

ΜΥΕ003: Ανάκτηση Πληροφορίας

Διδάσκουσα: Ευαγγελία Πιτουρά

Εισαγωγή στη Lucene. Περιγραφή Εργασίας.

Εργασία

Θέμα: Σχεδιασμός και υλοποίηση ενός συστήματος αναζήτησης πληροφορίας από ειδησεογραφικά άρθρα.

- Το κύριο μέρος της εργασίας αφορά αναζήτηση με λέξεις κλειδιά (80%)
- Η αναζήτηση αυτή θα επεκταθεί για την υποστήριξη διανυσματικής αναζήτησης (20%)

Για την υλοποίηση, θα χρησιμοποιήσετε τη βιβλιοθήκη **Lucene**

- Η εργασία μετράει σε **ποσοστό 50%** στο βαθμό σας στο μάθημα.

Σημαντικές Ημερομηνίες

Θα ανακοινωθεί αύριο (28/3)

Καταληκτικές Ημερομηνίες

- Δευτέρα 14 Απριλίου 2025: Σύντομη περιγραφή του σχεδιασμού της εφαρμογής και της συλλογής εγγράφων
- **Παρασκευή 23 Μαΐου 2025:** Παράδοση εργασίας
- Εβδομάδα 26 Μαΐου 2025: Προφορική εξέταση (οι ακριβείς ημέρες και ώρες θα ανακοινωθούν αργότερα)

Οι καταληκτικές ημερομηνίες είναι αυστηρές, **δεν γίνονται δεκτές αργοπορημένες παραδόσεις ασκήσεων**

Η εργασία **δεν** μπορεί να παραδοθεί τον Σεπτέμβρη

Διαδικαστικά

- Παράδοση μέσω edcourse
- Τελική εργασία στο github
- Η εργασία μπορεί να γίνει σε ομάδες έως 2 ατόμων.

Απορίες/ερωτήσεις μέσω edsteem

Βοηθοί για την εργασία

Γιώργος Μπαλανος

Βαγγέλης Χασάνης

Προαιρετική Εργασία

Υλοποίηση RAG για την ίδια συλλογή

Θα ανακοινωθεί την επόμενη εβδομάδα

Παράδοση: Παρασκευή 23 Μαΐου 2025

Απαλλακτική: 50% του βαθμού
Αντί για την τελική εξέταση

Περιεχόμενα

- Ευρετήρια ζώνης
- Περίληψη αποτελεσμάτων
- Lucene (βασική εισαγωγή)
- Εργασία (λίγα περισσότερα)

Παραμετρικά ευρετήρια και ευρετήρια ζώνης

- Για αρκετά έγγραφα εκτός του κειμένου, επιπρόσθετη πληροφορία: είναι χωρισμένα σε **τμήματα** με διαφορετική σημασία:
 - Συγγραφέας
 - Τίτλος
 - Ημερομηνία δημοσίευσης
 - Γλώσσα
 - κλπ
- Καλούνται και μεταδεδομένα (metadata) του εγγράφου

Παραμετρικά ερωτήματα

- Συχνά αναζήτηση με βάση τα μεταδεδομένα
 - Π.χ., βρες όλα τα έγγραφα που έγραψε το 1601 ο William Shakespeare, που περιέχουν τις λέξεις *alas poor Yorick*
 - Year = 1601 είναι παράδειγμα ενός πεδίου (field)
 - Επίσης, author last name = shakespeare, κλπ
- Ερωτήματα με πεδία (παραμετρικά ερωτήματα) συνήθως ερμηνεύονται ως **συζευκτικά** (conjunction, σύνδεση με AND) πρέπει να ισχύουν όλα

Παραμετρική αναζήτηση

Bibliographic Search

Search category	Value
Author	Example: Widens, J or Garcia-Molina
Title	Also a part of the title possible
Date of publication	Example: 1997 or 1997 or 1997 limits the search to the documents appeared in, before and after 1997 respectively
Language	Language the document was written in English ▾
Project	ANY ▾
Type	ANY ▾
Subject group	ANY ▾
Sorted by	Date of publication ▾

Ζώνη

Επίσης, συχνά τα *έγγραφα είναι χωρισμένα σε τμήματα (ζώνες)* με διαφορετική σημασία:


- Η *ζώνη* (zone) είναι μια περιοχή ενός εγγράφου που περιέχει κείμενο, π.χ.,
 - Title (τίτλος)
 - Abstract (περίληψη)
 - References (αναφορές) ...
- Πρέπει να τροποποιήσουμε τα ευρετήρια ώστε να επιτρέψουμε σχετικά ερωτήματα όπως
 - πχ, βρες έγγραφα με τον όρο «merchant» στον τίτλο τους
- Επίσης χρήσιμα αν θέλουμε να δώσουμε *μεγαλύτερο βάρος* σε εμφανίσεις όρων στον τίτλο ή στην περίληψη

