Anreicherung von Webseiten um beschreibende Metadaten

Studienarbeit

Universität Rostock, Fachbereich Informatik, Lehrstuhl Datenbank- und Informationssysteme

Andreas Schulz

Betreuer: Dr.-Ing. Meike Klettke

Abgabedatum: 01.10.2001

Inhaltsverzeichnis

1 Einleitung

Das explosionsartige Anwachsen des World Wide Web (WWW) in den letzten Jahren und die damit verbundene Flut von bereitgestellten Daten machen es unumgänglich, relevante von unwichtigen Informationen zu trennen. Weltweit stellen Firmen, Behörden, Universitäten, andere Forschungseinrichtungen und Privatpersonen aus verschieden motivierten Gründen Informations- und Serviceangebote bereit. Dabei handelt es sich sowohl um einfache Textdokumente als auch um Schnittstellen zu Datenbanken. Auch als Erstveröffentlichungsquelle ist das WWW nicht zu unterschätzen. Viele Arbeiten werden zu erst oder in einigen Fällen nur im WWW veröffentlicht. Der Drang nach Steigerung der Aktualität lässt das WWW aufgrund der Schnelligkeit der elektronischen Informationsvermittlung zu der Alternative schlechthin im Bezug auf die klassischen Medien wie Zeitung, Fernsehen, Rundfunk oder auch Buch werden.

Sucht der Nutzer in der Masse von Dokumenten nach zu einem Thema relevanten Informationen, steht er vor mehreren Problemen. Zunächst muss er WWW-Datenquellen finden, die relevante Daten zur Verfügung stellen. Dies geschieht im Allgemeinen unter Zuhilfenahme von diversen Suchmaschinen, welche aufgrund von Stichworten die Metadaten einer gewissen Anzahl von registrierten Dokumenten durchsuchen und eine Ergebnismenge zurückliefern. Aufgrund der Möglichkeit von Doppeldeutigkeiten von Daten liegt es am Nutzer, diese Dokumente selbst zu durchforsten, um eine mögliche Relevanz zum benötigten Thema zu erkennen.

Ziel dieser Studienarbeit ist es, kontextbezogene Webseiten um beschreibende Metadaten anzureichern. Dabei wird eine Kombination von Wrappermethoden und wissensbasierten Verfahren eingesetzt. Mit Hilfe dieser generierten Metadaten soll nun ein weiteres Schrumpfen der Datenmenge ermöglicht werden, um nur noch kontextrelevante Dokumente zu behalten. Kapitel 2 beschäftigt sich mit Metadaten und einer möglichen Klassifizierung dieser. Anschließend wird das Wrapper-Toolkit W4F zur Erzeugung von HTML-Wrappern untersucht. Wissensbasierte Verfahren aus dem Projekt GETESS werden dann in Kapitel 4 vorgestellt. Abschließend wird eine Kombination der beiden Verfahren vorgestellt und eine Implementation anhand der Beispieldomäne “Geschichte Mecklenburg-Vorpommerns“ beschrieben.

2 Metadaten

Ziel dieses Kapitels ist es die Notwendigkeit von Metadaten zu verdeutlichen. Im Verlauf des Kapitels wird versucht, den Begriff Metadaten zu definieren, um anschliessend mögliche Klassifikationen von Metadaten zu erläutern.

2.1 Sinn von Metadaten

Anwendungsgebiet und Nutzen von Metadaten sind sehr gross. Anhand von zwei Beispielen sollen Verwendungszweck und Notwendigkeit von Metadaten verdeutlicht werden.

2.1.1 Information Retrieval, Suche in grossen Datenbeständen

Anstatt im Information Retrieval grosse Datenbestände mit aufwendiger Volltextsuche zu durchforsten, besteht die Möglichkeit Metadaten anzulegen, da diese um ein Vielfaches kleiner sind und damit schneller durchsucht werden können. Die Effizienz der Suche wird so unter Umständen enorm verbessert. Zwar gibt es sicherlich auch im Information Retrieval Methoden und Techniken, die Effizienz in der Suche und Qualität im Suchresultat garantieren, was aber nicht dagegen spricht, Metadaten gezielt einzusetzen. Die Tatsache, dass die durchschnittlich benötigte Datenübermittlungszeit sinkt, ist hierbei ein nicht zu vernachlässigender Aspekt. Bedeutung gewinnt diese Technik gerade im Bezug auf die ständig zunehmende Vernetzung von Rechnern. Die Suche nach Informationen von auf entfernt liegenden Rechnern wird verbessert, wenn man vor dem Herunterladen der Daten weiss, ob diese sich als nützlich erweisen. Metadaten erlauben in diesem Kontext die Brauchbarkeit der Daten gezielt zu ermitteln.

2.1.2 “Originärer“ Sinn der Metadaten

Neben dem bisher genannten Bereich, der für die Nutzung von Metadaten spricht, gibt es ein klassiches Beispiel aus dem Alltag, das auf intuitive und verständliche Art den Zweck von Metadaten illustriert. Dieser Ansatz wurde mit dem Ausdruck originärer Sinn von Metadaten überschrieben, da es sich wahrscheinlich um den ursprünglichsten Sinn überhaupt handelt: Bei einer Bibliothek handelt es sich um eine Menge von Büchern (Dateneinheiten). Bücher lassen sich mit Hilfe von Attributen verschlagworten, so dass ein Katalog (Metadatenbank, Metadata Dictionary) entsteht, der die wichtigsten Suchkriterien (Metadaten) umfasst. Dazu gehören etwa der Titel, der Autor, Erscheinungsdatum, assoziative Schlagwörter aus dem Schlagwortverzeichnis oder andere Klassifizierungsattribute. Daneben werden noch weitere Informationen zu finden sein, etwa der Verwahrungsort, Verweise auf andere

Bücher oder weitere externe Verweise wie beispielsweise auf Publikationen in anderen Fachbibliotheken. Mit Hilfe des Kataloges lässt es sich auf einfache und effiziente Weise unter Angabe von wenigen Informationen suchen. Es kann also über die Relevanz eines Buches entschieden werden, ohne dass es vorher gelesen wurde.
Es gibt natürlich weitere Aspekte und Szenarien, die den Gebrauch von Metadaten befürworten, aber weniger mit dem Thema dieser Studienarbeit zu tun haben.

2.2 Begriffsdefinition - Was sind Metadaten?

Wie bereits festgestellt, handelt es sich bei Metadaten um ”Daten über Daten”, also Daten, die verschiedene Eigenschaften von Datensätzen beschreiben und den inhaltlichen Kontext herstellen. Es bleibt festzustellen, dass es keine einheitliche Definition gibt und so Autoren viele eigene Definition proklamieren. Eine kurze, treffende Definition lässt sich im Entwurf der ISO Spezifikation 11179 finden. Metadaten werden dort beschrieben als

“The information and documentation which makes data sets understandable and shareable for users“

Die genannte ISO Definition 11179 ist die wichtigste Definition, die auf Metadaten Anwendung finden kann. Dort werden in sechs Abschnitten die Aufgaben, Prinzipien und Richtlinien für die Klassifizierung, Attributierung, Namenskonvention (Identifikation) und Strukturierung von Daten diskutiert.

2.3 Klassifikation von Metadaten

In diesem Abschnitt werden einige Möglichkeiten der Klassifikation von Metadaten diskutiert. Hierbei handelt es sich nur um eine Auswahl von Klassifikationsmöglichkeiten und erhebt keinen Anspruch auf Vollständigkeit. So ist es möglich Metadaten nach ihrer Inhaltsabhängigkeit oder Nutzungsart zu unterteilen.

2.3.1 Klassifikation nach der Inhaltsabhängigkeit

- inhaltsabhängige Metadaten
  Inhaltsabhängige Metadaten beziehen sich auf den Inhalt des Dokumetes bzw. der Information. Ein Beispiel für solche Metadaten sind Schlüsselworte.

- inhaltsunabhängige Metadaten
  Inhaltsunabhängige Metadaten beziehen sich auf Informationen, die nichts mit dem Inhalt des Dokuments, welches sie beschreiben, zu tun haben. Hierbei handelt es sich sowohl um identifizierende Metadaten (ID-Nummer, Ver-

sionsnummer,...) als auch um administrative Metadaten (Aufbewahrungsort, Status,...).

2.3.2 Klassifikation nach der Nutzungsart

- aktive Nutzung der Metadaten
  Ein System (Metadata Repository, System Catalog), das aktive Nutzung der Metadaten betreibt, ist immmer konsistent mit der zugrundeliegenden Datenstruktur. Alle Änderungen in Struktur und Daten werden automatisch im System geändert.

- passive Nutzung der Metadaten
  Dem gegenüber können bei passiver Nutzung von Metadaten Inkonsistenzen zwischen Metainformationen und Datenstruktur auftreten. Akteure der Datenbank (Administratoren, Endanwender) sind selbst verantwortlich für die Aktualität und Konsistenz ihrer Dokumentation von Struktur und Prozessen der Datenbank.

Weitere Klassifikationsmöglichkeiten sind beispielsweise in[1] aufgeführt, hier aber nicht weiter erwähnt, da sie für die Bearbeitung des mir gestellten Problems unrelevant sind. Für den Verlauf der Studienarbeit wird die Klassifikation der Metadaten nach der Inhaltsabhängigkeit von Bedeutung sein.

[1] nach [Ma01]

3 Datengewinnung durch Abfragen des WWW

Inhalt dieses Kapitels ist das automatische Gewinnen von Daten durch Abfragen von WWW-Datenquellen. Der Zugriff wird durch eine Software, dem sogenannten Wrapper, realisiert. Da das WWW als Datenquelle für den menschlichen Nutzer konzipiert wurde, sind Probleme bei der Datenextraktion mittels einer Mensch-Maschinen-Schnittstelle nicht vermeidbar. Derzeit sind Wrapper aber die einzige Möglichkeit, um Daten aus WWW-Datenquellen abzufragen.

Im Abschnitt 3.1 wird der Begriff Wrapper geklärt und auf Konzepte für das Wrapper-Design eingegangen. Der Hauptabschnitt 3.2 ist dann dem W4F-Toolkit als Vertreter von Toolkits zur Wrapperimplementierung gewidmet. Abschliessend werden Probleme, die beim Einsatz von Wrappern bei der Abfrage von WWW-Datenquellen auftreten und somit eine Einschränkung des Einsatzbereiches darstellen, aufgeführt.

3.1 Design und Aufgabe von Wrappern

3.1.1 Aufgabe von Wrappern

Was versteht man unter einem Wrapper?

Als Wrapper wird eine Software bezeichnet, die Daten und Anfragen zwischen zwei Datenmodellen konvertiert. Im Zusammenhang mit dem WWW bedeutet es folgendes:
Ein Wrapper für eine WWW-Datenquelle extrahiert die im HTML-Dokument implizit gespeicherten Daten und konvertiert diese in explizit gespeicherte Daten eines Datenmodells. Das HTML-Dokument ist das Ergebnis einer Anfrage an die WWW-Datenquelle mittels des HTTP-Protokolls[2].

Den Ablauf kann man sich folgendermaßen vorstellen:
Ein Client verbindet sich über eine URL (Unifed Request Locator), unter Angabe der Übertragungsmethode (GET oder POST) für die zu übermittelnden Parameter, mit einem Server. Der HTTP-Server liefert bei einer erfolgreichen Anfrage ein HTML-Dokument zurück. Desweiteren wird immer eine Menge von HTTP-Parametern zurückgeliefert, die dem Client zu behandelnde Fehlerzustände, Authorisierungszustände, Umleitungen, ... mitteilen.

Für die implizit im Dokument gespeicherten Daten müssen nun eine Zielstruktur und der Datentyp ermittelt werden. Bei der Bestimmung des Datenmodells sind HTML-Struktur und Text-Struktur hilfreich. Desweiteren werden Verfahren

[2] Eine genaue Beschreibung von HTTP und HTML ist in [MK97] zu finden

zur Extraktion der Daten aus dem HTML-Dokument benötigt. Dieses Reverse-Engeneering ist Aufgabe des Wrapper-Entwicklers.

3.1.2 Design von Wrappern

Inhalt dieses Abschnitts sind Entwurfskriterien und zwei Design-Konzepte für Wrapper. Zunächst werden Entwurfskriterien für Wrapper aufgeführt, aus welchen verschiedene Design-Konzepte abgeleitet wurden.

