



Die Gestaltung der Suche in heterogenen Datenbeständen – Optionen und Herausforderungen. Ein Werkstattbericht

Von syntaktischer zur semantischen Suche

Dr. Lothar Hotz, Arved Solth, HITeC e.V., Universität Hamburg

EINFACHE SUCHE

Feuer Hamburg




Feuerversicherung

Feuerwehr

Hamburger Brand

Feuer in
Rohstofflager


EINFACH(E)(STE) SUCHE?



DIMENSIONEN

- Aufbereitung: Regionbezogene Filter
- Sucheingabe: Ausdruck der vom Benutzer intendierten Bedeutung
- Die Suche: Auswertung der Bedeutung
- Suchergebnis: Darstellung und Erklärung der verwendeten Bedeutung
- Verwertung: Ziel des Benutzers

KONTEXTUELLE BEDEUTUNG



Kontextuelle Bedeutung

- Kontext: **regionaler Bezug zu Hamburg**
- Auswahl entsprechender Ressourcen-Anbieter
 - ✓ **20 Anbieter und 64 Ressourcen**
- Festlegung eines Metadaten-Schemas
 - ✓ **13 Suchfelder und 26 interne Felder**
 - ❖ Standard-Metadaten-Schema
- Abbildung der Anbieter-Semantik auf Aggregator-Semantik
 - ✓ **Manuell pro Ressource**
 - ❖ **Ontology-Mapping, Ontology-Alignment**

Kontextuelle Bedeutung

- Abbildung und Indexierung der Informationsobjekte
 - ✓ **Automatische Metadatenabbildung**
 - ❖ Semantisches Parsing: Erkennen der kontextuellen Metadaten in Informationsobjekten

Verarbeitung von XML-Formaten

Metadaten im Original-Format
(z.B. LIDO)

```
...  
<lido:titleSet>  
<lido:appellationValue >  
Sonntagsstimmung auf der  
Elbe. St. Pauli  
Landungsbrücken  
</lido:appellationValue>  
</lido:titleSet>  
</lido:titleWrap>  
...
```

XSLT-Regeln

```
...  
<xsl:template  
match="lido:titleSet/lido:appellationValue">  
  <field name="title">  
    <xsl:value-of select="." />  
  </field>  
</xsl:template>  
...
```

Metadaten im HWD-Format

```
<doc>  
...  
<field name="title">  
Sonntagsstimmung auf der  
Elbe. St. Pauli  
Landungsbrücken  
</field>  
...  
</doc>
```

Übersicht verwendeter Parser

| Format | Parser/Bibliothek | Beispiel-Ressource |
|------------------------------|----------------------------|--|
| XML-Formate | Saxon XSL-Transformationen | Archiv des Hamburger Instituts für Sozialforschung |
| Webseiten (HTML) | BeautifulSoup | Beständeübersicht des Landesarchivs Schleswig-Holstein |
| Adobe PDF | Apache Tika | Statistische Berichte des Statistamts Nord |
| Comma Separated Values (CSV) | Python-CSV-Library | Stolpersteine-DB der Landeszentrale für politische Bildung |

Kontextuelle Bedeutung

- Abbildung und Indexierung der Informationsobjekte
 - ✓ **Automatische Metadatenabbildung**
 - ❖ Semantisches Parsing: Erkennen der gewählten Metadaten in Informationsobjekten

- Filterung der Datenbestände
 - (Manuelle Auswahl der Informationsobjekte)
 - ✓ Modellierung der Auswahl mittels eines Thesaurus/Ontologie
 - ✓ **7485587 Hamburgensien**
 - ❖ Automatisches Lernen durch Angabe von positiven und negativen Beispielen

HWD-Indexsuche: Hamburg-Filter

Vorläufige Trefferliste:

Erich Hartmann (1886-1974). Leben und Werk eines Hamburger Malers. Mit einem Verzeichnis der Gemälde und der "Kunst am Bau"

Einfluß einer Behandlung mit dem Steroid-Implantat Synovex-S auf das natürliche Steroidhormonmuster des Muskel- und Fettgewebes von Ochsen


Hamburger Mietenspiegel : Texte, Erläuterungen, Arbeitshinweise / von Friedemann Sternel. XII, 96 S.

