

# SWING: Eine Suchmaschine mit Datenbankanschluß

*Andreas Heuer   Gunnar Weber*

Lehrstuhl Datenbank- und Informationssysteme  
Fachbereich Informatik, Universität Rostock  
Postadresse: D-18051 Rostock  
Tel.: 0381/498-3401, -3402 und -3405  
Fax: 0381/498-3443  
E-Mail: swing@informatik.uni-rostock.de

## **Zusammenfassung**

SWING ist der Anfrage- und Suchdienst des Landesinformationssystems MV-Info, das die Internet-Informationsangebote Mecklenburg-Vorpommerns integriert und klassifiziert. SWING umfaßt neben klassischen Suchtechniken auch diverse neue Merkmale wie Konsistenzchecks, Profildienste und insbesondere das Ausnutzen von Strukturen in Informationen, die aus Datenbanken stammen. In diesem Beitrag wird ein Überblick über den aktuellen Entwicklungsstand von SWING gegeben und insbesondere die Art der Datenbankanbindung erläutert.

## **1 Einführung**

Das Projekt SWING (Suchdienst für WWW-basierte Informationssysteme der nächsten Generation) ist Teil des Landesinformationssystems Mecklenburg-Vorpommern (MV-Info), das verschiedene Unternehmen und Forschungseinrichtungen des Landes entwickeln und betreiben. MV-Info bietet eine einheitliche Schnittstelle auf Informationen, die im Internet über Firmen, Institutionen und Personen des Landes angeboten werden. Ziel des u.a. auf der CeBIT 99 vorgestellten Teilprojekts SWING ist es, diese Informationen strukturierter zu verwalten und insbesondere schneller auffindbar zu machen. Der Kern des Projekts ist die Entwicklung einer neuartigen Suchmaschine, die Datenbanktechniken (die in vielen firmeninternen Informationssystemen seit Jahren angewendet werden) und die Suche in elektronisch bereitgestellten Texten intelligent miteinander verbindet. SWING hat gegenüber den weltweit im WWW (World Wide Web) verfügbaren internationalen Suchmaschinen diverse neue Merkmale:

- Beschränkung der durchsuchten Informationen auf die Region Mecklenburg-Vorpommern.
- Verteilte, parallele (und damit weitaus schnellere) Suche nach Informationen auf verschiedenen Rechnern im Land (Gatherer). Danach Zusammenführung der Teilergebnisse (Broker).
- Zugriff auf strukturierte Datenbanken: im Gegensatz zu allen anderen Suchmaschinen werden nicht nur Texte, sondern auch Datenbanken durchsucht. Letztere werden in sogenannte "dynamische WWW-Seiten" eingebunden, die bisher von jeglicher Suche ausgeschlossen waren.
- Spezielle Meta-Tags wie *official-homepage* führen zu einer höheren Ergebniswichtung bei der Bewertung der zu einem Suchbegriff gefundenen Informationen. Bei der Generierung dieser Tags wird der Nutzer durch ein eingebautes MetaTool unterstützt.

- Profildienste: durch die Kenntnis von Nutzerspezifika können dem Anwender bestimmte Suchumgebungen bzw. zusätzliche Dienste bereitgestellt werden. Dazu zählen das Abonnieren von Anfragen durch den Nutzer und ein URL-Reminder, der den Anwender über Veränderungen in wichtigen WWW-Dokumenten informiert.
- Benutzerunterstützung durch Ausnutzung von linguistischem Wissen: ein Wörterbuch stellt alternative Begriffe wie Synonyme, allgemeinere und speziellere Begriffe bereit.
- Überprüfung aller durchsuchten Informationen durch regelmäßige Konsistenzchecks.

In diesem Beitrag sollen insbesondere neuere Entwicklungen im Projekt SWING II vorgestellt werden, die seit 1998 konzipiert und umgesetzt wurden. Beispielsweise unterstützt ein MetaTool die Definition sogenannter Meta-Tags, die WWW-Seiten so beschreiben, daß sie von SWING und anderen Suchmaschinen (wie Altavista) besser gefunden werden. Ein weiteres Werkzeug ermöglicht die Einbindung mehrerer, autonom bei verschiedenen Anbietern gehaltener heterogener Datenbanken in die Suche. Die Profildienste der SWING-Suchmaschine zur Benachrichtigung über Neuerungen in bestimmten Bereichen des Landesinformationssystems werden ebenfalls vorgestellt.

Die SWING-Suchmaschine ist über die Internet-Adresse <http://swing.m-v.de> oder <http://swing.informatik.uni-rostock.de> für jeden Internet-Nutzer zugänglich. Für nähere Informationen zu technischen Details sei auf [LDHM97] verwiesen, eine Kurzfassung wurde auf einem nationalen Workshop als [DLHM97] veröffentlicht. Auf den ersten IuK-Tagen des Landes-Mecklenburg-Vorpommern wurde die Funktionalität der ersten Version der Suchmaschine (SWING I) vorgestellt [HMDL97]. Die dort bereits beschriebenen Features werden hier nicht wiederholt. Für weitere Informationen zu SWING I sei daher auf die Originalartikel verwiesen.

## 2 State of the Art: Datenbankeinbindung in Suchmaschinen

Es gibt mehrere prinzipielle Möglichkeiten der Integration von Datenbanken in Suchmaschinen. Diese unterscheiden sich in der Art und Weise, wie weitgehend der Zugriff auf die lokale Datenbank ermöglicht wird. Grob kann man zwischen zwei Arten von Datenbankanbietern unterscheiden:

- *Kooperative Datenbankanbieter* ermöglichen den strukturierten Zugriff auf den Datenbankinhalt (oder spezielle Sichten) über JDBC oder ähnliche Mechanismen. In diesem Fall kann die volle Funktionalität einer Anfragesprache auch in der Datenbankanbindung ausgenutzt werden.
- *Nicht-kooperative Datenbankanbieter* ermöglichen nur den Zugriff über ein Anfrageformular, das im WWW über Parameter versorgt werden kann. Das Schema der Datenbank und Anfragefunktionen, die darüberhinaus nutzbar wären, sind nicht bekannt bzw. können nicht an die darunterliegende Datenbank übergeben werden.