Entwurfskriterien

- Änderungsfreundlichkeit
  Da sich das Layout von Dokumenten im WWW recht häufig ändert, ist eine leichte Anpassbarkeit an diese Änderungen erforderlich.
- Robustheit
  Wrapper sollen nicht bei jeder kleineren Layout-Änderung scheitern, sondern trotzdem den Großteil der Daten extrahieren.
- Wiederverwendbarkeit
  Eine fertige Extraktionslösung soll auch bei anderen Wrappern oder Dokumenttypen einsetzbar sein.
- Portierbarkeit
  Plattformunabhängigkeit ist eine wünschenswerte Eigenschaft von Wrappern. Der Einsatz eines unter Windows geschriebenen Wrappers soll beispielsweise auch in einer Unix-Umgebung möglich sein.
- Implementierungsunabhängigkeit
  Ein nachträglicher Wechsel der Programmiersprache ist ebenfalls ein Kriterium für das Wrapper-Design.

Klassisches Design

Sind Extraktionslösung und Zieldatenstruktur Bestandteil des Programmcodes in einer Programmiersprache, so wird der Wrapper als klassisch bezeichnet. Es gibt keine Trennung zwischen Programmcode für Programmablauf, Datenextraktion und Abbildung auf die Zieldatenstruktur. Eine negative Folge dieser Eigenschaft zeigt sich bei einer eventuell nötig werdenden Anpassung des Wrappers, da der gesamte Programmcode analysiert werden muss. Außerdem sind Probleme bei der Wiederverwendbarkeit der Extraktionslösung nicht ausgeschlossen, da der Programmcode für die Extraktion nur schwer vom Programm getrennt werden kann. Ein nachträglicher Wechsel der Programmiersprache ist nicht möglich, der Wrapper

müsste neu geschrieben werden. Geringe Probleme im Bezug auf die Portierbarkeit könnten nur auftreten, wenn die Verfügbarkeit der gewählten Programmiersprachen auf anderen Plattformen nicht gewährleistet werden kann.

Design-Richtlinien des W4F-Toolkits

Um den oben genannten Entwurfskriterien für einen Wrapper zu entsprechen, wurden von den W4F-Entwicklern Design-Richtlinien aufgestellt und im W4F-Tolkit[3] umgesetzt. Diese werden im folgenden beschrieben.

- Die Verwendung einer modularen dreistufigen Schichtenarchitektur gewährleistet Unabhängigkeit und Wiederverwendbarkeit. Die Schichten stellen die Teilaufgaben des Wrappers dar und werden mit Retrieval-Schicht, Extraktionsschicht und Abbildungsschicht bezeichnet.
  - Das Abfragen der WWW-Datenquelle mit dem HTML-Dokument als Ergebnis ist die Aufgabe der Retrieval-Schicht.
  - In der Extraktionsschicht werden die Daten von Interesse aus dem HTML-Dokument extrahiert. Die benutzte Sprache soll die HTML-Struktur und die Struktur der Text-Elemente ausnutzen können.
  - Die Abbildung der extrahierten Daten auf die weiterverwendbare Zieldatenstruktur ist Aufgabe der Abbildungsschicht.
- Die einzelnen Schichten werden deklarativ spezifiziert. Da jede durch eine Menge von Spezifikationsregeln beschrieben wird, gibt es eine eindeutige Semantik, die wiederum Verständlichkeit, leichte Wartbarkeit und Wiederverwendbarkeit sichert. Die zur Implementation benutzte Programmiersprache kann leicht ausgetauscht werden, ohne die Spezifikation ändern zu müssen. Ein weiterer Vorteil ist die leichte Erlernbarkeit der Spezifikationssprache, da sie weniger mächtig ist, als es Programmiersprachen sind.
- Die Extraktion der Daten muss an deren Granularität anpassbar sein. Das heißt, dass die Datenstruktur sowohl anhand der HTML-Struktur ermittelbar, als auch die Textstruktur innerhalb der HTML-Tags auswertbar sein muss. Durch Kommas getrennte Aufzählungen können beispielsweise durch reguläre

[3] Entnommen aus [SA00] und [Go00]

Ausdrücke ausgewertet werden.

- Um eine eindeutige Identifikation der Elemente und eine einfache Navigation im HTML-Dokument zu ermöglichen, wird das HTML-Dokument abstrakt repräsentiert. Dies wird durch eine deklarative Spezifikation erreicht.

- Werkzeuge zur Unterstützung des Users bei der Erstellung und Wartung von Wrappern helfen unnötigen Aufwand zu vermeiden und die Einarbeitungszeit zu verkürzen.

Im nächsten Abschnitt wird die Wrapper-Implementierung unter Berücksichtigung der Design-Richtlinien mittels des W4F-Toolkits beschrieben.

3.2 Das W4F-Toolkit

W4F bedeutet World Wide Web Wrapper Factory und wurde von der Universität Pennsylvania (USA) und der Telecom (E.N.S.T.) Paris (Frankreich) entwickelt. Das Toolkit ist bis Version 1.21 frei verfügbar.

W4F basiert auf Java und besteht aus mehreren Komponenten.
Dabei handelt es sich um:

- **W4F-Parser**
  Er dient zur Analyse von HTML-Dokumenten und zeichnet sich durch eine hohe Fehlertoleranz aus. Dies bedeutet, dass auch fehlerhafte HTML-Seiten analysiert werden können. Der Parser unterstützt HTML 3.2.

- **W4F-Compiler**
  Zur Generierung von Java-Klassen zur Wrapperspezifikation wird der W4F-Compiler verwendet. Seine generierten Klassen sind in jedem Java-Programm anwendbar.

- **W4F-Laufzeitmodul**
  Das mitgelieferte Laufzeitmodul erlaubt die Ausführung der generierten Java-Wrapper als selbständige Programme. Es ist beispielsweise beim Testen von geschriebenen Wrappern eine nicht zu unterschätzende Hilfe.

- **Werkzeuge zur Unterstützung des Nutzers**
  Die mitgelieferten Werkzeuge funktionieren allerdigns nur ab dem Internet Explorer 4 und sind besonders für Einsteiger interessant.

- **Formular-Wizard**
  Dient als Hilfe bei der Erstellung von Retrieval-Regeln für WWW-Seiten, die Formulare enthalten. Er gibt die wesentlichen Elemente eines HTML-Formulares aus.
- **Extraktions-Wizard**
  Dieser Wizard hilft bei der Erstellung von Extraktionsregeln. Er gibt den identifizierenden Pfadausdruck eines vom Nutzer in einer HTML-Seite selektierten Textelementes an.
- **Abbildungs-Wizard**
  Dieses Hilfetool hilft dem Nutzer bei der Abbildung vom intern verwendeten Datenformat NSL auf nutzerdefinierte Datenstrukturen.

Nach diesem kurzen Überblick folgt im nächsten Abschnitt eine Beschreibung der Wrapper-Erstellung mit W4F.

3.2.1 Prinzipielle Arbeitsweise eines W4F-Wrappers

Der vorgestellten Schichtenarchitektur entsprechend, besteht ein Wrapper aus drei Teilen. In der Retrieval-Schicht erfolgt das Laden des durch die Retrieval-Regeln spezifizierten HTML-Dokumentes. Es dient als Eingabe für den HTML-Parser, der daraus eine abstrakte Darstellung, den HTML-Baum oder Analysebaum, erstellt. Jedes Element des HTML-Dokumentes kann anhand des Analysebaumes über einen Pfadausdruck eindeutig identifiziert werden. In der Extraktionsschicht werden die durch Extraktionsregeln spezifizierten Elemente extrahiert und in der NSL-Datenstruktur (Nested String List) gespeichert. In der darauffolgenden Abbildungsschicht erfolgt das Mapping dieser Daten auf die gewünschte Zieldatenstruktur. Das Ergebnis ist dann ein Java-Objekt bzw. ein Java-Standarddatentyp. In Abbildung 1 ist die prinzipielle Arbeitsweise eines Wrappers dargestellt.

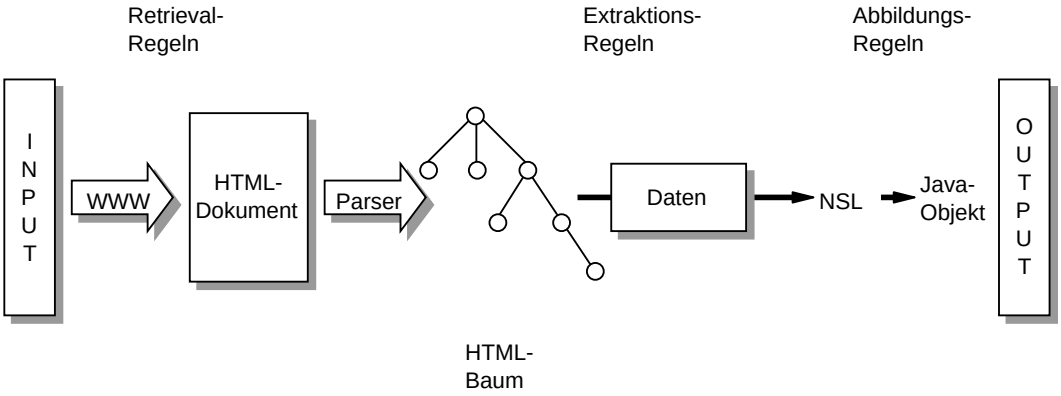

Abbildung 1: Prinzipielle Arbeitsweise eines Wrappers

Im folgenden wird auf die einzelnen Schichten detaillierter eingegangen.

- **Die Retrieval-Schicht**

  In dieser Schicht wird durch Angabe von Retrieval-Regeln[4] festgelegt, welches HTML-Dokument mit welchen Parametern von welcher Web-Adresse geladen wird. W4F unterstützt vier Retrieval-Methoden:

  – File GET
  – HTTP HEAD
  – HTTP GET
  – HTTP POST

  Der Retrieval-Block im Wrapper-Quelltext beginnt mit dem Schlüsselwort RETRIEVAL_RULES. Es ist zwar möglich mehrere Retrieval-Rules zu definieren, aber zu jedem Zeitpunkt ist nur eine Regel aktiv, wodurch gewährleistet wird, dass immer nur ein HTML-Dokument an die Extraktionsschicht übergeben wird. Abschließend folgen je ein Beispiel für die Übertragungsmethoden GET und POST.

  Laden eines HTML-Dokumentes mit Hilfe der GET-Methode

  Die URL ist in dieser Regel variabel und eventuelle Parameter werden in ihr übergeben.

[4] Die ausführliche Grammatik ist in [W4F] zu finden.

```
// GET-Methode
get_document(STRING url)
{
METHOD: GET;
URL: $url$;
}
```

Dem gegenüber sieht ein Beispiel für die Verwendung der POST-Methode folgendermaßen aus.

Laden eines HTML-Dokumentes mit Hilfe der POST-Methode

Parameter werden in diesem Beispiel in Form von Name-Wert-Paaren hinter dem Token PARAM: angegeben. Die Werte können dabei variabel gehalten werden.

```
//POST-Methode
get_document(String keyword)
{
METHOD: POST;
URL: ”http://www.amazon.com/exec/obidos/xxxx”;
PARAM: ”keyword-query- $keyword$, mode- ”books”;
}
```

Nach Abarbeitung des Retrieval-Blocks wird das geladene HTML-Dokument an die Extraktionsschicht übergeben.

- **Die Extraktionsschicht**

  Sobald ein HTML-Dokument geladen wurde, beginnt der HTML-Parser mit der Erstellung des zugehörigen Analysebaums. Dabei handelt es sich um eine eineindeutige Zuordnung von HTML-Dokument und Analysebaum, d.h. dasselbe HTML-Dokument ist wieder aus dem Analysebaum ermittelbar und umgekehrt.
  Er besteht aus drei Bausteinen. Dabei handelt es sich um:

  – **Wurzel**
    Die Wurzel repräsentiert den Startknoten im Analysebaum und wird mit HTML bezeichet.

