



Maschinelle Sprachverarbeitung

Übung

Aufgabe 1: Analyse eines PubMed-Korpus

Mario Säger

mario.saenger@informatik.hu-berlin.de

- Suchmaschine für biomedizinische Artikel
 - Entwicklung und Pflege durch National Center for Biotechnology Information (NCBI)
 - Zugriff auf verschiedene (Meta-) Datenbanken
 - Dokumentation von medizinischen Artikeln in Fachzeitschriften
- PubMed umfasst über 28 Millionen Referenzen
 - Indexierung von über 5600 Fachzeitschriften
 - Wächst jährlich um ca. 500k Dokumente
 - Zugriff auf 13 Millionen Abstracts und 3,8 Millionen freie Volltexte

- Zugriff via Webbrowser oder Programmierschnittstelle
 - <https://www.ncbi.nlm.nih.gov/pubmed/>



The screenshot shows the PubMed search interface. At the top, there is a search bar with 'Cancer' entered and a 'Search' button. Below the search bar, there are options for 'Format: Summary', 'Sort by: Most Recent', and 'Per page: 20'. The search results are displayed as a list of three items, each with a checkbox, a title link, and a brief description. The first item is 'Cognitive Impairment in Adults with Non-Central Nervous System Cancers (PDQ®): Health Professional Version.' with a PMID of 29112351. The second item is 'Prostate Cancer Treatment (PDQ®): Health Professional Version.' with a PMID of 26389471. The third item is 'Prostate Cancer Treatment (PDQ®): Patient Version.' with a PMID of 26389353. On the right side, there is a 'Results by year' bar chart and a 'Related searches' section listing 'breast cancer', 'lung cancer', 'prostate cancer', 'colorectal cancer', and 'ovarian cancer'.

- Indexierte Informationen:
 - Zuordnung einer eindeutigen ID zu jedem Artikel (PubMedID)
 - Angaben zum Journal und Veröffentlichungszeitpunkt
 - Titel des Artikels und ggf. Abstrakt oder Volltext
 - Verschlagwortung mittels Medical Subject Headings (MeSH)
<https://www.nlm.nih.gov/mesh/>
 - Autorenname und Affiliationen
 - Weitere Metadaten (z.B. Sprache, Verarbeitungsangaben)
- Datenbereitstellung in einem XML-Format
 - https://www.nlm.nih.gov/bsd/licensee/data_elements_doc.html

Aufgabenstellung

- Entwicklung eines Programms zum Analysieren eines PubMed-Korpus
 - <https://box.hu-berlin.de/f/19f49c6cf7604bd8bb65/?dl=1>
- Implementierung eines eigenen XML-Parsers
 - SAX / DOM / Eigenentwicklung „from scratch“
 - Benutzung von Third-Party-Libraries zum Parsen von XML-Dateien (e.g. Jackson, Saxon) ist nicht erlaubt
 - Keine Validierung der XML-Struktur (mittels DTD) notwendig
- Analyse der Wortverteilung und Ermittlung verschiedener Kennzahlen

Kennzahlen

- Anzahl an Dokumenten
- Anzahl von Wörtern in ArticleTitle und AbstractText

```
<PubmedArticle>
  <MedlineCitation Status="MEDLINE" Owner="NLM">
    <PMID Version="1">16753163</PMID>
    <ArticleTitle>Identification of [...]</ArticleTitle>
    <Abstract>
      <AbstractText>Guanylyl cyclase C (GC-C) is a single
        transmembrane receptor for [...]
      </AbstractText>
    </Abstract>
  </MedlineCitation>
</PubmedArticle>
```

Kennzahlen

- Anzahl an Dokumenten
- Anzahl von Wörtern in ArticleTitle und AbstractText
 - Whitespaces (`\s+`) bilden Trennzeichen für Wörter
 - Alle Wörter in lowercase konvertieren
 - Anzahl an Wörtern insgesamt + Anzahl verschiedener Wörter („distinct“)
 - Keine separate Kennzahl für AbstractTitle und AbstractText!
- Die 50 häufigsten Wörter, deren Vorkommenshäufigkeit und (kumulativer) prozentualer Anteil am Gesamtkorpus

Kennzahlen

- Achtung: Mehrere AbstractText-Elemente mit zusätzlichen Attributen möglich

```
<Abstract>
```

```
  <AbstractText Label="OBJECTIVE" NlmCategory="OBJECTIVE">
```

```
    To test the hypothesis that the cumulative endometriosis [...]
```

```
  </AbstractText>
```

```
  <AbstractText Label="DESIGN" NlmCategory="METHODS">
```

```
    Retrospective cohort study including infertility [...]
```

```
  </AbstractText>
```

```
</Abstract>
```