SWING II unterstützt den Zugriff auf Datenbanken von kooperativen und nicht-kooperativen Datenbankanbietern. Der Schwerpunkt dieses Beitrags beschreibt weiter unten den kooperativen Fall.

Im folgenden werden zwei weitere Suchmaschinen vorgestellt, die Datenbanken integrieren: die Suchmaschine des Microsoft Site Servers [Kra99] sowie die von der Universität Aalborg entwickelte Datenbanksuchmaschine Jungle [BBD99].

---

<sup>1</sup>Bei beiden Suchmaschinen wird davon ausgegangen, daß die Anbieter der Datenbanken einen strukturierten Zugriff auf die Inhalte gestatten.

## 2.1 Microsoft Site Server

Die Suchmaschine des Site Servers basiert auf 2 Diensten: dem Gatherer-Dienst und dem Search-Dienst. Der Gatherer-Dienst sammelt Inhalte, extrahiert Informationen, erstellt den Index und verbreitet ihn. Der Search-Dienst ermöglicht dem Nutzer das Durchsuchen der generierten Indizes.

Beim Site Server wird ein Index als Katalog bezeichnet. Es existieren verschiedene Katalogtypen, abhängig von der Art, wie die Informationen gesammelt werden. Zur Einbindung von Datenbanken dient der Datenbankkatalog. Dieser ist so aufgebaut, daß Informationen aus Datensätzen in einer Tabelle einer ODBC-Datenquelle gesammelt werden können. Pro Datenbank, die eingebunden werden soll, wird ein Katalog benötigt. Die Anzahl der Kataloge pro Suchserver ist aber auf 32 beschränkt. Der Site Server indexiert standardmäßig eine Tabelle pro einzubindender Datenbank. Diese Tabelle muß eine Spalte enthalten, die als Primärschlüssel dient. Weitere Tabellen können per Hand eingebunden werden, sie müssen aber mit der Haupttabelle in Beziehung stehen.

Der Nutzer kann im Katalog nach Informationen in der Datenbank suchen. Alle übereinstimmenden Sucheinträge werden auf einer Suchergebnisseite präsentiert. Wenn der Nutzer auf einen Link klickt, wird von dieser Seite aus eine Seite mit Informationen aus dem Datensatz in der Datenbank angezeigt.

Für die Einbindung von Datenbanken werden verschiedene Active Server Pages (ASP) benötigt, die von einem Assistenten erstellt werden. Dieser Assistent funktioniert jedoch nur mit einzelnen Tabellen in Microsoft SQL Server- und Microsoft Access-Datenbanken. Um Daten aus anderen Tabellen einzuschließen sowie für andere ODBC-Datenbanken müssen diese ASPs selbst erstellt werden.

Bei der Suche nach Informationen muß der Nutzer zunächst spezifizieren, in welchen Katalogen er suchen möchte. Somit werden die vorhandenen Datenbankkataloge nicht automatisch mitdurchsucht. Innerhalb eines Katalogs hat der Nutzer vielfältige Suchmöglichkeiten. Er kann eine einfache Stichwortsuche starten bzw. die Suche auf eine Katalogspalte einschränken. Bei der eingeschränkten Suche muß der Nutzer natürlich wissen, wie die entsprechenden Katalogspalten benannt sind. Die Anfragefunktionalität ist für alle Katalogtypen gleich, d.h. auch für Datenbankkataloge werden attributierte Anfragen unterstützt. Der Site Server bietet sogar die Möglichkeit, per SQL auf die Suchdaten zuzugreifen.

## 2.2 Jungle

Die Jungle Datenbanksuchmaschine nutzt JDBC-Verbindungen zu den entfernten Datenbanken, die integriert werden sollen. Jungle extrahiert und indexiert Datenbankinhalte sowie Metadaten und bildet somit eine Sammlung von Datenbankinformationen. Diese Informationen werden zur Berechnung und zur Optimierung von Anfragen in der AQUA-Anfragesprache genutzt. AQUA ist eine natürliche und intuitive Datenbankanfragesprache, die dem Nutzer die Suche nach Informationen gestattet, ohne das er weiß, wie diese strukturiert sind. Die Datenbank wird als eine Stufenhierarchie angesehen, von der Datenbank, zu Tabellen innerhalb der Datenbank, zu Spalten innerhalb einer Tabelle, bis hin zu individuellen Attributwerten innerhalb einer Spalte. AQUA unterstützt drei grundlegende Anfragearten: einstufige Anfragen, vertikale Anfragen, die aus einer Menge von einstufigen Anfragen zusammengesetzt werden, sowie horizontale Anfragen, die verwandte Informationen auf einer Stufe verbinden.

Die einstufigen Anfragen sind innerhalb jeder Stufe möglich. Vertikale Anfragen gestatten die Kombination der Suche in verschiedenen Stufen, wobei jede Stufe den Suchraum der darunterliegenden Stufen einschränkt. Bei horizontalen Anfragen kann das Schlüsselwort AND genutzt werden, um Informationen auf derselben Stufe zwischen Tabellen zu verbinden. AQUA hat die Fähigkeit, automatisch verwandte Informationen zu verbinden. Die Beziehungen werden aus den importierten und exportierten Schlüsselinformationen der darunterliegenden Datenbanken abgeleitet<sup>2</sup>.

Jungle besteht hauptsächlich aus zwei Untersystemen:

---

<sup>2</sup>Konzeptionell bilden Schlüssel die grundlegende Menge von Beziehungen zwischen verschiedenen Tabellen einer Datenbank.

- dem *Roboter*, der jede entfernte Datenbank besucht und die Datenbankinhalte ermittelt sowie die Indizes aufbaut, und
- der AQUA-Anfragebearbeitungsmaschine.