Analyse der Hamburger Rauschgifttodesfälle im Zeitraum 2004-2006 auf Hepatitis B, C, HIV und pulmonale Fremdkörpergranulome
Analysis of drug-related deaths from 2004 to 2006 for hepatitis B, C, HIV and pulmo...

Chemoenzymatische Synthese sialylierter Oligosaccharidstrukturen durch Transglycosylierung

Hamburg-Filter:

Normdaten-Wortgut
(SWD, GKD, HHBiB-SW)




Endgültige Trefferliste:

Funktionsweise des Filters

- ✓ Basis: Normdaten-Wortgut aus Schlagwortdatei (SWD), HHBIB-Schlagworte (HHBIB-SW), Gemeinsame Körperschaftsdatei (GKD), Lokalisatoren
- ✓ Kombination von ausgewählten Schlagworten mit Lokalisatoren
- ✓ Aktuell ca 7 Millionen Begriffe
- ✓ Anfrage an SOLR-Server: Hole alle Dokument, die x Hamburgensien enthalten
- ✓ Berücksichtigung eines Wortabstands bzgl. einer Hamburgensie
- ✓ Solr-Suche auf ausgewählten Feldern (Titel, Abstract, Volltext, etc.)
- ❖ Blackliste mit eindeutigen Nicht-Hamburgensien
- ✓ Laufzeit 6 bis 10 Stunden

```
params={fl=identifizier,start=0,q=ressource:hans AND _query_:"!edismax qf='title text author content_biography_text
content_person content_place content_standard_keyword content_description content_time content_keyword '
v=$qq}",wt=javabin,qq="Hamburg Bergstedt Michael Hering Erben"~10 OR "Rahlstedt Michael Hering Erben"~10 OR "Volksdorf
Michael Hering Erben"~10 OR "Barmbek German Committee for Marine Sciences and Technology"~10 OR "Hamburg Goldbeck
Janssen Horst Brockstedt Hans"~10 OR "Goldbeck Hamburg Janssen Horst Brockstedt Hans"~10 OR "Treudenberg Steber Jörg"~10
OR "Mooralster Steber Jörg"~10 OR "Susebeck Steber Jörg"~10 OR "Susebek Steber Jörg"~10 OR "Alsterwanderweg Steber
Jörg"~10 OR "Wandse Steber Jörg"~10 OR "Hamburg-Goldbeck Steber Jörg"~10 OR "Hamburg Goldbeck Steber Jörg"~10 OR
"Goldbeck Hamburg Steber Jörg"~10 OR "Krautsand Weichmann Christian Friedrich"~10 OR "Schweinesand Weichmann Christian
Friedrich"~10 OR "Pagensand Weichmann Christian Friedrich"~10 OR "Rodenbeker Quellental Weichmann Christian Friedrich"~10
OR "Klein-Flottbeck Weichmann Christian Friedrich"~10 OR "Klein-Flottbek Weichmann Christian Friedrich"~10 OR "Walddörfer
Weichmann Christian Friedrich"~10 OR "Hanskalbsand Weichmann Christian Friedrich"~10 OR "Hamburg Sülldorf Imhof
Hieronymus"~10 OR "Sülldorf Hamburg Imhof Hieronymus"~10 OR "Bergstedt Hamburg Musikkorps Deutschland 6"~10 OR
"Bergstedt-Hamburg Musikkorps Deutschland 6"~10 OR "Hamburg-Steinbek Unbehagen Johann Andreas Christoph"~10 OR
"Steinbeck-Hamburg Unbehagen Johann Andreas Christoph"~10 OR "Steinbek Hamburg Unbehagen Johann Andreas
Christoph"~10 OR "Hamburg Steinbek Unbehagen Johann Andreas Christoph"~10 OR "Scharhörn Unbehagen Johann Andreas
Christoph"~10 OR "Steinbek-Hamburg Unbehagen Johann Andreas Christoph"~10 OR "Schiffbek Unbehagen Johann Andreas
Christoph"~10 OR "Schiffbeck Unbehagen Johann Andreas Christoph"~10 OR "Hamburg-Hoheluft
Konzentrationslager Lerbeck"~10 OR "Hamburg Hoheluft Konzentrationslager Lerbeck"~10 OR "Steinbeck Hamburg Unbehagen
Johann Andreas Christoph"~10 OR "Hamburg Steinbeck Unbehagen Johann Andreas Christoph"~10 OR "Fuhlsbüttel Praetzel Karl
Gottlieb"~10 OR "Langenhorn Praetzel Karl Gottlieb"~10 OR "Wilhelmsburg-Hamburg Dornemann Henrich"~10 OR "Veddel
Dornemann Henrich"~10 OR "Barmbek Praetzel Karl Gottlieb"~10 OR "Barmbeck Praetzel Karl Gottlieb"~10 OR "Barmbek-Süd
Praetzel Karl Gottlieb"~10 OR "Barmbeck-Süd Praetzel Karl Gottlieb"~10 OR "Barmbeck-Nord Praetzel Karl Gottlieb"~10 OR
"Billstedt Dornemann Henrich"~10 OR "Dulsberg Praetzel Karl Gottlieb"~10,version=2,rows=20000}
```