Ευρετήριο πεδίου

- **Ευρετήριο πεδίου** (Field index) ή παραμετρικό ευρετήριο (parametric index): καταχωρήσεις (postings) για κάθε πεδίο
 - Συχνά ειδικού τύπου (πχ δέντρα διαστήματος για ημερομηνίες)

Βασικό ευρετήριο ζώνης encoded στο λεξικό (διαφορετικές λίστες καταχωρήσεων)


Ένα ευρετήριο για κάθε ζώνη/πεδίο:



Επέκταση καταχωρήσεων

Ένα ενιαίο ευρετήριο για κάθε έγγραφο

Η πληροφορία ζώνης στις λίστες καταχώρησης:



- Ευρετήριο πεδίου: καλύτερο για παραμετρικά ερωτήματα
- Επέκταση καταχωρήσεων: ποιο αποδοτικό για υπολογισμό «ενιαίας» ζυγισμένης συνάφειας

Περιεχόμενα

- Ευρετήρια ζώνης
- **Περίληψη αποτελεσμάτων**
- Lucene (βασική εισαγωγή)
- Εργασία (λίγα περισσότερα)

Περιλήψεις αποτελεσμάτων

- Αφού έχουμε διατάξει τα έγγραφα που ταιριάζουν με το ερώτημα, θέλουμε να τα παρουσιάσουμε στο χρήστη
- Πιο συχνά ως μια λίστα από **τίτλους** εγγράφων, URL, μαζί με μια μικρή **περίληψη** (**result snippet**), aka “10 blue links”

[John McCain](#)

John McCain 2008 - The Official Website of **John McCain's** 2008 Campaign for President ... African American Coalition; Americans of Faith; American Indians for **McCain**; Americans with ...
www.johnmccain.com · [Cached page](#)

[JohnMcCain.com - McCain-Palin 2008](#)

John McCain 2008 - The Official Website of **John McCain's** 2008 Campaign for President ... African American Coalition; Americans of Faith; American Indians for **McCain**; Americans with ...
www.johnmccain.com/Informing/Issues · [Cached page](#)

[John McCain News- msnbc.com](#)

Complete political coverage of **John McCain**. ... Republican leaders said Saturday that they were worried that Sen. **John McCain** was heading for defeat unless he brought stability to ...
www.msnbc.msn.com/id/16438320 · [Cached page](#)

[John McCain | Facebook](#)

Welcome to the official Facebook Page of **John McCain**. Get exclusive content and interact with **John McCain** right from Facebook. Join Facebook to create your own Page or to start ...
www.facebook.com/johnmccain · [Cached page](#)

Περιλήψεις αποτελεσμάτων

- Η περιγραφή του εγγράφου είναι *κρίσιμη* γιατί συχνά οι χρήστες βασίζονται σε αυτήν για να αποφασίσουν αν το έγγραφο είναι σχετικό
 - Δε χρειάζεται να διαλέξουν ένα-ένα τα έγγραφα με τη σειρά

Ο τίτλος αυτόματα από μεταδεδομένα, αλλά πώς να υπολογίσουμε τις περιλήψεις;

Περιλήψεις αποτελεσμάτων

Δύο βασικά είδη περιλήψεων

- Μια **στατική περίληψη** (static summary) ενός εγγράφου είναι πάντα η ίδια *ανεξάρτητα από το ερώτημα* που έθεσε ο χρήστης
- Μια **δυναμική περίληψη** (dynamic summary) εξαρτάται από το ερώτημα (**query-dependent**). Προσπαθεί να εξηγήσει γιατί το έγγραφο ανακτήθηκε για το *συγκεκριμένο* κάθε φορά ερώτημα

Στατικές Περιλήψεις

- Σε ένα τυπικό σύστημα η στατική περίληψη είναι ένα υποσύνολο του εγγράφου
- Απλός ευριστικός: οι πρώτες περίπου 50 λέξεις του εγγράφου
 - cached κατά τη δημιουργία του ευρετηρίου
- Πιο εξελιγμένες μέθοδοι (text summarization) – βρες από κάθε έγγραφο κάποιες **σημαντικές προτάσεις**
 - Απλή γλωσσολογική επεξεργασία (NLP) με ευριστικά για να βαθμολογηθεί κάθε πρόταση (πληροφορία θέσης: πρώτη και τελευταία παράγραφος, πρώτη και τελευταία πρόταση στην παράγραφο, και περιεχομένου: σημαντικές λέξεις)
 - Η περίληψη αποτελείται από τις προτάσεις με το μεγαλύτερο βαθμό
- Ή και πιο περίπλοκη γλωσσολογική επεξεργασία για τη σύνθεση/δημιουργία περίληψης

