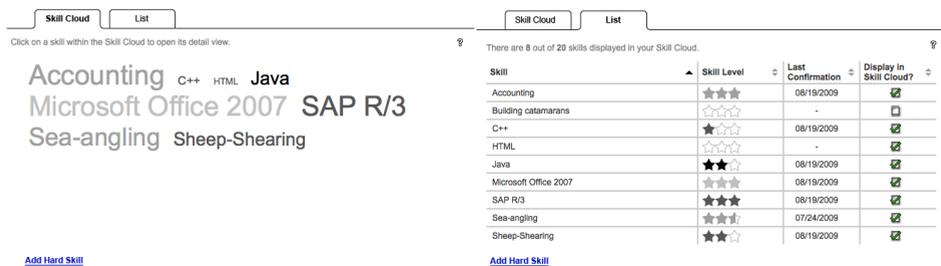


Abbildung 4: Screenshots einer beispielhaften Skill Cloud (links) und der korrespondierenden Listenansicht (rechts)⁵

6 Grenzen

Trotz positiver Ergebnisse erster Feldversuche mit dem Gadget innerhalb des sozialen Netzwerks eines Praxispartners, gibt es ein paar grundlegende Grenzen. Zunächst einmal produziert der SkillRank-Ansatz nur eine *Rangfolge* von Glaubwürdigkeiten und keine *Punktzahl*. Die Werte erlauben also nur den Vergleich von Benutzern innerhalb einer bestimmten Gruppe bezüglich ihrer Glaubwürdigkeit. In einer Gruppe von sehr glaubwürdigen Personen würde somit ein eigentlich glaubwürdiger Benutzer nur einen relativ geringen Rang erhalten, wohingegen sein Rang in einer zweiten Gruppe von sehr unglaubwürdigen Personen sehr gut wäre. Eine Punktzahl könnte nicht nur der Glaubwürdigkeit eines Benut-

⁵ Die Screenshots wurden auf Wunsch des Praxispartners optisch leicht verfremdet; schematisch sind sie jedoch unverändert.

zers eine absolute Bedeutung geben, sondern auch Vergleiche über Gruppen hinaus ermöglichen.

Eine zweite Grenze des aktuellen Ansatzes ist, dass die Glaubwürdigkeit nicht für das Fähigkeitsniveau sondern nur für die Fähigkeit selbst berechnet wird. Das Niveau und die Glaubwürdigkeit sind aber eigentlich zwei orthogonale Dimensionen. Je mehr Erfahrungen auf höchstem Niveau ein Benutzer in seinem Profil hat, desto höher wird sein Fähigkeitsniveau sein. Je mehr Bestätigungen er hat, desto besser wird sein Glaubwürdigkeitsrang sein. Wenn der Benutzer sorgfältig sein Fähigkeitsprofil plant, kann er eine Situation erreichen, in der er sehr viel Glaubwürdigkeit durch einige wenige, sehr glaubwürdige Erfahrungen auf niedrigem Niveau erhält und sein Fähigkeitsniveau durch zahlreiche ungläubwürdige Einträge auf höchstem Niveau aufwertet. Der Prototyp fängt dies teilweise dadurch ab, dass für die Berechnung des Fähigkeitsniveaus nur bestätigte Erfahrungen berücksichtigt werden. Jedoch müsste der SkillRank-Ansatz grundsätzlich geändert werden, um dieses Betrugspotenzial vollständig zu eliminieren. Die „offensichtliche“ Möglichkeit, diesen Nachteil zu umgehen, wäre, nur die Bestätigungen von Nutzern mit dem gleichen Fähigkeitslevel in die Bewertung einzubeziehen. Dieses führt jedoch bei genauerer Betrachtung dazu, dass gerade bei seltenen Skills, bei denen der zu Bewertende ggf. einziger Experte in seinem Netzwerk ist, keine Glaubwürdigkeit übertragen werden könnte.

Drittens funktionieren alle bekannten Angriffe auf PageRank auch für den SkillRank. Vor allem das Problem des sog. Link Farming kann in ein „Confirmation Farming“ übersetzt werden. Eine Gruppe von Personen würde dazu z. B. intensiv ihre eigenen Erfahrungen bestätigen, um den SkillRank der Mitglieder künstlich zu erhöhen. Damit lässt sich anders als die in Kapitel 3 aufgestellten übrigen fünf Anforderungs-Kriterien eine Verhinderung der Manipulation mit dem Mechanismus nicht erfüllen. Allerdings ist die hier angeführte Möglichkeit der Manipulation theoretischer Natur, da hierzu einerseits ein höherer Aufwand in sozialen Netzen mit persönlichen Verbindungen und Real-Namen notwendig ist und diese zugleich auch in der Historie der jeweiligen Nutzerbestätigungen ersichtlich ist.

7 Fazit und zukünftige Forschung

In diesem Artikel wurde ein neuer Ansatz zur Online-Bewertung von Fachkompetenzen basierend auf Bestätigungen und dem SkillRank-Glaubwürdigkeitsranking präsentiert. Der Ansatz erlaubt eine vollständig unbewachte Bewertung von Kompetenzen in einem online SN, inklusive einer Aussage über das angebliche Fähigkeitsniveau einer Person sowie die Glaubwürdigkeit für diese Behauptung. Aufgrund der Seitenbegrenzung wurde auf die Beschreibung der Methode fokussiert und Aspekte wie automatische Identifikation von identischen Eigenschaften, zusätzliche Anreize für die Benutzer zur Nutzung des Gadgets etc. ausgeblendet.