- **Interne Knoten**
  Geschlossene HTML-Tags werden als internen Knoten abgebildet und mit deren Namen bezeichnet. Sie kapseln Unterbäume, haben also Kinder und können Attribute besitzen. Bei dieser Art von Tags handelt es sich um die HTML-Sprachelemente, die durch Start- und Endmarke gebildet werden, wie z.B. $< table > ... < \backslash table >$
- **Blätter**
  Blätter des Analysebaums werden aus den offenen HTML-Tags gebildet und erhalten deren Namen als Bezeichnung. Ausserdem werden Textstücke auf die Blätter im Analysebaum abgebildet und mit PCDATA bezeichnet. Sie haben keine Kinder, können aber Attribute besitzen.

Zur Veranschaulichung wird der zum folgenden HTML-Dokument gehörende Analysebaum in Abbildung 2 dargestellt.

$$
\begin{array}{l}
< HTML > \\
\quad < HEAD >< TITLE > Text < \backslash TITLE > \\
\quad < BODY > \\
\quad\quad < H1 > Text < \backslash H1 > \\
\quad\quad < IMG > \\
\quad\quad < TABLE > \\
\quad\quad\quad < TR > \\
\quad\quad\quad\quad < TH > text < BR > text < \backslash TH > \\
\quad\quad\quad\quad < TH > ... < \backslash TH > \\
\quad\quad\quad\quad < TH > ... < \backslash TH > \\
\quad\quad\quad < \backslash TR > \\
\quad\quad\quad < TR > \\
\quad\quad\quad\quad < TD >< IMG >< A >< B > text < \backslash B >< \backslash A > \\
\quad\quad\quad\quad\quad\quad < BR >< IMG >< \backslash TD > \\
\quad\quad\quad\quad < TD > ... < \backslash TD > \\
\quad\quad\quad\quad < TD > ... < \backslash TD > \\
\quad\quad\quad < \backslash TR > \\
\quad\quad\quad < TR > \\
\quad\quad\quad ... \\
\quad\quad\quad < \backslash TR > \\
\quad\quad < \backslash TABLE > \\
\quad < \backslash BODY > \\
< \backslash HTML >
\end{array}
$$

Die Identifikation der Elemente des Baumes sowie der Zugriff auf diese er-

folgt über Pfadausdrücke, die aus Knotennamen, Operatoren, Indizes bzgl. der Knotennamen und Attributnamen gebildet werden. Die Indizes werden links absteigend vergeben, d.h. es wird zuerst links absteigend im Baum nach einem vorgegebenen Knotennamen gesucht und das Auftreten gezählt. Stimmen Zähler und Index überein, wurde der gesuchte Knoten gefunden. Indexwert Null adressiert das erste Auftreten.

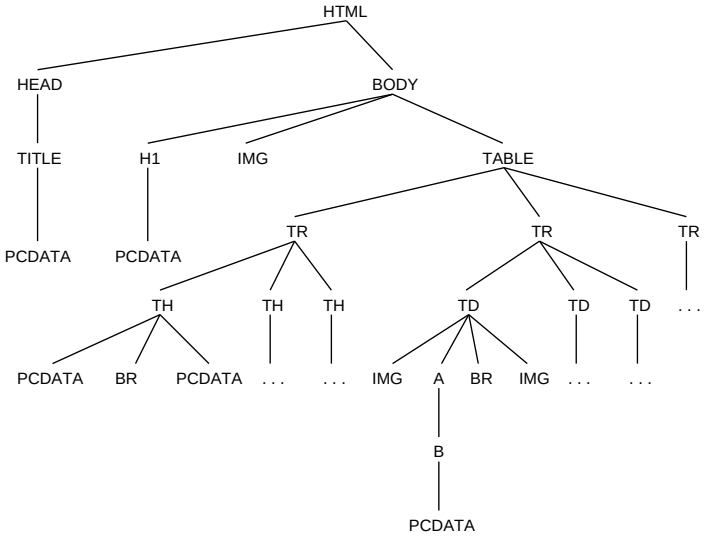

Abbildung 2: Beispiel eines HTML-Baums

Zur Bildung der Pfadausdrücke stehen zwei - entstanden aus verschiedenen Navigationsansätzen - Operatoren zur Verfügung.

– Punkt-Operator . :
Dieser Operator zeichnet sich durch die Ausnutzung der Baumstruktur aus. Hinter jedem Element im Pfadausdruck wird durch den Punkt-Operator getrennt der unmittelbare Kindknoten im Analysebaum angegeben. Damit ist es möglich zu jedem Knoten genau einen Pfadausdruck anzugeben.

Beispiele:
Pfadausdruck für den TITLE-Knoten:
$HTML.HEAD.TITLE$

Pfadausdruck zum ersten Bild-Knoten in der Tabelle:
$HTML.BODY.TABLE[0].TR[1].TD[0].IMG$

– Pfeil-Operator - $>$:
Charakteristisch für diesen Operator ist seine Orientierung am Fluss im HTML-Dokument. Ausgehend von einer Position im Analysebaum wird das nächste Auftreten des angegebenen Knotens unter Berücksichtigung des Indexes im Dokument gesucht. Dabei arbeitet er über die Hierarchie des Baumes hinweg. Für einen Knoten lassen sich mehrere Pfadausdrücke angeben.

Beispiel:
Mögliche Pfadausdrücke für das zweite Bild im BODY sind:
$HTML.BODY- > IMG[1]$
$HTML.BODY- > IMG[0]- > IMG[0]$

– Pfeil-Operator -/ $>$:
Auch dieser Operator orientiert sich am Fluss im HTML-Dokument. Im Gegensatz zum vorherigen Pfeil-Operator wird aber nur der im Pfadausdruck angegebene Teilbaum durchsucht.

Beispiel:
Pfadausdruck für das erste Bild in der zweiten Zeile der Tabelle ist:
$HTML.BODY.TABLE.TR[1] - / > IMG[0]$

Es wird nur die erste Zeile der Tabelle nach Bildern durchsucht. Ist hier kein Bild enthalten, so wird abgebrochen und im Gegensatz zum ersten Pfeiloperator, das HTML-Dokument nicht weiter durchsucht.

Eine Kombination der genannten Operatoren ist jederzeit möglich. Als Index für ein Pfadelement können auch Wildcards oder Intervalle verwendet werden, so dass mehrere Knoten das Ergebnis bilden.

Beispiele:
Alle Anker innerhalb eines HTML-Dokuments:
$HTML.BODY- > a[*]$

Alle Listenelemente der 3. bis 5. ungeordneten Liste des HTML-Dokumentes:
$HTML.BODY- > ul[2-4]- > li[*]$

Interne Knoten und Blätter können HTML-Attribute besitzen, während PCDATA-Blättern Textwerte als Attribute zugeordnet werden. Alle möglichen Eigenschaften der Knoten eines HTML-Baumes sind in Tabelle 1 beschrie-

ben.

	Wurzel	Interne Knoten	Blätter	PCDATA
Kinder	x	x	-	-
HTML-Attribute	-	x	x	-
Textwert	-	-	-	x

Tabelle 1: Eigenschaften von Knoten eines HTML-Baums

Ihre Eigenschaften können mit Hilfe spezieller Zugriffsfunktionen abgefragt werden. Dies geschieht durch das Anhängen des Punktoperators und der gewünschten Funktion an das letzte Element des Pfadausdrucks. Dabei stehen folgende Zugriffsfunktionen zur Verfügung:

- Funktion **txt** :
  Diese Funktion liefert den Textwert eines PCDATA-Blattes oder eine rekursive Verknüpfung der Textwerte im gesamten Unterbaum eines Knotens mit Kindern. Die Reihenfolge der Verknüpfung ist linksabsteigend zuerst.

  Beispiel:
  Titel des HTML-Dokumentes
  $HTML.TITLE.PCDATA.txt$

- Funktion **src** :
  Ergebnis dieser Funktion ist der HTML-Code zu einem Knoten. Die Bildung erfolgt analog zur txt-Funktion.

  Beispiel:
  Quellcode des HTML-Dokumentes
  $HTML.src$

- Funktion **getAttr**(Attributname) :
  Der Attributwert des angegebenen HTML-Attributes eines Knotens wird mit dieser Funktion zurückgegeben. Der Wurzel wird als Attribut der empfangene HTTP-Kopf zum HTML-Dokument zugeordnet.

Beispiel:
URL des HTML-Dokumentes
$HTML.getAttr(url)$

– Funktion **numberOf**(Knotenname) :
Alle Vorkommen eines Knotens im Unterbaum werden gezählt. Als Sonderfall zählt numberOf(all) alle Knoten eines Unterbaums.

Beispiel:
Anzahl aller HTML-Tags im HTML-Dokument
$HTML.numberOf(all)$

Die Anwendbarkeit der Funktionen ist in der Tabelle 2 zusammengefasst.

	Wurzel	Interne Knoten	Blätter	PCDATA
txt	x	x	-	x
src	x	x	x	x
getAttr()	x	x	x	-
numberOf	x	x	-	-

Tabelle 2: Zugriffsfunktionen der Knotentypen

Die vorgestellten Pfadausdrücke benutzt man bei der Bildung von Extraktionsregeln, die in der Sprache HEL[5] (HTML Extraction Language) spezifiziert werden. Als Ergebnis werden die Attributwerte bestimmter Knoten im intern verwendeten NSL-Format geliefert. Eine NSL (Nested String List) ist eine geschachtelte Liste von String-Listen beliebiger Tiefe. Der Datentyp NSL ist folgendermaßen definiert:
NestedStringList ::= String | listOf(Nested String List) | null .

Die Struktur einer NSL besteht aus Dimension, Tiefe und Zahl der Nestungen und wird durch die angegebenen Pfadausdrücke und deren Verknüpfungen mit HEL-Operatoren bestimmt.

Beispiel:
NSL der Form listOf(listOf(string))
$array = HTML.BODY->ul[2-4]->li[*].txt$

Weitere HEL-Sprachelemente sind die Operatoren match, split und #. Für

[5]die genaue Grammatik ist in [W4F] zu finden

weitere Informationen sei auf [W4F] verwiesen.

Der Extraktions-Block im Wrapper-Quelltext beginnt mit dem Token EXTRACTION_RULES. Es folgen die Extraktionsregeln, wobei die Variable auf der linken Seite der Extraktionsregel im Abbildungsblock deklariert sein muss, falls sie auf einen anderen Datentyp als das intern verwendete NSL-Format abgebildet werden soll.

- **Die Abbildungsschicht**
  Aufgabe der Abbildungsschicht ist die Definition des Zieldatentyps, auf den die durch Extraktionsregeln gewonnenen NSL-Konstrukte abgebildet werden sollen. Für jede Extraktionsregel wird genau eine Abbildung festgelegt. Dies geschieht durch eine Typdeklaration der Extraktionsvariable im Abbildungsblock. In [W4F] ist die genaue Grammatik zu finden.

  W4F bietet die Möglichkeit, die NSL auf Java-Standarddatentypen (String, int, float) und deren Array-Erweiterungen abzubilden.

  Beispiel:
  Abbildung der Extraktionsvariable pointers auf ein zweidimensionales String-Array
  $String[][]\ pointers;$
  Der deklarierten Variable pointers werden Verweisnamen und die URL aller Anker im Dokument zugewiesen.
  $pointers = HTML.BODY->a[*](.txt\ \#\ .getAttr(href));$

  Sollen komplexe NSL-Strukturen abgebildet werden, so muss der Nutzer eigene Java-Objekte (auch die Array-Erweiterungen) angeben, deren Konstruktor NSL verarbeiten kann. Die Konvertierung von NSL zu Java ist dann in der Konstruktorroutine zu implementieren. Weil keine Abbildungsregeln mehr spezifiziert werden, ist die Art der Abbildung nicht mehr deklarativ, sondern nur noch ein Interface.

  Beispiel:
  Die Extraktionsvariable pointers wird auf Liste von Pointer-Objekten abgebildet.
  $Pointer[]\ pointers;$
  $pointers = HTML.BODY->a[*](.txt\ \#\ .getAttr(href));$
  $//Java-Klasse\ Pointer$
  $public\ class\ Pointer$
  $\{$
  $\quad String\ name, url;$

```
    public Pointer(NestedStringListin)
    {
        nsl = (NSL_List) in;
        name = ((NSL_String) nsl.elementAt(0)).toString;
        url = ((NSL_String) nsl.elementAt(1)).toString;
    }
}
```

Die Klassen NSL_List und NSL_String werden von W4F zu Verfügung gestellt, über die der Zugriff auf die NSL-Elemente abläuft.

