

Lösungsvorschläge zu Blatt 2

Aufgabe 1:

Gegeben sind folgende Dokumente

Doc1: Neues aus der Literaturwissenschaft: Durchbruch in der Shakespeareforschung.

Doc2: ein neues buch von shakespeare entdeckt.

Doc3: Freude für Shakespeareliebhaber.

Doc4: Waren das schon alle neuen Bücher Shakespeares?

- 1) Konstruieren Sie einen Index durch folgende Zwischenschritte:
Tokenisierung, Normalisierung(Lemmatisierung), Sortieren und Gruppieren.
- 2) Was liefern folgende booleschen Anfragen für die vier Dokumente in der vorherigen Aufgabe zurück:
 - neu AND Shakespeare
 - Buch AND neu
- 3) Wieweit hängen die Ergebnisse von der Normalisierung der Token (linguistische, Bearbeitung wie Lemmatisierung etc.) ab?
- 4) Wieweit hängen die Ergebnisse von der Tokenisierung ab? Was wäre das Ergebnis wenn ein Kompositasplitter eingebaut ist

1)
Term
Doc.freq
Postings lists

buch:2,4
durchbruch:1
entdecken:1
freude:3
literaturwissenschaft:1
neu:1,2,4
shakespeare:2,4
shakespeareforschung:1
shakespeareliebhaber:1

2)

{Doc2, Doc4}

{Doc2, Doc4}

3)

Die Normalisierung:

- Linguistische Normalisierung: Verschiedene Formvarianten eines Terms werden auf eine einheitliche Grundform reduziert, z. B. die Vollform des Terms wird zum entsprechenden Lemma ersetzt und einer Äquivalenzklasse geordnet, beispielsweise die Wortformen „Neues“ und „neuen“ → neu „Buch“ und „Bücher“ → Buch
- Normalisierung von Wortvarianten, Flexion, Derivation: waren → sein
- Groß- und Kleinschreibung wandeln sich in Kleinschreibung: „neues“ und „Neues“
- Stopwörter werden entfernt, „für“, „das“ etc.

Die Tokenisierung:

- Der Text wird vor allem durch Leerzeichen in Token segmentiert. Aber für Mehrwortlexeme ist es problematisch: New York
- Die Interpunktion ist üblich gelöscht. Aber für Abkürzung wie C.A.T darf die Interpunktion nicht gelöscht werden.
- Stoppwortliste: entfernen oder behalten
- Kompositasplitter, wie z.B. ohne Kompositasplitter findet die Anfrage „Shakespeare“ keine Dokumente mit „Shakespeareforschung“, „Shakespearesliebhaber“. Problematisch sind bei Komposita wie Staubecken → Stau Becken or Staub Ecken.

Aufgabe6

(a) Was sind Vor- und Nachteile des Booleschen Retrievals?

(b) Angenommen, die folgenden Dokumente seien von einem Booleschen Retrievalsystem indexiert worden. Dabei fand die übliche Stoppworteliminierung, sowie Stemming statt.

1. Evaluating Strategic Support for Information Access in the Daffodil System.
2. Daffodil: A User-Oriented Approach for Accessing Federated Digital Libraries.
3. Daffodil: Distributed Agents for User-Friendly Access of Digital Libraries.
4. Daffodil - Strategic Support for User-Oriented Access to Heterogeneous Digital Libraries.
5. Active Support for Query Formulation in Virtual Digital Libraries: A case study with Daffodil.
6. Daffodil: An integrated desktop for supporting high-level search activities in federated digital libraries.
7. User-Oriented Query Modification in Metaclass Systems.

8. Daffodil: Strategic Support Evaluated

Formulieren Sie möglichst knappe Boolesche Anfragen (mit AND, OR und NOT),
die genau die folgenden Dokumente finden:

(i) 2 und 4

(ii) 7

(iii) 8

Vorteile

- Einfache Implementierung
- Keine Benutzung von Wahrscheinlichkeiten/Heuristiken
- Viele experimentelle Systeme
- keine hohen Anforderungen an Rechner
- Ausdrucksstarke Syntax, logische Klarheit

Nachteile

- Die Größe der Antwortmenge ist schwierig zu kontrollieren
- Keine Ordnung der Antwortmenge
- Keine Möglichkeit zur Gewichtung von Fragetermen oder gewichteter Indexierung
- Strenge Trennung zwischen gefunden / nicht gefunden
- Erstellung der Frageformulierung sehr umständlich
- schlechte Retrievalqualität
-

b)

Dokumente 2 und 4: Orient NOT Query

Dokumente 7: Modification / Metaclass;

Dokumente 8: Evaluate NOT Information

Aufgabe 8 wurde so nicht gestellt, denken Sie zur Übung aber über eine Lösung nach.

Implementieren Sie für das Information Retrieval System eine Klasse, die einen invertierten Index erstellt wie er im Information Retrieval Buch Manning et. al. als Basisalgorithmus dargestellt wurde also für jeden Term gibt es eine Postingsliste mit den Dokumenten IDs. Verwenden Sie zum Test wieder die Shakespearesammlung.