Zusammenfassend ist nach ersten Praxiserfahrungen in einem großen SN zu sagen, dass der Ansatz konzeptuell gut geeignet ist und aus theoretischer und praktischer Perspektive funktioniert. Als nächsten Schritt sind umfangreiche empirische Daten zu sammeln, um die Grenzen des Ansatzes zu identifizieren und zu überwinden. Im Besonderen sind folgende Forschungsfragen anzusprechen:

- Welche zusätzlichen Ergebnisse können abgeleitet werden, wenn nicht nur der vereinfachte Graph sondern die detaillierte Situation verwendet wird? Dies erfordert jedoch ein Umdenken bei der Berechnung der Glaubwürdigkeitsränge. Es könnte zu einer Anpassung des PageRank-Algorithmus führen oder aber auch einen vollständig neuen Ansatz erfordern.
- Wie können das Altern von Erfahrungen und die unterschiedlichen „Halbwertszeiten“ für verschiedene Fähigkeiten beachtet werden? Einige Fähigkeiten, wie Wissen über sich rasch entwickelnde Technologien, sind sicherlich schneller veraltet als grundsätzliche Kompetenzen wie Rechtschreibung
- Wie können die Glaubwürdigkeitsinformationen für mehrere Fähigkeiten in einen Glaubwürdigkeitswert für eine Person aggregiert werden? Dieses korreliert damit, wie eine Punktzahl statt eines Rangs berechnet werden kann.

Literatur

- Bolton G, Katok E, Ockenfels, A (2004) How Effective are Online Reputation Mechanisms? An Experimental Investigation. *Mgmt Sc.* 50(11):1587-1602.
- Bomze I, Gutjahr W (1995) Estimating qualifications in a self-evaluating group. *Quality and Quantity* 29(3): 241–250.
- Chen K-Y, Hogg T, Wozny N (2004) Experimental study of market reputation mechanisms. In: *Proc. of the 5th ACM Conf. on E-Commerce*, ACM, NY, USA.
- Cheung CMY, Luo C, Sia CL, Chen HP (2007) How do People Evaluate Electronic Word-of-Mouth? Informational and Normative Based Determinants of Perceived Credibility of Online Consumer Recommendations in China, Auckland, New Zealand.
- Dellarocas C (2003) The Digitization of Word of Mouth: Promise and Challenges of Online Feedback Mechanisms. *Mgmt Sc.* 49(10):1407-1424.
- Efimova L (2004) Discovering the Iceberg of Knowledge Work: A Weblog Case. In: *Proc. of the Fifth Europ. Conf. of Organizational Knowledge, Learning and Capabilities*, Innsbruck, Austria.
- Häsel M, Rieke K (2009) Open Social. *Informatik Spektrum* 32(3):250-254.
- Haveliwala, T. H. (1999). Efficient computation of pagerank. Technical Report 1999-31, Stanford InfoLab.

- Hevner AR, March ST, Park J, Ram S (2004) Design Science in Information Systems Research. *MIS Quarterly* 28(1):75-105.
- Jøsang A, Roslan I, Boyd C (2007). A Survey of Trust and Reputation Systems for Online Service Provision. *Decision Support Systems* 43(2):618-644.
- Kelleher T, Miller BM (2006). Organizational Blogs and the Human Voice: Relational Strategies and Relational Outcomes. *J. of Computer-Mediated Comm.* 11(2):395-414.
- Langville AN, Meyer CD (2006). *Google's PageRank and Beyond: The Science of Search Engine Rankings*. Princeton University Press, Princeton, NJ, USA.
- Page L, Brin S, Motwani R, Winograd T (1999). The PageRank citation ranking: Bringing order to the web. Technical Report 1999-66, Stanford InfoLab.
- Peters R, Reitzenstein I (2008) Reputationssysteme im eCommerce - Funktionsweise, Anwendung und Nutzenpotenziale. *HMD* 45:43-50.
- Resnick P, Kuwabara K, Zeckhauser R, Friedman E (2000) Reputation systems. *Comm. of the ACM* 43(12):45-48.
- Resnick P, Zeckhauser R (2001) Trust Among Strangers in Internet Transactions: Empirical Analysis of eBay's Reputation System. Working Paper for the NBER workshop on empirical studies of electronic commerce.
- Vossen G, Hagemann S (2007) *Unleashing Web 2.0*. Morgan Kaufmann, San Francisco, CA.
- Winkelmann A, Herwig S, Pöppelbuß J, Tiebe D, Becker J (2009) Discussion of Functional Design Options for Online Rating Systems: A State-of-the-Art Analysis. In: *Proc. of the Europ. Conf. on IS (ECIS)*. Verona, Italy.
- Winkelmann A, Vossen G, Becker J, Haselmann T, Herwig S, Pöppelbuß J (2008) Bewertungsmechanismen zur beruflichen Weiterqualifizierung in sozialen Web 2.0-Netzwerken. *LNI*, 134(2):955-961.