Jungle benötigt den URL jedes Datenbank-JDBC-Servers, einen Login-Namen sowie das Passwort für jede Datenbank. Der Jungle-Roboter besucht dann die Datenbank und unternimmt dann die folgenden Schritte zur Extraktion und Indexierung der Informationen, die gefunden werden:

- Der Schemagraber ermittelt das Schema: Tabellennamen, Spaltennamen, zusätzliche Tabellen- bzw. Spaltenbeschreibungen wie Synonyme, Spaltentypen, und die Namen der Domänen. Diese Meta-Informationen werden dann indexiert.
- Mit Hilfe der Meta-Daten werden SQL-Anfragen generiert und über JDBC ausgeführt, um die Werte in den textuellen und numerischen Spalten jeder Tabelle zu extrahieren. Die ermittelten Daten werden ebenfalls indexiert. Dieser Index ist ziemlich groß und dient dazu, daß bei Anfragen auf Werte-Ebene schnell identifiziert werden kann, welche Tupel relevante Informationen enthalten.
- Zum Schluß werden die importierten/exportierten Schlüsselinformationen (wenn vorhanden) abgefragt.

Der komplizierteste Teil von Jungle ist die AQUA-Anfragebearbeitungsmaschine. Eine AQUA-Anfrage ist eine Suche nach Informationen in den eingebundenen Datenbanken. Einige der Anfragen können direkt aus den Informationen der Jungle-Datenbank beantwortet werden (Anfragen an Metadaten). Im Allgemeinen aber wird die AQUA-Anfrage in eine Menge von SQL-Anfragen umgewandelt. Die Generierung dieser Anfragen geschieht unter Ausnutzung der Metadaten und Daten-Indizes. Die Anfragen werden dann von den entfernten Datenbanksystemen beantwortet, das Ergebnis wird von Jungle gesammelt und formatiert.

Die Jungle-Suchmaschine hat aus Anbietersicht einige Nachteile: Der Datenbankadministrator kann nicht entscheiden, welche Daten nach außen gegeben werden, und der Zugang zur Datenbank muß von außen möglich sein. Ein weiteres Problem stellt die Belastung der eingebunden Datenbanken dar, wenn sehr allgemeine Anfragen an Jungle gestellt werden. In diesem Fall müssen die entfernten Datenbanken eine Vielzahl von SQL-Anfragen verarbeiten, damit eine AQUA-Anfrage beantwortet werden kann.

## 3 Meta-Daten und MetaTool

### 3.1 Definition und Nutzen von Meta-Daten

Mit Hilfe von Meta-Daten kann man bestimmte Eigenschaften eines HTML-Dokuments beschreiben, die nicht vom WWW-Browser angezeigt werden. Suchmaschinen können diese Informationen interpretieren und sie bei der Bewertung des Dokuments bezüglich der Suchanfrage sowie bei der Ausgabe des Suchergebnisses verwenden. Meta-Daten werden mit Hilfe von *Meta-Tags* definiert, die folgende allgemeine Syntax haben:

```
<META NAME="Meta-Name" CONTENT="Meta-Wert">
```

Diese Meta-Tags müssen im Kopf eines HTML-Dokuments stehen. Damit auch Anwender, die nicht mit HTML vertraut sind, die Vorteile von Meta-Daten in ihren Dokumenten nutzen können, wurde ein MetaTool entwickelt, das die Generierung der Meta-Tags übernimmt.

Es existieren verschiedene Meta-Tags, von denen für Suchmaschinen das *description*- und das *keywords*-Tag die größte Bedeutung haben. Das *description*-Tag enthält eine Beschreibung der HTML-Seite, die von den Suchmaschinen bei der Ausgabe des Dokuments im Suchergebnis verwendet wird.

Fehlt dieses Tag, generieren viele Suchmaschinen eine Zusammenfassung des Dokuments, die in den meisten Fällen aber wenig aussagekräftig ist. Wenn im *keywords*-Tag Suchbegriffe angegeben sind, unter denen das Dokument gefunden werden soll, dann erhöht sich nicht nur die Trefferwahrscheinlichkeit, sondern auch der Rang der Seite in der Ergebnisliste.

SWING sieht außerdem die Meta-Tags *official-homepage* und *official-homepage-aliases* vor, die zur Bewertung eines Dokuments herangezogen werden. Mit dem *official-homepage*-Tag werden die in relationalen Datenbanken bekannten Primärschlüssel realisiert: in einer Datenbank kann eine Eigenschaft von Objekten angegeben werden, die diese eindeutig identifiziert (wie Personalausweisnummer für Personen und Matrikelnummer für Studenten). Damit eignet sich dieses Tag für die Kennzeichnung des Einstiegspunktes in eine Dokumentenhierarchie, von dem aus jedes Dokument in der Hierarchie über Links erreichbar ist, und es sollte auf der Startseite einer Firma oder Institution mit der offiziellen Bezeichnung (Firmen- bzw. Institutsname) hinterlegt werden. Die Definition des Tags *official-homepage* hat zwei Vorteile:

- Findet SWING eine zweite Seite in MV-Info mit dieser Kennung, wird auf die Nicht-Eindeutigkeit aufmerksam gemacht.
- Findet SWING mehrere Seiten mit dem Firmen- bzw. Institutsnamen als Suchbegriff, dann wird die so gekennzeichnete "official-homepage" am höchsten bewertet und somit als erstes angezeigt.

Weitere Schreibweisen für die *official-homepage*-Angabe (z.B. vollständig ausgeschriebener Firmennamen oder mehrdeutige Abkürzung) können mit dem Tag *official-homepage-aliases* angegeben werden.

Die Meta-Daten sind bei der SWING-Suche abfragbar. Somit wird das Anfrageergebnis reduziert und die Trefferrelevanz der zurückgelieferten Dokumente erhöht sich.