DIE SUCHE



HWD-Metasuche – erweiterte Suchmaske

Suche starten ▶

Freitext: ⓘ

Thema: ⓘ
 Titel / Bez. Schlagwort Abstract Volltext
 alle keine

Zeitbezug: ⓘ

Urheber: ⓘ

Entstehungsort: ⓘ

Entstehungszeit: ⓘ

Medientyp: ⓘ

Nummer: ⓘ

Datenbanken alle keine Nachweise Volltexte, Bilder

- BAM-Portal: Archive
- BAM-Portal: Museen
- BAM-Portal: Weitere Quellen
- Behörde für Justiz und Gleichstellung
- Bildarchiv Foto Marburg
- Denkmalschutzamt Hamburg
- digiCULT-Verbund eG
- Hamburger Institut für Sozialforschung
- Hamburgische Bürgerschaft
- Institut für die Geschichte der deutschen Juden
- Landesarchiv Schleswig-Holstein
- Landeszentrale für politische Bildung Hamburg
- Ludwig-Maximilian-Universität München / Musikwissenschaft
- Staats- und Universitätsbibliothek Hamburg
- Staatsarchiv Hamburg
- stadteilgeschichten.net e.V.
- Statistikamt Nord
- Technische Universität Berlin
- Universität Hamburg / Historisches Seminar
- ZBW - Leibniz-Informationszentrum Wirtschaft

* = Hamburg-relevanter Teilbestand (von HamburgWissen Digital gefiltert)
** = Hamburg-relevanter Teilbestand (vom Anbieter gefiltert)

Anzahl Treffer: ▼

HWD-Metasuche – erweiterte Suchmaske

Suche starten ▶

Freitext: ⓘ

Thema: ⓘ
 Titel / Bez. Schlagwort Abstract Volltext
 alle keine

Zeitbezug: ⓘ

Urheber: ⓘ

Entstehungsort: ⓘ

Entstehungszeit: ⓘ

Medientyp: ⓘ

Nummer: ⓘ

Ausdruckshilfe für die Darstellung der vom Benutzer intendierten Bedeutung

Felder mit Zeitbezug

Suche starten ▶

Freitext: ⓘ

Thema: ⓘ
 Titel / Bez. Schlagwort Abstract Volltext
• alle • keine

Zeitbezug: ⓘ

Urheber: ⓘ

Entstehungsort: ⓘ

Entstehungszeit: ⓘ

Medientyp: ⓘ

Nummer: ⓘ

Eingabe eines Zeitbereichs: e_z

Zeitbereich des Informationsobjekts: i_z

Mögliche Interpretationen:

$i_z = e_z$: gleiche Zeitbereiche

$i_z \sim e_z$: ungefähr gleiche Zeitbereiche

$i_z \subset e_z$: Eingabebereich umfasst

Informationsobjektsbereich

$e_z \subset i_z$: Eingabebereich innerhalb

Informationsobjektsbereich

(nur direkt umliegend(!))