Mit dem Token SCHEMA beginnt im Wrapper-Quelltext der Abbildungsblock. Es folgen die Typdeklaration der Extraktionsvariablen und die Extraktionsregeln.

3.3 Probleme bei der Arbeit mit WWW-Datenquellen

Beim automatischen Abfragen von Daten aus dem WWW stösst man schnell auf Grenzen. So sind beispielsweise mit dem Einsatz von Javascript, ActiveX, Java-Applets und anderen Plugins zur Darstellung von Informationen auf WWW-Seiten diese Daten für Wrapper-Systeme verloren, da keine klare Seitenbeschreibung mehr existiert. Einzig bei Javascript, das zur Dynamisierung des sonst statischen HTML-Codes benutzt wird, ist eine Auswertung des mit übermittelten Quellcodes denkbar und somit die Ermittlung der dadurch dargestellten Informationen. Aufgrund der Komplexität dieser Scriptsprache ist aber eine Auswahl bestimmter Konstrukte erforderlich.

Selbst bei reinem HTML tauchen Probleme bei der automatisierten Datengewinnung auf. Dazu folgen einige Beispiele:

- Häufiger Layoutwechsel und teilweise fehlerhafter HTML-Code erfordern robuste und leicht anpassbare Wrapper
- Bei der Ersetzung von Text durch nicht mehr auswertbare Bilder stoßen Wrapper ebenfalls auf ihre Grenzen.
- Der Einsatz von Frames erhöht den Aufwand bei der Datengewinnung durch Wrapper, da das nach außen als Einheit wirkende HTML-Dokument aus mehreren Teilseiten besteht und diese vom Wrapper abgefragt werden müssen.
- Dynamisch durch ein Programm erzeugte HTML-Dokumente können Wrapper ebenfalls vor Probleme stellen. Beim automatischen Ausfüllen eines

HTML-Formulares kann beispielsweise eine Ergebnisseite erzeugt werden, auf die der Wrapper nicht vorbereitet ist, da dieses Ergebnis noch nie auftrat.

- Erzeugt ein Programm ein Formular mit dynamisch generierten Variablennamen, so stellt das einen Programmierer, der einen Wrapper für ein solches Formular schreiben soll, vor erhebliche Probleme.

4 Wissensbasierte Verfahren aus dem Projekt GETESS

Dieses Kapitel soll einen kurzen Überblick über das Projekt GETESS und die darin angewandten Verfahren zur Erzeugung von Informationskondensaten auf Basis von Ontologiewissen geben.

4.1 Einleitung

Ziel des Projektes GETESS (GErman Text Exploitation and Search System) ist die Realisierung eines Suchdienstes, der sich von existierenden Suchdiensten in der Hinsicht unterscheidet, dass die zu untersuchenden Texte detailliert inhaltlich analysiert werden. Dabei werden Informationskondensate (Abstracts) auf Basis von linguistischem und Ontologien-Wissen unter Verwendung einer natürlichsprachlichen Dialogschnittstelle, die es dem Nutzer erlaubt, seine Suchanfrage in natürlichsprachlichen Phrasen zu formulieren und im Dialog zu konkretisieren, gebildet. Als Ergebnis wird eine Menge von HTML-Dokumenten geliefert, deren Inhalt dem Benutzer natürlichsprachlich auf Basis der Abstracts als Zusammenfassung präsentiert wird. Die Informationen werden in relationalen Datenbanken gespeichert. Suchaufträge werden als Kombination von Information-Retrieval-Suchkommandos und Datenbankanfragen (IRQL) formuliert.
Es handelt sich um ein vom BMBF gefördertes 3-Jahres-Projekt, das von den Partnern DFKI Saarbrücken (automatische Sprachverarbeitung), Universität Karlsruhe (Konstruktion von Ontologien), GECKO mbH Rostock (Dialoggestaltung) und der Universität Rostock (Suchmaschinen mit Datenbanktechnik) getragen wird.

4.2 Die GETESS-Architektur

Die GETESS-Architektur gliedert sich in vier Hauptkomponenten: das Dialogsystem, die Datengenerierung, das Knowledge Aquisition Tool und die Suchmaschine.

- **Datengenerierung**
  Die Erstellung von Stichwort-Index und Index-Einträgen für Informationen aus Datenbanken, den sogenannten Abstracts, ist die Aufgabe der Datengenerierung. Als Eingabe dienen sowohl Textdokumente (HTML, PS, RTF, ...) als auch verschiedene Arten von Datenbanken.

- **Abstracts**
  Das grundlegende Element des GETESS-Systems bilden die sogenannten

Abstracts. Sie stellen neben dem herkömmlichen Stichwort-Index die Suchbasis des Systems dar. Ein Analysesystem (Abstract-Generator) zwischen Suchmaschine und Informationen sorgt für die Kondensation der Informationen in sprachunabhängige, gewichtete Zusammenfassungen, den Abstracts. Die Ontologie nimmt als Basis der Abstract-Generierung eine wichtige Stellung ein. Die so generierten Abstracts dienen als Basis und Ergebnis der Suchanfragen. Wenn man eine Suchmaschine fürs Internet erstellt, geht man davon aus, dass sehr viele Informationen vorhanden sind und somit eine große Menge von Abstracts generiert werden müssen. Das bedeutet, dass Datenbanken für eine effiziente Speicherung und einen schnellen Zugriff verantwortlich sind.

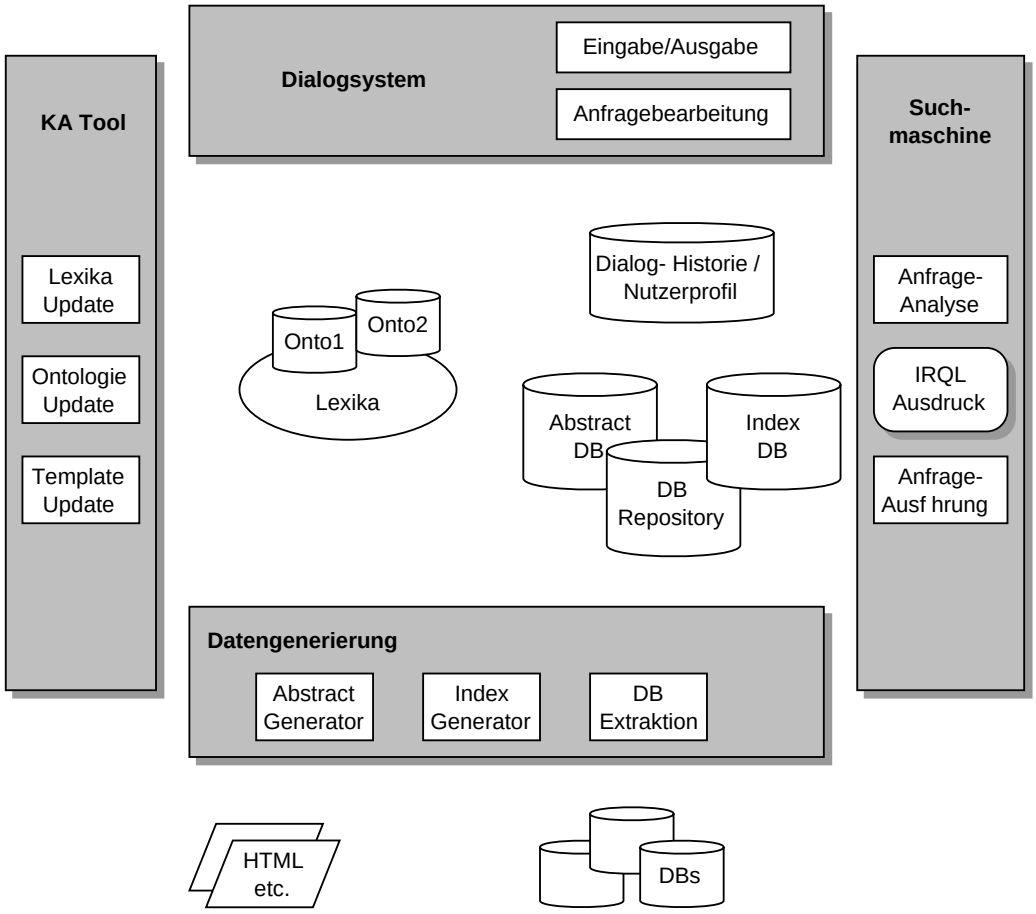

Abbildung 3: GETESS-Architektur

- **Dialogsystem**
  Sprachspezifische und domainspezifische Informationen aus einer Ontologie

werden verwendet, um eine Suchanfrage zu erstellen und beantworten. Es wird angestrebt, den Benutzer in seiner Suchbeschreibung zu führen, d.h. eine Suchanforderung zu erstellen, die seine Wünsche hinsichtlich Umfang und Qualität der Information spezifiziert. Durch das Anbieten von Ober- und Unterbegriffen wird beispielsweise eine Eingrenzung des Suchraums erreicht. Eine bessere Spezifizierung des Suchvorgangs wird durch eine Aushandlung treffender Ober- und Unterbegriffe im Dialog erreicht. Dies ist hilfreich, wenn dem Benutzer keine treffenden Suchbegriffe einfallen oder ihm im Dokument verwendete Begriffe nicht bekannt sind. Der Einsatz von Dialoghistorie und Benutzer-Profile ermöglicht einen zielgerichteten Dialog zur Klärung bzw. zur Konkretisierung der Suchanfragen.

- **Knowledge Aquisition Tool**
  Zur Aktualisierung des GETESS-Wissens wurde das Knowledge Aquisition Tool entwickelt. Diese kann durch häufige Nutzer-Anfragen zu einem spezifischen Thema oder neue Dokumente initiiert werden und zu einer Anpassung der Ontologie, der verwendeten Lexika für die Analyse der natürlichen Sprache führen.

- **Ontologie**
  Die zentrale Stellung im GETESS-System nimmt die Ontologie ein. Sie beschreibt eine konkrete Domäne, welche beispielhaft für Tourismus und Finanzinfos umgesetzt wurde. Die Vorgabe des Kontext-Wissens zur Abstract-Bildung und die Auflösung von linguistischen Mehrdeutigkeiten sind Aufgaben der Ontologie. Sie wird auf Basis einer definierten Menge von Internet-Informationen entwickelt und ständig weiterentwickelt. Die Beschreibung, wie die Abstracts in die Datenbank gespeichert werden, ist ebenfalls Aufgabe der Ontologie.

4.3 Ontologie und Domainlexikon

Wie schon mehrfach erwähnt, nehmen die Ontologie und das Domainlexikon innerhalb des Projektes GETESS eine herausragende Stellung ein. In diesem Kapitel sollen ihre Aufgaben verdeutlicht werden.

Als Ontologie wird in GETESS eine Menge von Begriffen verstanden, die über inhaltliche Beziehungen zueinander geordnet sind. So ist beispielsweise **Unterkunft** ein Oberbegriff für **Hotel**, **Jugendherberge** oder auch **Pension**. Bei der Ontologieentwicklung wurden zwei wesentliche Ziele verfolgt. Zum einen stellt das Ontologiesystem Dienste zur Verfügung, die von anderen Modulen des GETESS-Systems genutzt werden. Zum anderen wirkt die Modellierung aber auch strukturgebend auf die Datenbankschemata der anderen Module und dient damit als seman-

tisches Bindeglied zwischen Front-End und Back-End. Konkret lassen sich diese beiden Verwendungszwecke anhand der Interaktionen mit den anderen Modulen des GETESS-Systems beschreiben:

- Interaktion mit dem Modul für die Analyse natürlichsprachlicher Eingaben:

  Natürlichsprachliche Anfragen und das Parsen von Texten liefern syntaktische Beziehungen zwischen Worten und Phrasen. Diese liefern Hinweise darüber, welche Objekte inhaltlich relationiert werden sollen. Klärung, ob und wie aufgrund der inhaltlichen Zusammenhänge relationiert werden kann, ist Aufgabe der Ontologie.
  Beispiel:
  Die Phrase **Rostocker Rathaus** wurde in einem Text erkannt und eine syntaktische Beziehung **Rostocker** und **Rathaus** festgestellt. Durch Abfrage der Ontologie wird jetzt festgestellt, ob aus Sicht der Ontologie eine semantische Relationierung zwischen **Rostock** und **Rathaus** möglich ist.