### 3.2 Einfluß der Meta-Daten auf die Bewertung eines Dokumentes

Das Ergebnis einer Anfrage ist eine Liste von bewerteten Dokumentreferenzen. Diese Bewertung wird auch als Ranking bezeichnet. In diesem Abschnitt werden die Regeln vorgestellt, nach denen die SWING-Suchmaschine die Relevanz eines Dokumentes bezüglich der Suchanfrage bewertet. Im Mittelpunkt der Betrachtung soll dabei die Beantwortung der Frage stehen, wie Meta-Daten die Bewertung eines Dokumentes beeinflussen.

Der Ranking-Algorithmus, der für die Suchmaschine implementiert wurde, weist jedem einzelnen Dokument aus der Menge der mit SWING gefundenen Dokumente eine Wertigkeit zu. Die Bewertung kann maximal 100% betragen und wird folgendermaßen bestimmt:

- *Datenbank-Anfrageformular*: Handelt es sich bei dem Dokument um ein Datenbank-Interface in Form eines Anfrageformulars, dann wird dieses Dokument mit 100% bewertet (alle weiteren Regeln werden in diesem Fall nicht betrachtet). Somit erscheinen Datenbank-Anfrageformulare immer am Anfang der Ergebnisliste, basierend auf der Annahme, daß man durch die größeren und vor allem strukturierten Datenmengen in den zugrundeliegenden Datenbanken die besten Suchergebnisse erreicht.
- *Qualität des Dokumentes*: Die Qualität eines Dokumentes ist durch das Vorhandensein von Meta-Tags gekennzeichnet. Ist einer der Suchbegriffe in einem Meta-Tag enthalten, dann wird das Dokument höher bewertet als andere, wobei die Einstufung am höchsten ist, wenn der Suchbegriff im *official homepage*-Tag vorkommt.  
Desweiteren werden HTML-Dokumente mit dem Namen `index.html` höher gewertet als andere, da diese in der Regel Einstiegsseiten für Dokumentensammlungen darstellen.
- *Vorkommen des Suchbegriffs im Titel*: Dokumente, bei denen der Suchbegriff im Titel vorkommt, erhalten eine höhere Bewertung als andere.

- *Häufigkeit des Suchbegriffs*: Bezüglich des gefundenen Dokuments wird das anzahlmäßige Auftreten des Suchbegriffs ausgewertet. Ein Dokument wird hoch eingestuft, wenn der Suchbegriff häufig im Dokument vorhanden ist.
- *Pfadlänge*: Der Pfadname eines gefundenen Dokuments wird hinsichtlich seiner Länge analysiert. Kurze Pfadnamen werden höher bewertet als lange, da die Länge des Pfadnamens die Hierarchie auf dem Server widerspiegelt, d.h. je kürzer der Pfadname, desto höher ist das Dokument in der Serverhierarchie angeordnet.
- *Pivotisierung*: Alle Dokumente auf den Servern des Landesinformationssystems erhalten eine höhere Bewertung als andere, da es sich bei MV-Info um ein Katalogsystem handelt. Somit können in dem gefundenen Dokument weitere interessante Links enthalten sein, die vielleicht nicht den Suchbegriff enthalten, aber zum gesuchten Themenkreis passen.

Einige dieser Bewertungsregeln werden von den meisten Suchmaschinen verwendet (Vorkommen des Suchbegriffs im Titel, Häufigkeit des Suchbegriffs), andere wurde speziell für die SWING-Suchmaschine eingeführt.

Einige der genannten Bewertungskriterien sind von jedem Informationsanbieter in seinen eigenen Dokumenten realisierbar. Es ist somit möglich, Dokumente so zu gestalten, daß sie zu bestimmten Stichworten durch den Ranking-Algorithmus hoch bewertet werden. Dies soll im folgenden an einem Beispiel demonstriert werden. Dazu wurde die Homepage des Lehrstuhls zweimal kopiert und unter den Pfaden `/CeBit99-1/index.html` bzw. `/CeBit99-2/index.html` auf dem WWW-Server `wwwdb.informatik.uni-rostock.de` abgelegt. Das erste Dokument enthält das *official-homepage*-Tag mit dem Wert "Lehrstuhl Datenbank- und Informationssysteme". Ansonsten stimmen beide Dokumente überein. Sucht man mit SWING nach Dokumenten, die die Phrase "Datenbank- und Informationssysteme" enthalten, dann erscheint das Dokument unter `/CeBit99-1/index.html` an erster Stelle mit 100%, während das andere Dokument erst an der dreizehnten Position mit dem Rankingwert 39% auftaucht.

Warum wurden die beiden Dokumente so unterschiedlich bewertet, obwohl sie doch fast identisch sind? Nach dem obigen Ranking-Algorithmus liefern alle Bewertungsregeln bis auf eine Ausnahme die gleichen Resultate für die Dokumente. Unterschiedliche Resultate ergeben sich nur bei der Bewertung der Qualität der beiden Seiten, da der Suchbegriff "Datenbank- und Informationssysteme" im *official-homepage*-Tag des ersten Dokuments enthalten ist. An diesem Beispiel sieht man, daß ein Dokument, auch wenn es noch so gut zur Suchanfrage paßt, nicht so hoch bewertet (und das nicht nur bei SWING, sondern auch bei allen anderen gebräuchlichen Suchmaschinen wie Altavista) wird, wenn die entsprechenden Meta-Daten fehlen. Aus diesem Grund wurde für die SWING-Suchmaschine ein Werkzeug entwickelt, das die Definition von Meta-Tags auf sehr einfache Art und Weise erlaubt.

### 3.3 MetaTool

Das MetaTool gestattet dem Anwender das Erzeugen, das Ändern sowie das Löschen von Meta-Tags für eine bestimmte HTML-Seite. Für die HTML-Seite, die analysiert werden soll, kann entweder die URL angegeben werden, oder es kann auch ein Upload der HTML-Datei vom lokalen Dateisystem des Anwenders erfolgen. Ein Upload der HTML-Quelle wird angeboten, da der HTML-Code eines Dokuments von einigen WWW-Servern bei der Bereitstellung des Dokumentes verändert werden kann (z.B. Roxen Challenger). Bei der Abspeicherung des Dokumentes mit dem neu erzeugten Meta-Datenblock würde das Dokument dann den vom WWW-Server modifizierten HTML-Code enthalten, was in den meisten Fällen aber sicherlich nicht gewünscht ist. Mit dem MetaTool können folgende Meta-Tags definiert werden:

- *language*: Sprache, in der das Dokument vorliegt.