$e_z \cap i_z$: Eingabebereich hat Schnitt mit

Informationsobjektsbereich

Felder mit Zeitbezug

- **Aufbereitung:**
 - ✓ **Metadatenfelder: creation_time_from, creation_time_to, content_time_from, content_time_to**
 - ❖ Abbildung von zeitbezogenen Begriffen auf Zeitbereich
- **Suche:**
 - ✓ **Intervallarithmetik**
- **Darstellung:**
 - ❖ Zeit des Informationsobjekts mit “Im Bereich”

Felder mit Ortsbezug



Eingabe eines Ortsbereichs: e_o
Ortsbereich des Informationsobjekts: i_o

Mögliche Interpretationen:

$i_o = e_o$: *gleiche* Ortsbereiche

$i_o \sim e_o$: *ungefähr* gleiche Ortsbereiche

$i_o \subset e_o$: Eingabebereich *umfasst*

Informationsobjektsbereich

$e_o \subset i_o$: Eingabebereich *innerhalb*

Informationsobjektsbereich

(nur direkt umliegend(!))

$e_o \cap i_o$: Eingabebereich hat *Schnitt* mit

Informationsobjektsbereich

Felder mit Ortsbezug

- Aufbereitung:
 - ❖ Metadatenfelder: content_place, content_georeference
 - ❖ Punkt, Polygon, Bounding-Box
 - ❖ Abbildung von ortsbezogenen Begriffen auf Georeferenz
- Suche:
 - ✓ **Syntaktische Suche nach Ortsbezugsbegriff**
 - ❖ Koordinatenbereichssuche
- Darstellung:
 - ❖ Kartendarstellung mit Orten der Informationsobjekte

Textuelle Felder


Suche starten ▶

Freitext: Freitextsuche über alle Felder

Thema: Feuer

Titel / Bez. Schlagwort Abstract Volltext

alle keine



Eingabe eines Strings: e_t

Texte im Informationsobjekts: i_t

Mögliche Interpretationen:

$i_t = e_t$: **Stringsuche**, Synonyme

$i_t \sim e_t$: Rechtschreibprüfung, etc.

$e_t \subset i_t$: Eingabebereich *innerhalb* Informationsobjektsbereich (nur direkt umliegend(!))

$e_t \cap i_t$: Eingabebereich hat *Schnitt* mit Informationsobjektsbereich

$i_t \subset e_t$: Eingabebereich *umfasst* Informationsobjektsbereich

Textuelle Felder

- Aufbereitung:
 - ✓ Indexierung
 - ❖ Anreicherung mit Kategorien
- Suche:
 - ✓ **Syntaktische Suche**
 - ❖ Ontologische Suche
- Darstellung:
 - ✓ **Anzeige der Fundstellen des Suchworts**
 - ❖ Erklärung der ontologischen Suche


EINFACH(E)(STE) SUCHE



Technische Herausforderungen

- ✓ Trennung von Entwicklungs- und Produktivsystem
 - Entwicklung und Test von neuen Verfahren
- ✓ Trennung von Suche und Indexierung
 - Dauerhaftes Harvesting und Indexierung

Systemarchitektur



Werkzeuge

- Programmiersprachen:
 - Perl, Python, PHP, Java, Javascript, Shell, XSLT
- Infrastruktur:
 - Solr, Lucene, Tomcat, Apache, IPS, Suse, Debian, Corba, Wget, FTP, OAI-Harvester, Saxon, Mysql
- Formate:
 - Lido, XmetaDiss, proprietäre XML-Formate, HTML, museumdat, CSV

Vielen Dank für Ihre Aufmerksamkeit

Dr. Lothar Hotz

Mail: hotz@informatik.uni-hamburg.de

Tel.: 040-42883 2605

Arved Solth

Mail: solth@informatik.uni-hamburg.de

Tel.: 040-42883 2611