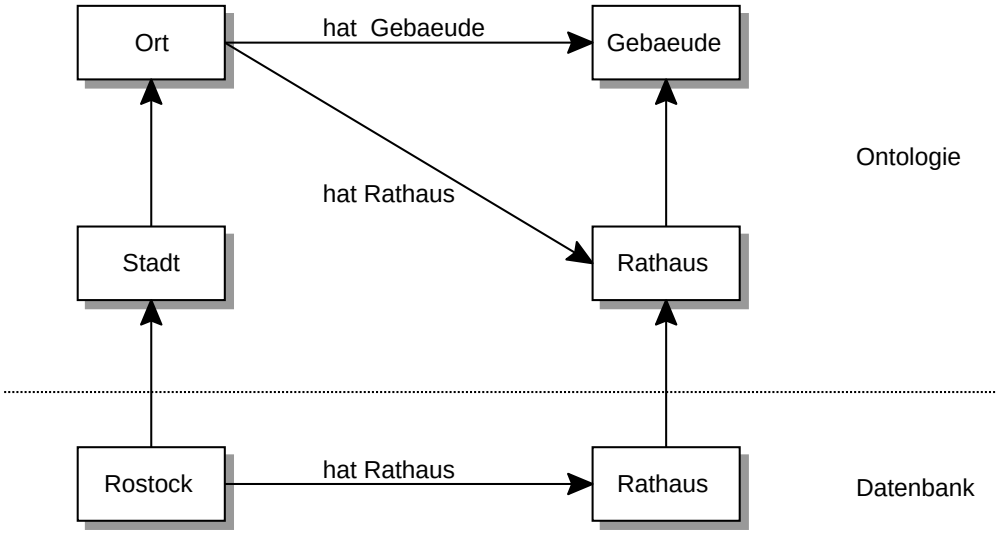

Abbildung 4: Semantische Relationierung textueller Informationen

Es wird ein Eintrag für den Begriff **Rostock** im Lexikon gefunden, der einen Verweis auf einen Eintrag in der Datenbank enthält. Es ist bekannt, dass dieses Objekt eine Instanz der Klasse **Stadt** und diese wiederum in der Ontologie definiert ist. Für **Rathaus** ist wiederum ein ähnlicher, direkter Verweis auf die in der Ontologie beschriebene allgemeine Klasse von Rathäusern definiert. Über die Ontologie erfolgt nun die Suche nach sinnvollen semantischen

Relationierungen zwischen **Rostock** und **Rathaus**. Für den in Abbildung 4 angegebenen Ausschnitt aus der Ontologie werden zwei Relationierungen gefunden. Das ist zum einen die Relation **hat Gebaeude** und zum anderen die Relation **hat Rathaus**. Die Beschreibungen dieser Relationen werden von der Klasse Ort an die Klasse Stadt vererbt. Da es sich bei der Relation **hat Rathaus** um die speziellere handelt, wird sie als sinnvollere Alternative angesehen und als Ergebnis zurückgegeben. **Rostock** und **Rathaus** werden als Ergebnis der Ontologieabfrage über **hat Rathaus** relationiert und diese Information mit in die Abstract-Datenabnk eingebracht.

- Interaktion mit dem Datenbanksystem:

  Wie schon erwähnt, bestimmt die Ontologie, wie die aus den Texten generierten Abstracts und damit die im Datenbanksystem zu speichernden semantischen Relationierungen aussehen. Dies muss sich natürlich in den Klassenbeschreibungen des Ontologiemodells im Datenbankschema niederschlagen. Andererseits ist es so, dass das Datenbanksystem das Ontologiesystem zu Hilfe nehmen kann, um Inferenzen durchführen zu lassen.

- Interaktion mit dem Dialogsystem:

  Neben natürlichsprachlichen Anfragen kann das Wissen der Ontologie natürlich auch direkt über grafische Schnittstellen dem Benutzer zur Verfügung gestellt werden, um interessante Informationen zu liefern. Die Schnittstelle kann benutzt werden, um über Mausklicks komplexe Anfragen zusammzustellen. Je nach Versiertheit mit dem System kann der Benutzer die für ihn effizienteste Anfragemethode wählen. Dies wird zunächst eine einfache natürlichsprachliche Anfrage sein, allerdings bieten bei zunehmendem Wissen die in der Ontologie modellierten Konzepte einen möglicherweise einfacheren, da zielgerichteteren, Zugang zum System.

Wie es in den Erlärungen zur Ontologie bereits angeklungen ist, wird durch das Parsen von Texten eine syntaktische Beziehung zwischen Worten und Phrasen erkannt. Dies geschieht in GETESS auf der Basis des flachen Textverarbeitungssystems SMES. SMES wurde am DFKI im BMBF-Projekt PARADIME entwickelt. In SMES wird eine systematische Trennung zwischen domainunabhängiger linguistischer Kernfunktionalität und domainspezifischer Templateverarbeitung verfolgt. Die Kernkomponenten umfassen: Textscanner, eine schnelle und effiziente Morphologiekomponente (inklusive Behandlung von Komposita und robustem Lexikonzugriff, Performanz: 5000 Wörter/Sek.), ein Chunk-Parser auf der Basis kaskadierter endlicher Automaten und Methoden zur Templategenerierung. SMES

verfügt über umfangreiche linguistische Wissensquellen (über 150.000 Lemata, Grammatiken zur Erkennung von Eigennamen, generische Nominal- und Präpositionalphrasen und eine Satzgrammatik mit einem Subkategorisierungslexikon von über 15.000 Einträgen). SMES ist in eine Client/Server-Architektur integriert, die eine schnelle und einfache Verfügbarkeit neuer Funktionalitäten erlaubt. Für das Projekt GETESS wurden die linguistischen Wissensquellen von SMES um für die GETESS-Domäne relevante Quellen erweitert. Ein Schwerpunkt lag dabei in der Integration von Domainwissen in die flache Textverarbeitung. Dazu waren folgende Schritte nötig:

- Definition der Abbildung von Lexikoneinträgen und terminalen Elementen der Ontologie,
- Erweiterung der Grammatiken um eine domainspezifische Schnittstelle.

Das Domainlexikon als Schnittstelle zur Ontologie wird mittels einer einfachen ASCII-basierten Schnittstelle realisiert. Auf Basis dieser ASCII-Schnittstelle wurden einige Perl-Programme definiert, welche eine automatische Konvertierung in eine STP(flache Textanalysekomponente von SMES)-interne Lisprepräsentation vornehmen. Das Format des Domainlexikons ist sehr einfach aufgebaut. Ein Lexikoneintrag beschränkt sich jeweils auf eine einzige Zeile. Diese ist in vier Spalten unterteilt. Die Trennung der Spalten erfolgt durch Hash(#). Die erste Spalte enthält den Stamm des Wortes, die zweite seine Kategorie, die dritte das zugehörige Konzept und die vierte Spalte kann, falls vorhanden, die Slotangabe enthalten. Ist ein Wort zwei oder mehr Konzepten zuzuordnen, so wurde der Eintrag mehrfach vorgenommen. Die Auflistung der Eintragungen erfolgt in alphabetischer Reihenfolge der Stämme. Ein Ausschnitt aus dem Domainlexikon ist in der folgenden Abbildung verdeutlicht.

```
klimaanlage       # N    # :zimmer          # :ausstattung
konferenzraum     # N    # hotel           # konferenzausstattung
konferenzraum     # N    # gasthof         # konferenzausstattung
kost              # V    # :preis_auskunft
minibar           # N    # :zimmer          # :ausstattung
```

Abbildung 5: Ausschnitt aus dem Domainlexikon

In der flachen Textanalyse selbst, übernimmt ein Chunk-Parser die syntaktische Analyse von morphologisch analysierten Wortsequenzen. Ein Chunk-Parser besteht aus einem System von Modulen. Jedes Modul besteht aus einer Grammatik zur Analyse eines bestimmten Phrasentyps, z.B. Nominalphrasen, Prepositionalphrasen oder Verbgruppen. Die Grammatiken sind uniform als endliche Automaten

kodiert, um die angestrebte Robustheit und Effiziens zu erreichen. Nach dem Parsingprozess werden alle Phrasen ausgefiltert, die keine Beziehung zum Domainlexikon haben. Weiterführende Informationen sind unter anderem in den Publikationen [MS1], [MS2], [MS3] und [GE99] zum Projekt zu finden.

5 Kombination von Wrappermethoden und Ontologiewissen

Ziel dieser Studienarbeit ist es, Methoden zu entwickeln, die HTML-Dokumente um beschreibende Metadaten anreichern. Dabei soll eine Kombination von Wrappermethoden und wissensbasierten Verfahren aus dem Projekt GETESS eingesetzt werden.

5.1 Konzept zur Kombination

Das Anreichern von HTML-Dokumenten um beschreibende Metadaten erfolgt prinzipiell in drei Schritten: dem Laden lokaler oder im WWW liegender HTML-Dokumente, dem Wrappen von Daten und anschließender Datenextraktion auf Basis von Ontologiewissen. Die Ergebnisse werden im Dokument als Metadaten gespeichert.
Der Benutzer hat die Möglichkeit, die um Metadaten anzureichernden HTML- Dokumente lokal von seinem Rechner oder aus dem WWW zu laden. Es dient dann als Eingabe für den Wrapper, welcher Metainformationen, die sich aus der Struktur des HTML-Dokumentes ableiten lassen, extrahiert. Außerdem wird sämtlicher Textinhalt extrahiert, bearbeitet und mit dem Ontologiewissen verglichen. In Text und Ontologie vorkommende Daten werden zu Metadaten. Sowohl die gewrappten als auch die über das Ontologiewissen gewonnenen Metadaten werden ins HTML-Dokument eingefügt und lokal gespeichert. Die prinzipielle Vorgehensweise ist in der folgenden Abbildung dargestellt.

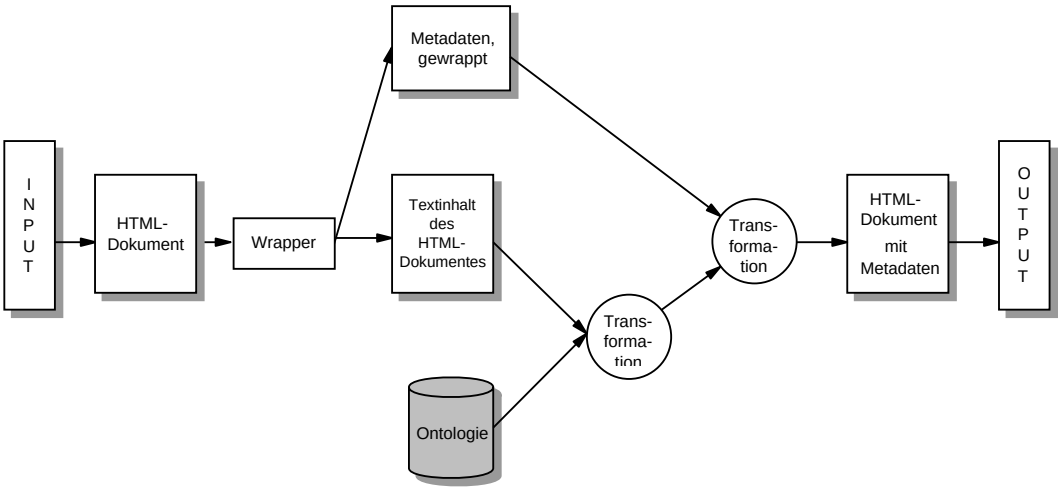

Abbildung 6: Prinzip der Kombination von Wrappermethoden und wissensbasierten Verfahren

Nach der oben beschriebenen Konzeption wird im folgenden Abschnitt eine prototypische Implementierung vorgestellt.

