# SPRACHTECHNOLOGIE IN SUCHMASCHINEN
# IR-GRUNDLAGEN – TERMBASIERTE SUCHE

MASTERSEMINAR SUCHMASCHINEN

COMPUTERLINGUISTIK

SOMMERSEMESTER 2025

---

STEFAN LANGER

STEFAN.LANGER@CIS.UNI-MUENCHEN.DE

# "Big data"

IR ist eigentlich schon lange 'big data':

- Internet-Suchmaschinen indizieren Milliarden von Dokumenten
- Suchmaschinen-Software wie Solr und Elasticsearch kann ohne weiteres mehrere Millionen oder gar Milliarden von Dokumenten indizieren und verwalten, auch repliziert
- Ähnlich neueren NLP-Modellen basiert der Index (i.e. das Datenmodell) auf sehr vielen Daten
- Corporate-Suchmaschinen enthalten in ihren Indexen große Ausschnitte des Wissens eines Unternehmens und sind sehr häufig der umfassendste Informationsspeicher eines Unternehmens; sie machen die Information zugänglich

# IR – Grundlagen - Index

Texte durchsuchen:

- Sequenziell mit Zeichenkettenabgleich (string matching) oder mit regulären Ausdrücken (z.B. Unix grep) – dies stößt bei größeren Textmengen schnell an die Grenzen des Machbaren

- Mithilfe eines Indizes: Invertierte Dateien (inverted index)
  - Grundidee der Implementierung: Hash oder Trie (aber Indizes von großen Suchmaschinen sind noch zusätzlich optimiert)

# Invertierter Index

Zerlegung des Dokuments in Terme

Im einfachsten Fall: Zuordnung von Termen zu Dokument-Ids

**Dokument 1**

Schöne Männer gehören nach Cannes wie die Aschewolke an den isländischen Himmel

**Dokument 2**

Getrocknetes Wasser, das vom Himmel fällt und Tiere ohne Flügel, die trotzdem fliegen können?