Δυναμικές Περιλήψεις

- Παρουσίασε ένα ή περισσότερα «*παράθυρα*» (windows, snippets) μέσα στο έγγραφο που να περιέχουν αρκετούς από τους όρους του ερωτήματος
 - “*KWIC*” *snippets*: αναπαράσταση Keyword-in-Context

	christopher manning	<u>Christopher Manning, Stanford NLP</u> Christopher Manning, Associate Professor of Computer Science and Linguistics, Stanford University. nlp.stanford.edu/~manning/ - 12k - Cached - Similar pages
	christopher manning machine translation	<u>Christopher Manning, Stanford NLP</u> Christopher Manning, Associate Professor of Computer Science and Linguistics, ... computational semantics, machine translation, grammar induction, ... nlp.stanford.edu/~manning/ - 12k - Cached - Similar pages
	web images video christopher manning	<u>Christopher Manning, Stanford NLP</u> Christopher Manning, Associate Professor of Computer Science and Linguistics, Stanford University ... Chris Manning works on systems and formalisms that can ... nlp.stanford.edu/~manning/ - Cached

Δυναμικές Περιλήψεις

- Για τον υπολογισμό τους χρειαζόμαστε τα ίδια τα έγγραφα (δεν αρκεί το ευρετήριο)
- Cache εγγράφων – που πρέπει να ανανεώνεται
- Συχνά όχι όλο το έγγραφο αν είναι πολύ μεγάλο, αλλά κάποιο πρόθεμα του
- Βρες μικρά παράθυρα στα έγγραφα που περιέχουν όρους του ερωτήματος
 - Απαιτεί γρήγορη αναζήτηση παράθυρου στην cache των εγγράφων

Δυναμικές Περιλήψεις

- Βαθμολόγησε κάθε παράθυρο ως προς το ερώτημα
 - Με βάση διάφορα χαρακτηριστικά: το πλάτος του παραθύρου, τη θέση του στο έγγραφο, κλπ
 - Συνδύασε τα χαρακτηριστικά
- Δύσκολο να εκτιμηθεί η ποιότητα
- Positional indexes
- Ο χώρος που διατίθεται για τα παράθυρα είναι μικρός


Δυναμικές Περιλήψεις

Query: “new guinea economic development” Snippets (in bold) that were extracted from a document: . . .

In recent years, Papua New Guinea has faced severe economic difficulties and economic growth has slowed, partly as a result of weak governance and civil war, and partly as a result of external factors such as the Bougainville civil war which led to the closure in 1989 of the Panguna mine (at that time the most important foreign exchange earner and contributor to Government finances), the Asian financial crisis, a decline in the prices of gold and copper, and a fall in the production of oil. **PNG’s economic development record over the past few years is evidence that** governance issues underly many of the country’s problems. Good governance, which may be defined as the transparent and accountable management of human, natural, economic and financial resources for the purposes of equitable and sustainable development, flows from proper public sector management, efficient fiscal and accounting mechanisms, and a willingness to make service delivery a priority in practice. . . .

Quicklinks

- Για *navigational query* (όταν ψάχνουμε μια συγκεκριμένη σελίδα) όπως **united airlines** οι χρήστες πιθανόν να ικανοποιούνται από τη σελίδα www.united.com
- Quicklinks παρέχουν navigational cues σε αυτή τη σελίδα



Google

Web  [Show options...](#)

[United Airlines Flights](#)
www.OneTravel.com/United-Airlines Save \$10 Instantly on **United Airlines** Airfares.

[United Airlines - Airline Tickets, Airline Reservations, Flight ...](#)
Airline tickets, **airline** reservations, flight airfare from **United Airlines**. Online reservation **airline** ticket purchase, electronic tickets, flight search, ...  [Show stock quote for UUA](#)
www.united.com/ - [Cached](#) - [Similar](#) -   

Search options	Baggage
EasyCheck-in Online	Services & information
Mileage Plus	Itineraries & check-in
My itineraries	Planning & booking

[More results from united.com »](#)

united airlines

Search Pad

SearchScan - On

102,000,000 results for
united airlines:

Show All

United Air Lines

Wikipedia

Also try: [united airlines reservations](#), [united airlines flight](#), [More...](#)

United Airlines - Airline Tickets, Airline Reservations ... (Nasdaq: [UAUA](#))

Official site for **United Airlines**, commercial air carrier transporting people, property, and mail across the U.S. and worldwide.