- *official-homepage*: Offizielle Bezeichnung des Dokuments innerhalb des Landesinformationssystems, die eindeutig sein sollte. Die Eindeutigkeit dieses Tags kann über eine eingebaute Funktion getestet werden.
- *official-homepage-aliases*: Weitere Bezeichnungen für das Dokument.
- *theme*: Themengebiet(e) des Landesinformationssystems, denen das Dokument zugeordnet werden kann.
- *author*: Autor des Dokuments.
- *keywords*: Stichwörter, unter denen das Dokument gefunden werden soll.
- *description*: Beschreibung des Dokuments, die von der Suchmaschine bei der Ausgabe des Dokuments verwendet werden kann.

Weitere Meta-Daten, die im Dokument bereits definiert sind, können ebenfalls verändert bzw. gelöscht werden. Die Meta-Tags *language*, *author*, *keywords*, *description* werden auch von vielen anderen Suchmaschinen verwendet, die anderen sind speziell für die SWING-Suchmaschine eingeführt worden.

Nach der Angabe der Meta-Daten wird dann entweder das gesamte Dokument neu erzeugt oder nur ein Meta-Datenblock generiert, der anschließend über die Copy&Paste-Funktion des WWW-Browsers in das HTML-Dokument eingefügt werden kann.

## 4 Einbindung heterogener Datenbanken in die Suche

Damit die Suchmaschine systembekannte Datenbanken referenzieren kann, müssen ihr die Datenbank-Inhalte bekannt gemacht werden. In der ersten Version von SWING [HMDL97] wurden Datenbanken über *Schemainformationen* angesprochen: Wurde beispielsweise der Name einer in SWING eingebundenen Datenbank oder Datenbanktabelle (etwa `Hotel`) im Suchausdruck entdeckt, so wurde das zugehörige Datenbank-Anfrageformular angesprochen. In [HMDL97] wurden verschiedene Möglichkeiten aufgezeigt, wie auf diese Art gefundene Datenbanken dann technisch an die SWING-Suche angekoppelt werden können.

Die in SWING II vorgenommene Erweiterung erlaubt es nun sogar, nach *Datenbank-Inhalten* die zu einem Suchauftrag passende Datenbank zu finden. Es existieren bereits sehr einfache Mechanismen, die es Suchmaschinen erlauben, Datenbank-Inhalte zu indexieren. Beispielsweise ist es möglich, HTML-Texte aus Datenbank-Inhalten zu generieren, die dann von der Suchmaschine verarbeitet werden können. Dieser Ansatz hat aber entscheidende Nachteile:

- Die strukturierten Werte der Datenbank kommen im HTML-Text nur als unstrukturierte Zeichenketten vor. Somit läßt sich auch nicht feststellen, in welchem Attribut der Suchbegriff vorkommt.
- Als Ergebnis der Suchanfrage erhält man einen Link auf den HTML-Text, der den Datenbank-Inhalt repräsentiert und keinen Link auf ein Anfrageformular, mit dem dann eine Suche in der Datenbank möglich ist.

In diesem Abschnitt soll nun ein Mechanismus vorgestellt werden, der speziell für SWING entwickelt wurde und die eben genannten Nachteile beseitigt.

### 4.1 Aufbau der Suchmaschine

Der Basisbestandteil der SWING-Suchmaschine ist das Informationsmanagementsystem *Harvest*. Die zwei Hauptkomponenten des Harvest-Systems [HSW96] werden als *Gatherer* und *Broker* bezeichnet.

Gatherer sammeln Meta-Informationen über Dokumente, die im Internet verfügbar sind. Anschließend werden diese Meta-Informationen vom Broker indexiert und als Ergebnis auf Suchanfragen geliefert.

Um die Aktualität der Daten zu gewährleisten, prüfen die Gatherer in periodischen Abständen, ob die verfügbaren Dokumente verändert wurden. Ein Gatherer ermittelt aus den Dokumenten Informationen, die den Inhalt betreffen (z.B. Titel des Dokuments), sowie Meta-Informationen, zu denen beispielsweise URL, Größe, und Datum der letzten Änderung zählen. Diese Informationen werden in regelmäßigen Abständen vom Broker angefordert, der diese in sein Retrievalsystem einspeist.

Der Gatherer kann neben Dokumenten auf HTML-Basis auch andere Formate wie PostScript analysieren, da das Harvest-System verschiedene Filter bereitstellt, die in Abhängigkeit vom Dokumenttyp angewendet werden. In Abbildung 1 wird dieser Prozeß der Datenextraktion grob skizziert.

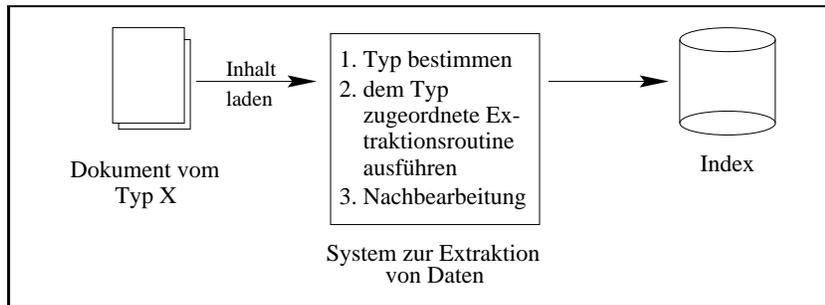


Abbildung 1: Der Prozeß der Datenextraktion

Die offenen Schnittstellen des Gatherers erlauben die Einbindung weiterer Filterprogramme für beliebige Dokumenttypen. Dadurch ist es möglich, eigene Filter für die Integration von Datenbank-Inhalten zu realisieren.