**Index**

schöne.d1
männer.d1
….
himmel.d1/d2
wasser.d2
fliegen.d2

# Trie

aal
aas
apfel
bär
…

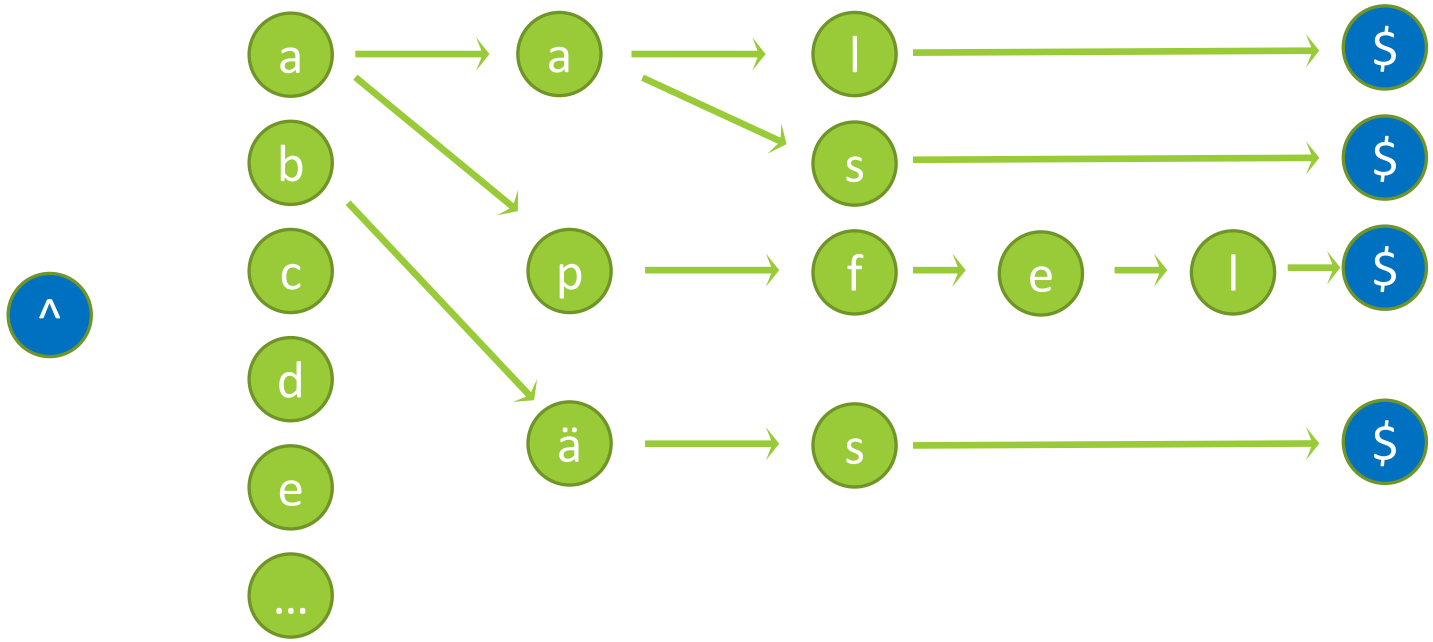

# Hash

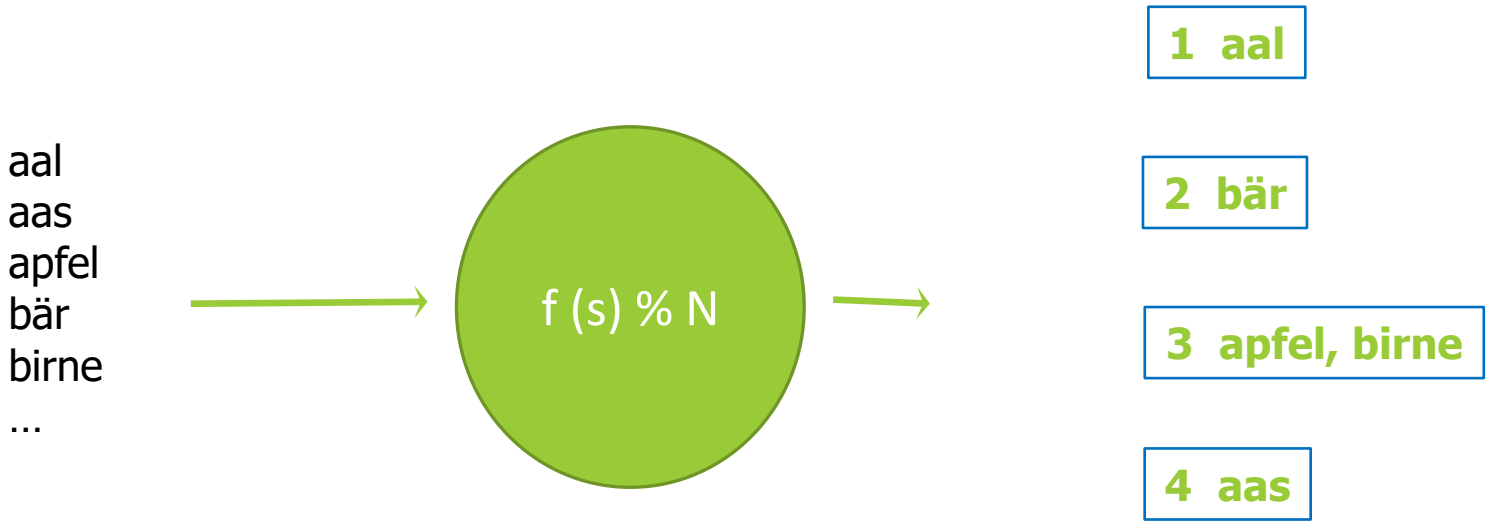


Hash function examples: md5, sha-1,

# Terminologie

| Terminologie | Erklärung | Elasticsearch |
|---|---|---|
| Index | Index zum Speichern der Informationseinheiten (z.B. Tokens, Wortbigramme, Buchstaben N-Gramme) | Index, (Shard) |
| Feld | Teil eines Dokuments mit Label. Jedes indizierte Element gehört zu einem Feld | Field, property |
| Schema | Welche Felder existieren im Index, und welches Format haben sie (String, Integer, Boolean etc.) | Mapping, mapping type |
| Tokenisierung | Nach welchen Kriterien werden Token erzeugt | analyzer, tokenizer |
| Stemming | Linguistisch motivierte Trunkierung von Strings | stemming / stemmer |
| Facetten, Aggregationen | Unterteilung von Suchergebnissen aufgrund der Inhalte bestimmter Felder | aggregations |
| Filter | Teil einer Anfrage, der nicht zum Ranking verwendet wird | Filter |

# Retrieval mit boolschen Ausdrücken

Verknüpfung von Suchtermen mit UND/ODER/NICHT

Dokumenten-Ids für jede Teilquery

Bilde Schnittmengen (UND) /Differenzmengen (NICHT) / bzw. Vereinigungsmengen (ODER)

Effiziente Algorithmen verfügbar

- S. Abschnitt 1.3 im IR-Buch

# Boolsche Operatoren

UND (AND): beide Teilausdrücke müssen in einem Dokument auftreten

Das ist der Default bei allen mir bekannten Websuchmaschinen

Beispiel: *UND(“HAMLET”,”OPHELIA”)*

ODER (OR): einer der Teilausdrücke muss im Dokument auftreten

Beispiel: *ODER(“Streichholz”,”Zündholz”)*

NICHT (NOT): negiere den dahinterstehenden Ausdruck

Beispiel: *UND(“HAMLET”,NOT(”OPHELIA”))*

Kombinationen: z. B. ANDNOT = AND NOT

# Komplexität Schnittmengenbildung

Die Komplexität der Schnittmengenbildung für einen Index (Mengen nach Größe sortiert):