5.2 Prototypische Implementierung anhand der Beispieldomäne ”Geschichte Mecklenburg-Vorpommerns”

Ein wichtiger Aspekt bei der Implementation des vorgestellten Konzeptes war die Suche nach einer geeigneten Domäne. Aufgrund des Vorhandenseins von Beispieldokumenten zur **Geschichte Mecklenburg-Vorpommerns** wurde diese Thematik für den Aufbau einer Ontologie und somit als Wissensbasis zugrunde gelegt. Den genauen Aufbau der Ontologie entnehme man später folgeneden Erläuterungen. Die verwendeten Beispieldokumente wurden aus einer Distribution zur **Geschichte Mecklenburg-Vorpommerns** entnommen.
In den folgenden Abschnitten wird die Beispielimplementation näher erläutert und auf vorkommende Besonderheiten eingegangen. Nach dem Start der Applikation hat der Benutzer die Möglichkeit zu entscheiden, von welchem Ort ein HTML-Dokument geladen werden soll. Das HTML-Dokument kann von einem lokalen Speichermedium oder aus dem WWW geladen werden. Das erhaltene HTML-Dokument wird an einen Wrapper gegeben und durch diesen verarbeitet. In Anhang-A sind der Quelltext der entsprechenden Wrapper-Spezifikation und in Anhang-B der Quelltext der daraus generierten java-Klasse zu finden. Durch den Wrapper werden Metadaten, die sich direkt aus der Struktur des HTML-Dokumentes ableiten lassen, ausgelesen. Exemplarisch wurde dies anhand der Auswertung des TITLE-Tags implementiert. Anschließend wird der gesamte textuelle Inhalt des

HTML-Dokuments in einer (NSL_List) gesammelt und übergeben. Nun werden die Token jeden Listenfeldes separiert und in einem SET gespeichert. Dieser Datentyp wurde gewählt, um doppelte Einträge zu vermeiden. Desweiteren wurde als Methode des Information Retrieval eine Stoppwortliste angelegt, um Füllwörter wie beispielsweise an, als, und, der, die, das, ... zu entfernen und so die Größe des SETs ”maximal” zu minimieren. Um einen kontrollierten Zugriff auf den Inhalt des SETs zu garantieren, wird es in ein ARRAY umgewandelt. Damit wurde der Textinhalt des HTML-Dokumentes für eine Verarbeitung durch die Ontologie vorbereitet.

Aufbau der Ontologie
In der Ontologie werden Begriffe einander zugeordnet, die in inhaltlicher Beziehung zueinander stehen. Diese Begriffe werden als Konzepte bezeichnet und als Baumhierarchie in einer Tabelle gespeichert. Das Prinzip ist in der folgenden Abbildung verdeutlicht.

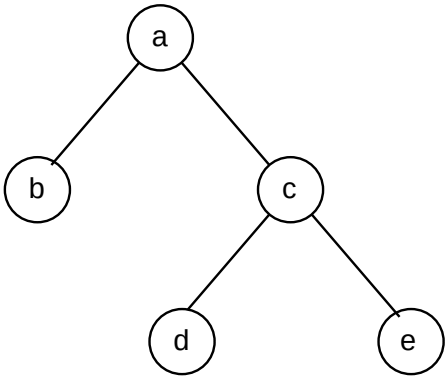

Ontologie als Baumstruktur

Konzept	Vorgaenger
a	-
b	a
c	a
d	c
e	c

Speicherung der Ontologie in Tabelle

Abbildung 7: Aufbau und Speicherung der Ontologie

Anstatt eine lexikalische und morphologische Analyse der HTML-Dokumente mit Hilfe einer umfangreichen Grammatik durchzuführen, wird eine zweite Tabelle angelegt, die als Lexikon und Morphologie fungiert und die möglichen Ausprägungen der einzelnen Konzepte enthält. Als Ausprägung eines Wortes werden z.B. die verschiedenen Zeit-, Personen-, Kasus-, und Komparationsformen verstanden. Die Tabelle dient als Schnittstelle zwischen Textinhalt und Ontologiewissen. Der prinzipielle Aufbau ist in der folgenden Tabelle demonstriert.

Auspraegung	Konzept
a1	a
a2	a
a3	a
b1	b
b2	b
c1	c
d1	d
d2	d

Abbildung 8: Prinzip der Speicherung von Ausprägungen zu einzelnen Konzepten

Die konkreten Tabellen zur Beispieldomäne sind im Anhang-F und Anhang-G zu finden.

Wie oben beschrieben, wurden sämtliche Token des Textes des zu analysierenden HTML-Dokumentes in einem Array gespeichert. Nun werden alle Elemente des Arrays durchlaufen und mit den Inhalten der Ausprägungstabelle verglichen. Wird ein Element gefunden, welches gleichzeitig eine Ausprägung eines Konzeptes in der Tabelle darstellt, so wird das zugehörige Konzept ermittelt. Dieses dient in der Ontologiehierarchie als Einstiegspunkt. Jetzt wird in der Hierarchie bis zur Wurzel gegangen, wobei jeder zwischen Wurzel und Konzept vorkommende Knoten mit in eine Konzeptliste aufgenommen wird. Zu Metadaten werden somit sämtliche im Text gefundenen Ausprägungen und die dazu aufgestellte Konzeptliste. Nachteil dieser Art der Analyse ist, dass es unmöglich ist, Mehrdeutigkeiten zu erkennen, da nur das Vorkommen von Ausprägungen überprüft wird, aber nicht deren inhaltliche Bedeutung.

Ergebnis der Analyse des HTML-Dokumentes sind zwei Arten von Metadaten. Dies sind einerseits die gewrappten und andererseits die mit Hilfe von Ontologiewissen gewonnenen. Sie werden in der anschließend beschriebenen Form in den Header des HTML-Dokumentes eingefügt. Beide Arten von Metadaten haben das Attribut **name**, welches beschreibt, um welche Sorte es sich handelt. Bei den gewrappten Metadaten folgt das Attribut **Titel**, welches den Inhalt des TITLE-Tags repräsentiert. Die mit Hilfe der Ontologie gewonnenen Metadaten hingegen besitzen zwei weitere Attribute. Das Attribut **Originaltext** beschreibt eine im Dokument

vorkommende Ausprägung eines Konzeptes und das Attribut **Ausprägung_von** die zugehörige Konzeptliste.
Im angereicherten HTML-Dokument sieht dies folgendermaßen aus:

```
<html>
<head>

<meta name ="Metadaten_gewrappt" Titel="Mecklenburg von 1815 bis 1847">

<meta name ="Metadaten_aus_Ontologiewissen" Originaltext ="Neustrelitz"
Ausprägung_von ="stadt:land:region:geschichtsereignis">

<meta name ="Metadaten_aus_Ontologiewissen" Originaltext ="Landesherren"
Ausprägung_von ="herrscher:herrschaftsform:politik:geschichtsereignis">

...

</head>
```

Dem Anwender wird die Möglichkeit gegeben, den Quelltext des mit Metadaten angereicherten HTML-Dokumentes zu manipulieren und es anschließend zu speichern.
Die Quelltexte der java-Klassen, die das oben Beschriebene realisieren, sind in den Anhängen zu finden.

6 Ausblick

Da es sich bei dem in dieser Studienarbeit implementierten Ansatz zur Anreicherung von HTML-Dokumenten um beschreibende Metadaten durch Kombination von Wrappermethoden und wissensbasierten Verfahren um einen Prototypen handelt, sind logischerweise noch einige Schwächen vorhanden, deren Eliminierung eine Verbesserung der Qualität der Implementation darstellen würde. Beispielsweise wäre es denkbar, durch den Einsatz von Grammatiken Mehrdeutigkeiten aufzulösen oder Sinnzusammenhänge zu erkennen. Eine verbesserte syntaktische und morphologische Analyse der Texte wäre mit Hilfe eines umfangreicheren Lexikons vorstellbar. Aber auch schon während des Wrappens sind durchaus Mankos vorhanden. Eine stärkere Einbeziehung der Dokumentenstruktur beim Wrappen wäre nur ein Beispiel. Man könnte eventuell dem Anwender die Möglichkeit geben, eigene Extraktionsregeln zu schreiben und so das Ergebnis des Wrappens dynamisch seinen Erfordernissen anzupassen.
Als weiterführende Projekte wären Szenarien denkbar, die die gewonnenen Metadaten nutzen um die analysierten HTML-Dokumente weiter zu verarbeiten, beispielsweise in Datenbanken zu speichern.

7 Anhänge

7.1 Anhang A — Wrapper-Spezifikation.

```
SCHEMA
{
String titel;
}

EXTRACTION_RULES
{
titel = html.head.title.txt;
inhalt = html->pcdata[*].txt;
}

RETRIEVAL_RULES{
get(String url)
{
METHOD: GET ;
URL: "$url$" ;
}
}
```

7.2 Anhang B — Quelltext für die generierte Wrapper-Klasse.

```
/************************************************

         class schu

  This class was generated automatically by W4F

************************************************/

/*************************/
/** user defined JAVAHEAD */
/*************************/


import java.io.* ;
import java.net.* ;
import java.util.* ;

import edu.upenn.w4f.binop.* ;
import edu.upenn.w4f.conditions.* ;
import edu.upenn.w4f.nsl.* ;
import edu.upenn.w4f.util.* ;
import edu.upenn.w4f.htmlpath.* ;
import edu.upenn.w4f.parser.* ;
import edu.upenn.w4f.parser.html.* ;
import edu.upenn.w4f.mapping.xml.*;


public class schu {


/*************************/
/**   type declarations   */
/*************************/

  public NestedStringList inhalt ;
  public String titel ;

  HtmlPath inhalt__extract_1 ;
  HtmlPath titel__extract_1 ;



//
// No mapping defined
//
/*******************************/
/**   Retrieval method 0       */
/*******************************/
   static schu get(String url) throws IOException,
   UnknownHostException, edu.upenn.w4f.parser.ParseException {
    String __url ;
    RetrievalAgent __ra = new RetrievalAgent() ;

    __url = url ;

    return new schu(__ra, __url ) ;
  }
```

```
/*************************/
/**      Constructor 1    */
/*************************/
  public schu(DataInputStream __in, Hashtable __header) throws IOException,
  UnknownHostException, edu.upenn.w4f.parser.ParseException {
    HtmlParser __hp = new HtmlParser() ;
    HtmlNode __root = __hp.parse(__in) ;
    __root.addAttributes(__header) ;

    HtmlPathParser __hpp = new HtmlPathParser() ;
    int __i ;
    Condition __conditions[] ;

    // loading extraction rules
    __conditions = null ;
    titel__extract_1 = __hpp.parseCorrectPath(".head[0].title[0].text", __conditions) ;

    __conditions = null ;
    inhalt__extract_1 = __hpp.parseCorrectPath("->pcdata[0-].text", __conditions) ;



    // building object
    try {
      inhalt = (inhalt__extract_1.getNSLFrom(__root)) ;
    } catch (edu.upenn.w4f.htmlpath.NoSuchElementException e1) {
      inhalt = null ;
    }


    try {
      titel = NslToJava.to_String(titel__extract_1.getNSLFrom(__root)) ;
    } catch (edu.upenn.w4f.htmlpath.NoSuchElementException e1) {
      titel = NslToJava.default_String() ;
    }


  }

/*************************/
/**      Constructor 2    */
/*************************/
  public schu(RetrievalAgent ra, String url) throws IOException,
  UnknownHostException, edu.upenn.w4f.parser.ParseException {
    this(ra.GET(url), ra.header) ;
    ra.close() ;
  }

/*************************/
/**      Constructor 3    */
/*************************/
  public schu(RetrievalAgent ra, String url, String postdata, String extraHeader)
  throws IOException, UnknownHostException, edu.upenn.w4f.parser.ParseException {
    this(ra.POST(url, postdata, extraHeader), ra.header) ;
    ra.close() ;
  }

/*************************/
/**       toString        */
/*************************/
  public String toString() {
    String result = new String() ;
```

```
    result += "inhalt : " + inhalt + "\n" ;
    result += "titel : " + titel + "\n" ;
    return result ;
}

/***********************************/
/**    user defined JAVACODE below    */
/***********************************/

}
```