## 4.2 Integration von Datenbank-Inhalten

Für die Meta-Daten, die vom Gatherer extrahiert werden, definiert Harvest das *Summary Object Interchange Format* (SOIF). Das SOIF besteht aus einer Liste von Attribut/Wert-Paaren. Gebräuchliche Attribute sind beispielsweise *author*, *description*, *keywords* und *title*. Andere Attribute können frei hinzugefügt werden. Die uneingeschränkte Erweiterbarkeit der Attribute wird für die strukturierte Abspeicherung der Datenbank-Inhalte genutzt.

Die Extraktionsroutinen für die Datenbanken, die in die Suche einbezogen werden sollen, müssen in Abhängigkeit vom zugrundeliegenden Datenbanksystem leicht modifizierbar sein, da beispielsweise unterschiedliche SQL-Dialekte zu berücksichtigen sind. Damit ein Gatherer erkennen kann, um welches Datenbanksystem es sich handelt, wurden neue Dokumenttypen eingeführt, z.B. *ing-db* für Ingres- und *ora-db* für Oracle-Datenbanken. Diese Dokumente müssen auf den WWW-Servern, die den Zugriff auf die einzubindenden Datenbanken ermöglichen, vorhanden sein und enthalten Informationen, die für die Integration einer Datenbank benötigt werden:

- Die Angabe *Summarizer* gibt Auskunft darüber, wo das Programm zu finden ist, das aus den Datenbank-Inhalten ein SOIF-Fragment erzeugt. Der Summarizer wurde in DB-Perl implementiert und muß auf dem WWW-Server, der die Schnittstelle für den Zugriff auf die Datenbank bereitstellt, installiert werden. Bei DB-Perl handelt es sich um ein Perl-Interface, das den einheitlichen Zugriff auf eine Vielzahl existierender Datenbanksysteme ermöglicht.
- *URL* enthält die Adresse für ein Anfrage-Interface, das den Zugriff auf die Datenbank ermöglicht.
- *Title*, *Description* und *Keywords* enthalten Informationen, die dem Datenbank-Anfrageformular zugeordnet werden.

- *Database* gibt den Namen der Datenbank an, die eingebunden werden soll.
- Über die Angaben *Table* und *Attribut* kann der Datenbank-Administrator steuern, welche Attribute aus welcher Relation indexiert werden sollen. Dadurch wird sichergestellt, daß nur Inhalte, die öffentlich gemacht werden sollen, an die Suchmaschine weitergegeben werden.

In die SWING-Suchmaschine wurde beispielsweise der CityWorld-Hotelführer integriert, der auf einer Oracle-Datenbank basiert. Auf dem WWW-Server, über den der Zugriff auf diese Datenbank erfolgt, ist das Dokument `cityworld.ora-db` vorhanden, das folgende Informationen bereitstellt:

```

Summarizer:  http://www.cityworld.de/.../Ora-DB.pl
URL:         http://www.cityworld.de/.../auswahl.pl
Title:       CityWorld - Hotels und Pensionen
Description: Hotelführer M-V
Keywords:    Hotel, Zimmer, Unterkunft, Pension, Motel, Preis
Database:    Cityworld
Table:       hotel
Attribute:   name
Attribute:   ort
Table:       region
Attribute:   region

```

Der Index für den Hotelführer enthält somit 3 Attribute, denen alle vorhandenen Hotels, Orte bzw. Regionen zugeordnet sind.

Die folgenden Schritte werden vom Gatherer durchgeführt, um Datenbank-Inhalte in das Retrievalsystem der SWING-Suchmaschine einzuspeisen:

1. Lesen des Dokuments, das die benötigten Informationen für die Integration der Datenbank enthält (der URL muß SWING bekannt sein).
2. Bestimmen des Datenbanksystems über den Dokumenttyp und Aufruf der entsprechenden Extraktionsroutine.
3. Die Extraktionsroutine ruft dann den Summarizer auf, der unter dem im Dokument angegebenen URL zu finden ist.
4. Der Summarizer generiert ein SOIF-Fragment aus den Schemainformationen der Datenbank und den Attributwerten, die extrahiert werden sollen, und liefert es an den Gatherer zurück.
5. Der Gatherer vervollständigt dieses Fragment und nimmt ein URL-Mapping vor, d.h. der URL für das Dokument mit den Integrationsinformationen wird durch den URL für das Anfrageformular ersetzt.

Nach dem Einsammeln der Daten liegen die Datenbank-Inhalte in strukturierter Form im Suchmaschinen-Index vor, so daß jederzeit feststellbar ist, in welchem Attribut ein Suchbegriff enthalten ist.

### 4.3 Bereitstellung der relevanten Datenbanken

Als Suchergebnis auf Anfragen, für deren Beantwortung eine Datenbank als relevant eingestuft wurde, wird eine Referenz auf eine Interface-Seite in Form eines Anfrageformulars generiert, die der Nutzer im Dialog vervollständigen kann. In der ursprünglichen Anfrage enthaltene Stichworte werden nach Möglichkeit in das Formular übernommen. Der Nutzer kann somit hochrelevante Informationen in kompakter Form erhalten. Die eigentliche Datenbankanfrage bleibt dem Suchmaschinennutzer hierbei vollkommen transparent.

In nächster Zeit ist die folgende Weiterentwicklung geplant: Falls zu einer Suchthematik mehrere gleichartige bzw. ähnliche Datenbanken existieren, die sich in ihrem Schema nur geringfügig unterscheiden, dann sollen diese Datenbanken gemeinsam zur Bereitstellung der gesuchten Informationen genutzt (geplant ist die Kopplung mehrerer Hoteldatenbanken) werden. Die beteiligten Datenbanken können hierbei auf unterschiedlichen Rechnersystemen beheimatet sein.