- Naiver Ansatz: Vergleiche alle Elemente aus Menge 1 mit allen aus Menge 2: O ($n^2$)

- Verbesserter naiver Ansatz: Sortiere die Elemente aus Menge 1 oder schreibe sie in einen Hash/Dictionary. Lookup von allen Elementen aus Menge 2 in Menge 1 (binäre Suche oder Hash-Lookup):O (n log n) (sortieren)

- Index-Ansatz: lege die Mengen bereits nach Dokument-ID sortiert ab. Arbeite die sortierten Listen nach Dokument-ID ab. Linear – O (N)

# Suche von Termfolgen und Nähe im durchsuchten Dokument

Beispiele für Operatoren:

PHRASE(“Rot“,“Grün“)

NAH(Rot,Grün)

NAH(Rot,Grün,<ABSTAND>)

GEORDNETES_NAH(Rot,Grün)

# Lucene: Abfrage von Tokens

*text:dalloway* → "text" : "Mrs. Dalloway would by the flowers …"

Finde alle Dokumente, die im Feld 'text' das Wort 'dalloway' enthalten. Wenn das Feld ein Textfeld ist, wird die Anfrage durch den Tokeniserer/Analyzer vorbehandelt, d.h. normalisiert.

# Lucene: Phrasensuche / Proximity

*text:"to the lighthouse*" → "text" : "Tomorrow, we'll go to the lighthouse"

Suche im Feld 'text' die Wortsequenz 'to the lighhouse' (wird tokenisiert/normalisiert)

Zwischen den Wörtern können im Dokument keine weiteren Token stehen.

Proximity:

*text:"to the lighthouse*"~1 → "text" : "Tomorrow, we'll go to the red lighthouse"

Zwischen zwei der Wörter kann ein Token stehen (~ ist die Phrasen-Editierdistanz)

# Lucene: Boolsche Suche

text:"to the lighthouse" OR text:dalloway

text:"Peter Walsh" AND text:dalloway

# Lucene: Suche mit Platzhaltern

Wildcard ?: text:dall?way → dalloway, dallaway…

Wildcard *: text:lighthou*

Einschränkung: nicht in Phrasen, nicht als erstes Zeichen

# Lucene: Unscharfe Suche

text:dalloway~

text:dalloway~1

Je höher der Wert nach der Tilde, desto unschärfer die Suche, Defaultwert ist 1, Maximalwert 2 – Levenshtein-Distanz

Einschränkungen:

- nicht in Phrasen (dort ist es Phrasen-Editierdistanz),
- nicht als erstes Zeichen

# Lucene query string syntax in elasticsearch

```
GET /_search
{ "query":
   { "query_string" :
     { "default_field" : "text", "query" : "this AND that OR thus" }
   }
 }
```

# Ranking / Scoring

Beim Ranking geht es darum, für eine gegebene Anfragezu ermitteln, wie gut ein Dokument passt, um die Reihenfolge der Ergebnisse festzulegen.

Einige Parameter:

- Gewicht der Anfrage-Terme in der Query
- - Gewicht der Dokumententerme
  - Abhängig von der Termfrequenz im Dokument
  - Abhängig von der Termfrequenz über alle Dokumente
  - Abhängig vom Feld, in dem ein Term auftritt (Dokumentenstruktur)
- - Statischer Score des Dokuments / Felds

# Rankingfunktionen

- (Okapi) BM25

  - D: Dokument
  - q: query-Terme
  - k, b: Parameter (1.2, 0.75)

BM25F: + Felderinformation

# Lucene scoring I

**score(q,d) =**

**coord(q,d) · ∑( tf(t in d) · idf(t)² · t.getBoost() · norm(t,d) )**

Wobei:

- tf(t in d) = frequency½
- idf(t) = 1 + log (numDocs/(docFreq+1))
- coord(q,d) Ist eine Bewertungsfaktor, der darauf basiert, wie viele der Anfrageterme im Dokument gefunden wurden. Standard = 1
- t.getBoost() Ist ein Boost für term t in Anfrage q, wie in der Anfrage(manuell) spezifiziert
  Bsp: *jakarta^4 apache*

# Lucene scoring II

**score(q,d) =**

**coord(q,d) · queryNorm(q) · ∑( tf(t in d) · idf(t)$^2$ · t.getBoost() · norm(t,d) )**

***norm(t,d)*** encapsulates a few (indexing time) boost and length factors:

- **Document boost** - set by calling doc.setBoost() before adding the document to the index.
- **Field boost** - set by calling field.setBoost() before adding the field to a document.
- **lengthNorm** - computed when the document is added to the index in accordance with the number of tokens of this field in the document, so that shorter fields contribute more to the score. LengthNorm is computed by the similarity class in effect at indexing.

# Lucene scoring III

In der Formel fehlt:

- Termnähe (proximity) als Faktor

Mögliche Option:

~ "sloppy phrase query": text:"Leonce Lena"~100

- → max Distanz 100, sortiert nach Distanz