7.3 Anhang C — Quelltext für die Swing-Oberfläche.

```
import java.awt.event.*;
import java.awt.*;
import javax.swing.*;
import javax.swing.text.*;
import java.util.*;
import java.lang.*;
import java.io.*;
import javax.swing.filechooser.*;
import javax.swing.text.html.* ;
import java.net.*;

//interface des metadatengenerators
public class swing_main extends JFrame
{
//variablendeklarationen
static final String RED = "Red";
static final String BLACK = "Black";
static private final String newline = "\n";
static private Writer out;
private String indentString = "    ";
private int indentLevel = 0;

java.lang.String ext;
        JTextArea log;
JPanel contentPane;
JFileChooser fc;
JMenuBar menu;
JMenu datei, parse;
JMenuItem punkt1, punkt2, punkt3;
JScrollPane scrollPane, scrollPane1;
JButton knopf, knopf2;
JTextPane mypane,mypane1;
StringBuffer Text;
String ende1, ausgabe, inputValue, rüber;
File file;
DefaultStyledDocument doc,doc1;
String[] liste;

//swing interface
public swing_main()
{

super("Tool zur Anreicherung von Webseiten um beschreibende Metadaten");

//Erstellen eines Frames
setSize(800,600);

     // styles der schriftarten festlegen
final Hashtable paraStyles;

paraStyles = new Hashtable();
SimpleAttributeSet attr = new SimpleAttributeSet();

attr = new SimpleAttributeSet();
StyleConstants.setForeground(attr, Color.red);
paraStyles.put(RED, attr);

final AttributeSet bigStyle =  (AttributeSet) paraStyles.get(RED);
final AttributeSet normalStyle =  (AttributeSet) paraStyles.get(BLACK);
```

```
//der ganze Swing - Kram
log = new JTextArea(5,20);
        log.setMargin(new Insets(5,5,5,5));
        log.setEditable(false);
        JScrollPane logScrollPane = new JScrollPane(log);

contentPane = new JPanel();
  fc = new JFileChooser();

menu = new JMenuBar();
datei = new JMenu("Datei");
punkt1 = new JMenuItem("lokale Webseite laden");
punkt2 = new JMenuItem("Webseite laden");
punkt3 = new JMenuItem("Exit");
knopf = new JButton("File Parsen");
knopf2 = new JButton("save File");
knopf2.setEnabled(false);

//das linke JTextPane
doc = new DefaultStyledDocument();
mypane = new JTextPane (doc);
scrollPane = new JScrollPane(mypane);
JViewport vp =  scrollPane.getViewport();
vp.add(mypane);
scrollPane.setPreferredSize(new Dimension(380,500));

//das rechte JTextPane
doc1 = new DefaultStyledDocument();
mypane1 = new JTextPane (doc1);
scrollPane1 = new JScrollPane(mypane1);
JViewport vp1 =  scrollPane1.getViewport();
vp1.add(mypane1);
scrollPane1.setPreferredSize(new Dimension(380,500));

//wenn aktuelle File geparsed werden soll
knopf.addActionListener(new ActionListener()
{
public void actionPerformed(ActionEvent c)
{
try
{
//instanz von metadaten_main und speicherung des ergebnisses in liste
metadaten_main schu = new metadaten_main();

//pfadnamen umformen, falls lokal
//rüber --> dokumentadresse
rüber = rüber.replace('\\','/');
System.out.println("übergebene Adresse: "+rüber);
liste = schu.toParseFile(rüber);

//bei erfolg, save - button aktivieren
knopf2.setEnabled(true);
}
catch (Exception a)
{
System.out.println("Fehler mit Adresse ist aufgetreten: " + a);
}

try
{
doc1.remove(0,doc1.getLength());
}
catch (BadLocationException v1)
```

```
{
System.out.println("Fehler beim Leeren des Textpanes ist aufgetreten: " + v1);
}

try
{
int leng1 = liste.length;
  int c1 = 0;
//festlegen an welche stelle die metadaten eingetragen werden
int InsertAnStelle = ext.indexOf("<head>");
if (InsertAnStelle == -1)
{
InsertAnStelle = ext.indexOf("<HEAD>");
}
System.out.println(InsertAnStelle);
String begin = ext.substring(0,InsertAnStelle+6);
String restText = ext.substring(InsertAnStelle+7);
doc1.insertString(doc1.getLength(),begin+"\n", normalStyle);
doc1.insertString(doc1.getLength(),"<meta name =\"Metadaten_gewrappt\"
Titel=\""+liste[leng1-1]+ "\">\n", bigStyle);
for (c1=0; c1<(leng1-1); c1++)
{
doc1.insertString(doc1.getLength(),liste[c1]+"\n", bigStyle);
}

doc1.insertString(doc1.getLength(),restText, normalStyle);
mypane1.setCaretPosition(0);
}
catch (BadLocationException s)
{
System.out.println("Fehler beim Füllen des Textpanes ist aufgetreten: " + s);
}
}

});

//File lokal speichern
knopf2.addActionListener(new ActionListener()
{
public void actionPerformed(ActionEvent c)
{
int returnVal = fc.showSaveDialog(swing_main.this);

if (returnVal == JFileChooser.APPROVE_OPTION)
{ File file = fc.getSelectedFile();

                    //this is where a real application would save the file.
                    log.append("Saving: " + file.getAbsolutePath() + "." + newline);
try
{

System.out.println("Speichere in: " + file.getAbsolutePath());
FileWriter ausgabestrom = new FileWriter(file.getAbsolutePath());
ausgabestrom.write(mypane1.getText());
ausgabestrom.close();
}
catch (Exception l)
{
System.out.println("Fehler beim Speichern ist aufgetreten: " + l);
}
                }
else
{
```

```
                    log.append("Save command cancelled by user." + newline);
                }
}

});

//WebFile wird geladen
punkt2.addActionListener(new ActionListener()
{
public void actionPerformed(ActionEvent e)
{
knopf2.setEnabled(false);
//Dialog zur Fileauswahl
JOptionPane bla = new JOptionPane();
inputValue = JOptionPane.showInputDialog("Bitte eine vollständige URL eingeben");
                try
{
doc.remove(0,doc.getLength());
doc1.remove(0,doc1.getLength());
}

catch (BadLocationException v)
{
System.out.println("folgender Fehler ist aufgetreten URL: " + v);

}

System.out.println(inputValue);
/*if (inputValue.equals("") == true)
{
//custom title, error icon
JOptionPane.showMessageDialog(bla,
     "Du musst schon was eingeben um weiter zu kommen!",
     "Fehler",
     JOptionPane.ERROR_MESSAGE);


System.out.println(inputValue);

}*/
//zu überprüfende url wird gesetzt
rüber = inputValue;
  try
{
//dateitextinhalt wird gelesen
Text = new StringBuffer();
/*URL verb = new URL(inputValue);
         BufferedReader eingabestrom = new BufferedReader(
new InputStreamReader(verb.openStream()));

         String inputLine;

         while ((inputLine = eingabestrom.readLine()) != null)
Text.append(inputLine);
             eingabestrom.close();
    */
URL verb = new URL(inputValue);
        URLConnection conn = verb.openConnection();
        BufferedReader eingabestrom = new BufferedReader(
                                new InputStreamReader(
                                conn.getInputStream()));
        String inputLine;
```

```
        while ((inputLine = eingabestrom.readLine()) != null)
{System.out.println(inputLine);System.out.println(inputLine);
Text.append(inputLine);
}
eingabestrom.close();


//bei erfolgreichem einlesen wird parseknopf aktiviert
knopf.setEnabled(true);


// Insert into pane
try
{
ext= Text.toString();
doc.insertString(doc.getLength(),ext, normalStyle);
mypane.setCaretPosition(0);
  }
catch (BadLocationException s)
{
System.out.println("Fehler beim Datei einlesen ist aufgetreten: " + s);
}
}
catch (IOException n)
{
knopf.setEnabled(false);
knopf2.setEnabled(false);
System.out.println("folgender Fehler ist aufgetreten:buffer " + n);
JOptionPane.showMessageDialog(bla,
     "Fehlerhafte Eingabe!",
     "Fehler",
     JOptionPane.ERROR_MESSAGE);
    //knopf.setEnabled(false);
//knopf2.setEnabled(false);
}

mypane.setEditable(false);
contentPane.add(scrollPane);
contentPane.add(scrollPane1);
contentPane.add(knopf);
contentPane.add(knopf2);
         setContentPane(contentPane);
}
});

//lokales File wird geladen
punkt1.addActionListener(new ActionListener()
{
public void actionPerformed(ActionEvent e)
{
//Dialog zur Fileauswahl
knopf2.setEnabled(false);
knopf.setEnabled(true);
int returnVal = fc.showOpenDialog(swing_main.this);

if (returnVal == JFileChooser.APPROVE_OPTION)
{
                file = fc.getSelectedFile();
    System.out.println(file.toString());

try
{
doc.remove(0,doc.getLength());
```

```
doc1.remove(0,doc1.getLength());
}

catch (BadLocationException v)
{
System.out.println("folgender Fehler ist aufgetreten: " + v);
}
try
{
System.out.println("die ausgesuchte datei ist : " + file);

try
{
rüber = file.getPath().toString();
FileReader eingabestrom = new FileReader(file);
int gelesen;
Text = new StringBuffer(10);
boolean ende = false;

// lese Zeichen, bis Dateiende erreicht worden ist
while (!ende)
{
gelesen = eingabestrom.read();

if (gelesen == -1)
ende = true;
else
Text.append( (char) gelesen);
}

// Datei wieder schliessen
eingabestrom.close();
ext = Text.toString();

// Insert into pane
try
{
doc.insertString(doc.getLength(),ext, normalStyle);
mypane.setCaretPosition(0);
  }
catch (BadLocationException s)
{
System.out.println("folgender Fehler ist aufgetreten: " + s);
}
}
catch (IOException n)
{
System.out.println("folgender Fehler ist aufgetreten: " + n);
}
}
catch(Exception f)
{
System.out.println("Da ist wohl was mit der Fileanzeige schief gelaufen!" + f);
}

mypane.setEditable(false);
contentPane.add(scrollPane);
contentPane.add(scrollPane1);
contentPane.add(knopf);
contentPane.add(knopf2);
         setContentPane(contentPane);

//this is where a real application would open the file.
```

```
                log.append("Opening: " + file.getName() + "." + newline);
            }
else
{
log.append("Open command cancelled by user." + newline);
        }
}
});

punkt3.addActionListener(new ActionListener()
{
public void actionPerformed(ActionEvent e)
{
System.exit(0);
}
});

datei.add(punkt1);
datei.add(punkt2);
datei.addSeparator();
datei.add(punkt3);
menu.add(datei);
setJMenuBar(menu);
setContentPane(contentPane);

//Fenstersteuerung
addWindowListener(new WindowAdapter()
{
public void windowClosing(WindowEvent e)
{
System.exit(0);
}
});

}

//Hauptroutine
public static void main(String [] argv)
{
swing_main frame = new swing_main();
frame.setResizable(false);
frame.setVisible(true);
}
}
```