## 5 Profildienste

In der heutigen Zeit reichen Suchmaschinen allein nicht mehr aus, um die Informationsflut im Internet zu bewältigen. Aus diesem Grund gehen immer mehr Anbieter dazu über, Informations-Abonnementdienste bereitzustellen. Je nach der Form des Dienstes unterscheidet man dabei zwischen Alerting- und Profildiensten [Glo98]:

- *Alertingdienst*: In einem föderativen, service-orientierten System zur Verbreitung und Nutzung von Informationen treten Ereignisse auf, von denen nicht bekannt ist, wann sie auftreten, die jedoch für den Nutzer von Interesse sind. Ein Alertingdienst ist ein Benachrichtigungsdienst, der den interessierten Nutzer über das Eintreten von Ereignissen informiert. Die Ereignisse werden dabei immer anbieterseitig ausgelöst.
- *Profildienst*: Ein Profildienst filtert auftretende Ereignisse hinsichtlich nutzerspezifischer Interessen und informiert den Benutzer über relevante Ereignisse. Die Definition des erforderlichen Nutzerprofils kann auf verschiedene Arten erfolgen, zum Beispiel durch Beobachtung des Benutzerverhaltens, anhand von Benutzereigenschaften oder durch Beispielvorgaben. Ein Profildienst kann reaktiv sein, das heißt er kann auftretende Ereignisse hinsichtlich der definierten Profile filtern. Er kann aber auch aktiv nach auftretenden Ereignissen bei Diensteanbietern fragen.

Im Umfeld von Suchmaschinen existieren zur Zeit aber noch keine oder nur sehr rudimentäre Abonnementdienste. In diesem Abschnitt soll deshalb der Profildienst der SWING-Suchmaschine vorgestellt werden, der mit Hilfe von Agententechnologien gezielt nach Informationen sucht, diese entsprechend den Wünschen des Nutzers aufbereitet und in periodischer Form zur Verfügung stellt.

### 5.1 Aufbau von Abonnementdiensten

Der wesentliche Aufbau eines Abonnementdienstes, unabhängig von seiner Organisationsform (entweder beim Anwender oder beim Diensteanbieter organisiert) entspricht der Abbildung 2 [Her96].

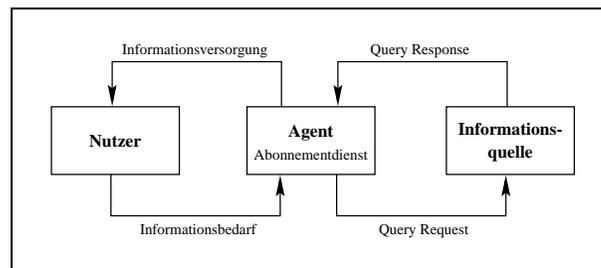


Abbildung 2: Aufbau eines Abonnementdienstes

Der Agent bildet die zentrale Rolle in dieser Drei-Schichten-Architektur. Die Nutzer haben einen bestimmten Informationsbedarf, zu deren Deckung sie sich eines Agenten bedienen. Der Agent verfügt nun nicht unbedingt selbst über die nachgefragte Information und bedient sich wiederum Informationsanbietern. Das Anfrageergebnis der Informationsanbieter wird vom Agenten unter Umständen noch einer Filterung unterzogen, bevor es dem Nutzer bereitgestellt wird.

## 5.2 Der SWING-Abonnementdienst

In der Konzeptionsphase wurden verschiedene Abonnementdienste wie Ariadne, The Informant, Podcast, Business Network und Elsevier ContentDirect betrachtet ([Por98]), um Erkenntnisse über positive und negative Eigenschaften dieser Systeme in den Entwurf des SWING-Abonnementdienstes einfließen zu lassen. Das Anforderungsprofil, das der Abonnementdienst einer Suchmaschine abdecken sollte, umfaßt die folgenden Punkte:

- Benachrichtigung des Nutzers über Veränderungen im System,
- Bearbeitung zyklisch wiederkehrender Anfragen,
- Bereitstellung turnusmäßiger Informationen zu einem speziellen Thema.

Der SWING-Abonnementdienst ist so konzipiert, daß er einerseits diese Anforderungen erfüllt und andererseits möglichst viele der Eigenschaften besitzt, die bei der Untersuchung der verschiedenen Systeme als positiv bewertet wurden. Im folgenden soll die Funktionalität beschrieben werden, die der Profildienst der SWING-Suchmaschine bietet. Auf Elementarfunktionen wie das Authentifizieren oder die Neuanmeldung eines Nutzers soll hier nicht näher eingegangen werden.

Die *Anfragebearbeitung* ermöglicht es dem Nutzer, Anfragen an die Suchmaschine in einem von ihm festgelegten Zeitintervall zu abonnieren. Der Unterschied zu herkömmlichen Suchmaschinen liegt in der autonomen Initiierung der Anfrageausführung durch den Abonnement-Agenten. Neben der Abonnementfunktion werden Funktionen zum Löschen, Editieren und manuellen Wiederholen von Anfragen angeboten.

Innerhalb des *URL-Reminders* können durch den Anwender Internetadressen spezifiziert werden, die durch den Abonnementdienst auf Änderungen beobachtet werden. Dabei kann das gesamte Dokument betrachtet werden oder aber nur ausgewählte Bereiche (Tabellen, Listen usw.).

Der *Newschannel* sammelt Nachrichten an einen Nutzer. Bei den Nachrichten kann es sich sowohl um abonnierte Anfrageergebnisse bzw. Mitteilungen des URL-Reminders als auch um SWING-Systemnachrichten handeln. News können im Moment nur in eine Richtung vom SWING-System an Abonnementnutzer übertragen werden, denkbar ist aber auch der Austausch von Nachrichten zwischen Nutzern.

Der *Themenkatalog* ist eine Art Browsing-System, in dem Dokumentenreferenzen nach Themen sortiert sind. Der Nutzer kann durch Auswahl von Themen Neuigkeiten direkt auf seinem Profil sehen. Aufgrund der gleichen Begriffswelt des Themenkatalogs sind Interessensanalysen zwischen Profilen unterschiedlicher Nutzer möglich.