Kennzahlen

- Anzahl an Artikeln je Journal + Anzahl an Artikeln je Jahr

<Journal>

<ISSN IssnType="Print">0016-6480</ISSN>

<JournalIssue CitedMedium="Print">

<Volume>149</Volume>

<Issue>1</Issue>

<PubDate>

<Year>2006</Year>

<Month>Oct</Month>

</PubDate>

</JournalIssue>

<Title>General and comparative endocrinology</Title>

<ISOAbbreviation>Gen. Comp. Endocrinol.</ISOAbbreviation>

</Journal>

Kennzahlen

- Anzahl an Artikeln je MeSH-Heading
 - Kombination des Description-Eintrags mit Qualifier-Angabe
 - Verbindungszeichen „//“

```
<MeshHeadingList>
  <MeshHeading>
    <DescriptorName UI="D010802">Phylogeny</DescriptorName>
  </MeshHeading>
  <MeshHeading>
    <DescriptorName UI="D011506">Proteins</DescriptorName>
    <QualifierName UI="Q000378">metabolism</QualifierName>
  </MeshHeading>
</MeshHeadingList>
```

=> „Phylogeny“ und „Proteins//metabolism“

Kennzahlen

- Anzahl an Artikeln je MeSH-Heading
 - Kombination des Description-Eintrags mit Qualifer-Angabe
 - Verbindungszeichen „//“

```
<MeshHeadingList>
  <MeshHeading>
    <DescriptorName UI="D011248">
      Pregnancy Complications
    </DescriptorName>
    <QualifierName UI="Q000209">etiology</QualifierName>
    <QualifierName UI="Q000601">surgery</QualifierName>
  </MeshHeading>
</MeshHeadingList>
```

=> „Pregnancy Complications//etiology“ und „Pregnancy Complications//surgery“

Abgabedetails

- Aufgabe muss mit Java oder einer Java-VM kompatiblen Sprache gelöst werden (z.B. Scala, Kotlin, ..)
- Programm lässt sich wie folgt starten:

```
java -jar uebung1-gruppeX.jar ordner/
```

- Programm liest und analysiert alle XML-Dateien (*.xml) im übergebenen Ordner
- Ausgabe der Ergebnisse in die Standardausgabe (stdout)

Programmausgabe (Beispiel)

1. Artikelanzahl, Wortanzahl (insgesamt/distinct) und Top-50 Wörter (inkl. kumulativen Anteil)

Artikel: 60000

Wörter: 10477600 (491354 distinct)

the : 531489 (5,07 %)

of : 456729 (4,36 %)

and : 376277 (3,59 %)

[...]

cell : 13112 (0,13 %)

Top 50 : 3515229 (33,55 %)

Programmausgabe (Beispiel)

2. Anzahl an Jahresangaben (insgesamt/distinct) und Top-10 Jahre (inkl. kumulativen Anteil)

Jahresangaben: 57739 (53 distinct)
2017 : 18428 (31,92 %)
2014 : 16525 (28,62 %)
2015 : 11262 (19,51 %)
2016 : 1434 (2,48 %)
[...]
1996 : 397 (0,69 %)
1992 : 389 (0,67 %)
1991 : 369 (0,64 %)
Top 10 : 50047 (86,68 %)

Programmausgabe (Beispiel)

3. Anzahl an Journalangaben (insgesamt/distinct) und Top-10 Journale (inkl. kumulativen Anteil)

Journale: 60000 (4701 distinct)

Oecologia : 7295 (12,16 %)

PloS one : 1287 (2,15 %)

Scientific reports : 673 (1,12 %)

[...]

Methods in molecular biology (Clifton, N.J.) : 348 (0,58 %)

Kardiologia : 337 (0,56 %)

Top 10 : 12429 (20,72 %)

Programmausgabe (Beispiel)

4. Anzahl an MeSH-Angaben (insgesamt/distinct) und Top-10 MeSHs (inkl. kumulativen Anteil)

MeSH: 426314 (69839 distinct)
Humans : 22406 (5,26 %)
Female : 11887 (2,79 %)
Male : 11516 (2,70 %)
Animals : 6861 (1,61 %)
[...]
Adolescent : 2544 (0,60 %)
Treatment Outcome : 2032 (0,48 %)
Top 10 : 77006 (18,06 %)

Abgabe

- Upload eines ZIP-Archivs *uebung1-gruppeX.zip*
 - Ausführbares JAR-Archiv und Quellcode des Programms
 - Feedback zur benötigten Zeit
- Testet das Programm vor der Abgabe auf gruenau!
 - Verwendet (auch) kleinere Teil- oder Testkorpora
- Abgabe bis spätestens 04.11.2018, 23:59 Uhr über:
 - https://hu.berlin/ue_masprach1819_ass1

Wettbewerb

- Implementiert eine schnelle (und korrekte!) Lösung
- Wir messen die Laufzeit des Programms mit "time"
 - Parallelisierung macht sicherlich Sinn
- Die drei besten Teams bekommen 3/2/1 Punkte!

RoadMap nächste Wochen

- Gruppenbildung bis 22.10.2018
 - Per Email an mario.saenger@informatik.hu-berlin.de
- Optionale Übung am 25.10.2018
 - Rückfragen zur ersten Aufgabe + sonstige Fragen
- **Achtung: Übung am 01.11.2018 entfällt!**
 - Rückfragen per Mail aber jederzeit möglich
- Abgabe 1. Übungsaufgabe bis 04.11.2018, 23:59 Uhr