7.4 Anhang D — Quelltext für die Klasse, die gewrappte Daten steuert.

```
import java.io.* ;
import java.net.* ;
import java.util.* ;
import edu.upenn.w4f.binop.* ;
import edu.upenn.w4f.conditions.* ;
import edu.upenn.w4f.nsl.* ;
import edu.upenn.w4f.util.* ;
import edu.upenn.w4f.htmlpath.* ;
import edu.upenn.w4f.parser.* ;
import edu.upenn.w4f.parser.html.* ;
import edu.upenn.w4f.mapping.xml.*;
import java.sql.*;

//klasse, die die ergebnisse der wrappergenerierten schu.class erhält
//und verarbeitet
public class metadaten_main
{

//methode um url der html-seite an die generierte klasse schu.class zu geben
//und ergebnis zu verarbeiten, um es als String[] zurückzugeben
//wird von swing_main aufgerufen
public String[] toParseFile(String url)throws Exception
{
//instanz von schu
schu f = schu.get(url) ;
//zu testzwecken, gewrappte überschrift der html-seite
System.out.println("Die Überschrift lautet: " + f.titel);
//gewrappter textinhalt der seite als NSL_List geholt
NSL_List nsl = (NSL_List) f.inhalt;

int size =  nsl.size();
int i =0;
//Set, um darin Textinhalt, wort für wort ohne dopplungen zu speichern
Set testset = Collections.synchronizedSet(new HashSet());

/*jedes element der NSL_List wird in String verwandelt,
  bearbeitet und im Set testset gespeichert
*/
for (i=0; i<size; i++)
{
String name = ((NSL_String) nsl.elementAt(i)).toString();
name = name.replace('(' ,' ' );
     name = name.replace(')' ,' ' );
     name = name.replace(',' ,' ' );
     name = name.replace('|' ,' ');
name = name.replace('"' ,' ');
name = name.replace('?' ,' ');
name = name.replace('!' ,' ');
name = name.replace(':' ,' ');
name = name.replace(';' ,' ');
name = name.trim();

if (name.indexOf("@") == -1)
{
name = name.replace('.' ,' ');
}

//füllwörter entfernen
```

```
System.out.println(name  + " FeldNr.:" + i );
Vector füllwörter=new Vector();
String a = "mit";
String b = "der";
String c = "die";
String d = "das";
String e = "wo";
String f1 = "ein";
String g = "über";
String h = "als";
String i1 = "an";
String j = "am";
String k = "eine";
String l = "zu";
String m = "so";
String n = "und";
String o = "kein";
String p = "jeden";
String q = "zur";

füllwörter.add(a);
füllwörter.add(b);
füllwörter.add(c);
füllwörter.add(d);
füllwörter.add(e);
füllwörter.add(f1);
füllwörter.add(g);
füllwörter.add(h);
füllwörter.add(i1);
füllwörter.add(j);
füllwörter.add(k);
füllwörter.add(l);
füllwörter.add(m);
füllwörter.add(n);
füllwörter.add(o);
füllwörter.add(p);
füllwörter.add(q);

  //stringtokenizer, um jeden token der NSL_List zu extrahieren und
//ins testset zu speichern
StringTokenizer st = new StringTokenizer(name);
      while (st.hasMoreTokens())
{
      String eintrag = st.nextToken();

if (füllwörter.contains(eintrag)==false)
  {
   testset.add(eintrag);
}
}
}

int d = testset.size();
System.out.println(d);
//umwandlung testset im array
String[] x = (String[]) testset.toArray(new String[0]);

//für testzwecke um arrayinhalt zu überprüfen
int leng = x.length;
System.out.println(leng);
int c = 0;

for (c=0; c<(leng); c++)
```

```
{
System.out.println("array-felder "+ x[c]+ " , " + c);
}

  //instanz von DbKram, um ontologie abzufragen
final DbKram test = new DbKram();
//übergabe des arrys an DbKram und ergebnis in Set liste abspeichern
    Set liste = test.eintraege(x);
System.out.println(liste.size());
int p =liste.size();
//liste in array umwandeln und an letzte stelle des feldes
//die gewrappte überschrift abspeichern
String[] liste1 = (String[]) liste.toArray(new String[p+1]);
liste1[p] = f.titel.toString();
//für testzwecke
int leng1 = liste1.length;
int c1 = 0;

for (c1=0; c1<(leng1); c1++)
{
System.out.println("array-felder "+ liste1[c1]+ " , " + c1);
}
//rückgabe des feldes an swing_main
return liste1;
}
}
```

7.5 Anhang E — Quelltext für die Klasse, die den Datenbankzugriff steuert.

```
/*************************************************************************
 *  Title:         DbKram.java
 *
 *  Description:    Datenbankverbindungen  und -abfragen und was sonst noch
  so gebraucht wird
 *************************************************************************
 */
import java.sql.*;
import java.util.*;


class DbKram
{
  static Connection conn = null;

  //klasse, die einen vorgänger zu einem konzept als string zurückliefert
  public String konzepte(String konzept)
   {
     String returne = "";
String cmd1 = "SELECT vertreter, vorgaenger FROM geschichte where vertreter ='"+ konzept+"'";
     Statement query1 = null;
ResultSet rs_query1 = null;

try
{
   query1 = conn.createStatement();
  rs_query1 = query1.executeQuery(cmd1);
  conn.commit();

  //ResultSet durchgehen
while (rs_query1.next())
{
  returne = rs_query1.getString(2);
  }
 }

 catch (SQLException e)
 {
  System.out.println("SQLException, "+ e);
 }

 return returne;
  }

  public Set eintraege(String[] inhalt)
  {
    Set returner = Collections.synchronizedSet(new HashSet());

if(connectDBServer()!=false)
{
int leng = inhalt.length;
int c = 0;
for (c=0; c<(leng); c++)
{
System.out.println("aktuelle Ausprägung: "+ inhalt[c]+ " , " + c);

String cmd = "SELECT auspraegung, konzept FROM einstieg where auspraegung ='"+ inhalt[c]+"'";
     System.out.println(cmd);
```

```
Statement query = null;
ResultSet rs_query = null;

try
{
   query = conn.createStatement();
  rs_query = query.executeQuery(cmd);
  conn.commit();

//ResultSet durchgehen
while (rs_query.next())
{
     String hilfstring = konzepte(rs_query.getString(2));String konzepthierarchie = hilfstring;
String bla = "null";
while (hilfstring.equals("ontologievater")==false)
{
hilfstring = konzepte(hilfstring);

if (hilfstring.equals("ontologievater")==false)
{
konzepthierarchie = konzepthierarchie+":"+hilfstring;
}
System.out.println("konzepthierarchie danach  "+ konzepthierarchie);
}

returner.add("<meta name =\"Metadaten_aus_Ontologiewissen\"
Originaltext =\"" + rs_query.getString(1)+"\"
Ausprägung_von =\""+rs_query.getString(2)+":"+konzepthierarchie+"\">");
}
}
catch (SQLException e)
{
System.out.println("SQL - Fehler: "+ e);
}
}
return returner;
}
return null;
  }


  //************************************
  //schließt die connection zum Server
  public static boolean closeDBServer()
  {
   try
{
   conn.close();
    }
catch (SQLException e)
{
       System.out.println("SchuERROR: Die Verbindung konnte
       nicht geschlossen werden: "+e.toString());
   return false;
}
return true;
  }
  //end of closeDBServer()

  //************************************
  //öffnet eine Connection zum DB-Server
  public static boolean connectDBServer()
  {
```

```
    String DBUrl = "jdbc:interbase://localhost/C:/Studienarbeit/w4f/w4f/datenbank/gesch_m";
    try
{
   Class.forName("interbase.interclient.Driver");
}
catch (Exception e)
{
   System.out.println("SchuERROR: InterClient-Treiber konnten nicht geladen werden.");
   return false;
}
try
{
   conn = DriverManager.getConnection(DBUrl,"sysdba","masterkey");
}
catch (SQLException e)
{
   System.out.println("SchuERROR: Der Server konnte nicht connectet werden: " + e.toString());
       return false;
}
return true;
  }
  //end of connectDBServer

}
```

7.6 Anhang F — Ontologietabelle.

VERTRETER	VORGAENGER
geschichtsereignis	<null>
politik	geschichtsereignis
wirtschaft	geschichtsereignis
wissenschaft	geschichtsereignis
gesellschaft	geschichtsereignis
kunst	geschichtsereignis
religion	geschichtsereignis
philosophie	geschichtsereignis
region	geschichtsereignis
zeit	geschichtsereignis
krieg	politik
aufstand	krieg
schlacht	aufstand
gegner	schlacht
sieger	gegner
verlierer	gegner
herrschaftsform	politik
herrscher	herrschaftsform
staat	herrscher
herrensitz	herrscher
partei	staat
verfassung	staat
gesetz	staat
mitglied	partei
burg	herrensitz
schloss	herrensitz
industrie	wirtschaft
landwirtschaft	wirtschaft
wirtschaftsordnung	wirtschaft
rohstoff	industrie
entdeckung	wissenschaft
erfindung	wissenschaft
technik	wissenschaft
entdecker	entdeckung
erfinder	erfindung
gesellschaftsordnung	gesellschaft
krankheit	gesellschaft
epedemie	krankheit
kultur	gesellschaft
kunstepoche	kunst
kuenstler	kunstepoche
kunstwerk	kuenstler
architektur	kunstwerk
skulptur	kunstwerk
malerei	kunstwerk
poesie	kunstwerk
musik	kunstwerk
glaube	religion
einfluss_auf_staat_gesellschaft	religion
einrichtung	glaube
glaubensvertreter	glaube
philosoph	philosophie
werk	philosoph
zeitraum	zeit
zeitpunkt	zeit
anfang	zeitraum
ende	zeitraum

```
land                            region
gebiet                          land
stadt                           land
stadtteil                       stadt
```

7.7 Anhang G — Tabelle mit den Ausprägungen zu den Konzepten.

AUSPRAEGUNG	KONZEPT
Wiener	stadt
Schwerin	stadt
Rostock	stadt
Güstrow	stadt
Neustrelitz	stadt
mecklenburgischen	land
Mecklenburg-Strelitz	land
Mecklenburg-Schwerin	land
Preußen	land
Deutschen	land
Deutschland	land
Bundesstaaten	land
Österreichs	land
Dänemark	land
Herzöge	herrscher
Großherzöge	herrscher
Landesherren	herrscher
Großherzog	herrscher
Bismarck	herrscher
Bund	herrschaftsform
Großherzogtum	herrschaftsform
Ritterschaft	herrschaftsform
Reiches	herrschaftsform
Fürstenhaus	herrschaftsform
Königshaus	herrschaftsform
Bundesversammlung	verfassung
Verfassungssystem	verfassung
Verfassung	verfassung
Rechte	verfassung
Freiheiten	verfassung
Repräsentativvertretung	verfassung
Verfassungsentwicklung	verfassung
Verfassungen	verfassung
Landesverfassung	verfassung
Verfassungsreform	verfassung
Ständeverfassung	verfassung
Berfreiungskriege	aufstand
antinapoleonischen	aufstand
Revolution	aufstand
Niederlage	verlierer
Justizkanzleien	gesetz
Kriminalgesetzordnung	gesetz
Verordnung	gesetz
Regelung	gesetz
Gewerbegesetz	gesetz
Staatsgrundgesetzes	gesetz
Landesklöster	einrichtung
Gutsbetrieben	landwirtschaft
landwirtschaftlichen	landwirtschaft
agrarwissenschaftlichen	landwirtschaft
ertragssteigernden	landwirtschaft
Thünen	landwirtschaft
Landwirt	landwirtschaft
Agrarökonom	landwirtschaft
gutswirtschaftlich	landwirtschaft
Konjunktur	wirtschaft

wirtschaftlicher	wirtschaft
Verkehrsnetzes	wirtschaft
Fernverkehrsstrassen	wirtschaft
Kunststraße	wirtschaft
Eisrenbahnlinie	wirtschaft
Eisenbahnverbindung	wirtschaft
Eisenbahnverbindungen	wirtschaft
Güterverkehr	wirtschaft
Aktiengesellschaften	wirtschaft
Großbetrieb	wirtschaft
Gewerbe	wirtschaft
Zunftzwang	wirtschaft
Stände	wirtschaft
industrielle	industrie
Alban	industrie
Hochdruckdampfmaschine	industrie
Landmaschinen	industrie
Demmler	architektur
Baumeister	architektur
Stadtarchitekt	architektur
Reuter	kuenstler
Dichter	kuenstler
Stromtid	poesie
Vereine	partei
Opposition	partei
Arbeitervereine	partei
liberale	partei
Prügelstrafe	gesellschaft
Auswanderungswelle	gesellschaft
Konflikt	krieg
Österreich/Preußen	krieg
militärischen	krieg
Truppen	krieg
deutsch-französischen	krieg

Tabellenverzeichnis

Abbildungsverzeichnis

Literatur

[GE99] GETESS: Ein Analyse- und Suchdienst für Texte im Internet, 2.IUK-Tage MV, Rostock 1999

[MK97] Musciano, C.; Kennedy, B.: HTML - The Definitive Guide. O´Reilly Associates, Inc., Köln, 1.Auflage, 1997.

[MS1] BMBF-Projekt GETESS, Arbeitsbericht zum Meilenstein 1, 1998

[MS2] BMBF-Projekt GETESS, Arbeitsbericht zum Meilenstein 2, 1999

[MS3] BMBF-Projekt GETESS, Arbeitsbericht zum Meilenstein 3, 2000

[Go00] Gohla, R.: Integrierte WWW-Anfragesichten, Diplomarbeit an der Universität Rostock, Februar 2000.

[SA00] Sahuguet, A.; Azavant, F.: W4F, 2000, URL http://db.cis.upenn.edu/W4F/.

[Ma01] Marugg, Thomas: Metadaten für Content-Indizierung und Wissenssicherung, Januar 2001, URL: http://www.internetmanagement.ch/index.cfm/fuseaction/shownews/newsid/351

[W4F] W4F's BNF, Grammatik der Spezifikationssprachen eines W4F-Wrappers, URL http://db.cis.upenn.edu/W4F/.