Mit Ausnahme des Themenkatalogs wurden alle anderen Komponenten bereits im Profildienst der SWING-Suchmaschine realisiert. Die Architektur dieses Dienstes wird in Abbildung 3 dargestellt, wobei die oben beschriebene Schichtenarchitektur deutlich zu erkennen ist.

Mit Hilfe der Eingabekomponente stellt der Nutzer des Abonnementdienstes Kontakt zum Informationsagenten her. Wichtigstes Werkzeug ist für ihn in diesem Zusammenhang der WWW-Browser. Die Ausgaben der personalisierten Informationen des Agenten können dem Nutzer sowohl in Form von E-Mails als auch über das WWW bereitgestellt werden. Der Informationsagent verwaltet alle Daten der Nutzer, wie Name, Paßwort usw.. Im besonderen verwaltet er auch die vom Nutzer gestellten Anfragen, die zurückgelieferten Dokumentenreferenzen und die zu überwachenden URL's. Zusätzlich übernimmt er die Visualisierung der Daten. Dies geschieht in diesem Profildienst mittels HTML-Formularen. Zur Informationsgewinnung bedient sich der Informationsagent des SWING-Agenten, indem er über eine Schnittstelle Informationen zu einer Nutzeranfrage anfordert. Die Antwort, in Form eines HTML-Formulars, beinhaltet neben den Dokumentenreferenzen auch Relevanzbewertungen und Kurzbeschreibungen der Referenzen.

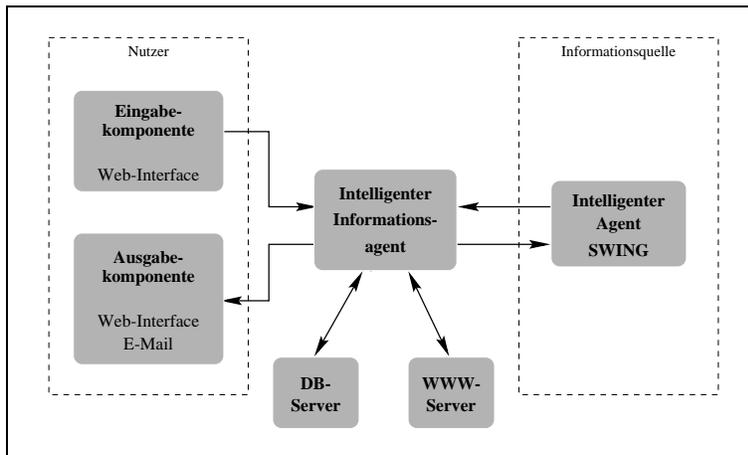


Abbildung 3: Architektur des SWING-Abonnementdienstes

## 6 Zusammenfassung

SWING ist eine moderne Suchmaschine, die viele exklusive Merkmale wie die Integration von Datenbanken bei der Suche im WWW aufweist. SWING ist damit eine der entscheidenden Funktionalitäten im Landesinformationssystem MV-Info, das im Internet die WWW-Angebote Mecklenburg-Vorpommerns integriert und klassifiziert. Das SWING-Projekt soll hier auch als gelungenes Beispiel für die Synergieeffekte stehen, die ein Verbundprojekt mit lokalen Firmen (insbesondere Software-Häusern und EDV-Dienstleistern) und Universitäten (hier speziell der Fachbereich Informatik der Universität Rostock) erzeugen kann.

## Literatur

- [BBD99] M. H. Böhlen, L. Bukauskas und C. E. Dyreson. The Jungle Database Search Engine. In *SIGMOD Conference 1999*: 584-586.
- [DLHM97] A. Düsterhöft, U. Langer, H. Meyer und A. Heuer. SWING: Konzept einer Suchmaschine für das regionale Informationssystem MV-Info. In *9. Workshop "Grundlagen von Datenbanken"*, Forschungsbericht 643 der Universität Dortmund, 1997.
- [Glo98] Global-Info: *Vorschlag der technischen Arbeitsgruppe in Schwerpunkt 4 zur Rahmenarchitektur*. 1998.
- [Her96] B. Hermans. *Intelligent Software Agents on the Internet*. Diplomarbeit an der Universität Tilburg, Niederlande, Juli 1996.
- [HSW96] D.R. Hardy, M.F. Schwartz und D. Wessels. HARVEST - Effective Use of Internet Information. TR CU-CS-743-94, University of Colorado at Boulder, Dept of CS, Januar 1996.
- [HMDL97] A. Heuer, H. Meyer, A. Düsterhöft und U. Langer. SWING: Der Anfrage- und Suchdienst des Regionalen Informationssystems MV-Info. In: *1. IuK-Tage Mecklenburg-Vorpommern, Schwerin, 27.-28. Juni 1997*, Wirtschaftsministerium Mecklenburg-Vorpommern, Juni 1997.

- [HMW99] A. Heuer, H. Meyer und G. Weber. SWING: Die Suchmaschine des Landesinformationssystems MV-Info. In: *2. IuK-Tage Mecklenburg-Vorpommern, Rostock, Juni 1999*, Wirtschaftsministerium Mecklenburg-Vorpommern, Juni 1999.
- [Kra99] J. Krause. Microsoft Site Server 3.0. Addison-Wesley-Longmann, München, 1999.
- [LDHM97] U. Langer, A. Düsterhöft, A. Heuer und H. Meyer. SWING: Ein Anfrage- und Suchdienst im Internet. In *Rostocker Informatik-Berichte (1997), Heft 21*.
- [Por98] B. Porst. Konzept eines Internet-Abo-Dienstes für die SWING Suchmaschine. Studienarbeit, Universität Rostock, Fachbereich Informatik, Oktober 1998.
- [Tit98] P. Titzler. Realisierungsvorschlag für die Implementierung einer verteilten Suchmaschine. Studienarbeit, Universität Rostock, Fachbereich Informatik, Oktober 1998.