[www.united.com](#) - 65k - [Cached](#)

[Planning & Booking](#)

[Shop for Flights](#)

[Itineraries & Check-in](#)

[Special Deals](#)

[Mileage Plus](#)

[Flight Status](#)

[Services & Information](#)

[Customer Service](#)

[more results from united.com »](#)

bing

united airlines



UNITED AIRLINES

United **Airline**
Fleet

United **Airline**
Schedule

United Airlines
Reservations

United **Airline** **Jobs**

Reference

ALL RESULTS

[Cheap Flight Tickets](#) · [www.CheapOair.com](#)

CheapOair - The Only Way to Go!! Find Over 18 Million Exclusive Fares.

[Fly United Airlines](#) · [www.OneTravel.com/United-Airline](#)

Save \$10 Instantly on **United Airlines** Flights. Book Now, Hurry!

Best match

United Airlines - Airline Tickets, **Airline** Reservations, Flight ...

[www.united.com](#) · Official site

Airline tickets, **airline** reservations, flight airfare from **United Airlines**. Online reservations, **airline** ticket purchase, electronic tickets, flight search, fares and availability ...

[Flights](#)

[Redeem miles](#)

[Check In Online](#)

[Children, pets, & assistance](#)

[My itineraries](#)

[Change your travel plans](#)

[Baggage](#)

[Special deals](#)

Customer service 800-864-8331


RELATED SEARCHES

United Airlines **Flight**
Status

US Airways

Continental Airlines

Εναλλακτικές αναπαραστάσεις;



Περιεχόμενα

- Ευρετήρια ζώνης
- Περίληψη αποτελεσμάτων
- **Lucene (βασική εισαγωγή)**
- Εργασία (λίγα περισσότερα)

Εισαγωγή



- **Open source** search software
- **Lucene Core** provides **Java-based** indexing and search as well as spellchecking, hit highlighting and advanced analysis/tokenization capabilities
- Let you add search to your application, not a complete search system by itself -- **software library** not an application
- Written by Doug Cutting

Εισαγωγή

- An “engine” used by LinkedIn, Twitter, Netflix, Oracle, ...
 - and many more (see <http://wiki.apache.org/lucene-java/PoweredBy>)
- Ports/integrations to other languages
 - C/C++, C#, Ruby, Perl, PHP
 - **PyLucene**: a Python port of the Core project
 - Allows use of Lucene's text indexing and searching capabilities from Python.


<https://lucene.apache.org/pylucene/>

Μπορείτε να την κατεβάσετε από

<http://lucene.apache.org/core/>

Κάποια στοιχεία στην παρουσίαση αφορούν
προηγούμενες εκδόσεις

Βασικές έννοιες



Some features (indexing)

Scalable, high-performance indexing

- over 800GB/hour on modern hardware
- small RAM requirements -- only 1MB heap
- incremental indexing as fast as batch indexing
- index size roughly 20-30% the size of text indexed

Some features (search)

Powerful, accurate and efficient search algorithms

- *ranked* searching -- best results returned first
- many powerful *query types*: phrase queries, wildcard queries, proximity queries, range queries and more
- *fielded searching* (e.g. title, author, contents)
- *nearest-neighbor search* for high-dimensionality vectors
- sorting by any field
- multiple-index searching with merged results
- allows simultaneous update and searching
- flexible faceting, highlighting, joins and result grouping
- fast, memory-efficient and typo-tolerant suggesters
- pluggable ranking models, including the Vector Space Model and Okapi BM25
- configurable storage engine (codecs)

Στόχος της παρουσίασης: σύντομη εισαγωγή

Περισσότερες πληροφορίες

https://lucene.apache.org/core/10_1_0/index.html

- **Lucene tutorials**


<http://www.lucenetutorial.com/>

- Example updated to 9.x

<https://www.lucenetutorial.com/lucene-in-5-minutes.html>

- **Lucene demo**

https://lucene.apache.org/core/10_1_0/demo/index.html



<https://www.manning.com/books/lucene-in-action-second-edition>

Βασικές έννοιες: document

- The **unit** of search and index.
- **Indexing** involves adding Documents to an **IndexWriter**.
- **Searching** involves retrieving Documents from an index via an **IndexSearcher**.
- A document consists of one or more **Fields**
 - A Field is a name-value pair.
example: title, body, or metadata (creation time, etc)

Βασικές έννοιες: Fields

- You have to translate raw content into Fields
- Search a field using <field-name:term>,
 - e.g., title:lucene

Βασικές έννοιες: index

- Indexing in Lucene
 1. Create documents comprising of one or more Fields
 2. Add these Documents to an IndexWriter.

Βασικές έννοιες: search

Searching requires an index to have already been built.

- It involves
 1. Create a Query (usually via a `QueryParser`) and
 2. Handle this Query to an `IndexSearcher`, which returns a list of `Hits`.
- The `Lucene query language` allows the user to specify
 - which field(s) to search on,
 - which fields to give more weight to (boosting),
 - the ability to perform boolean queries (AND, OR, NOT) and
 - other functionality.

Neural (semantic) search in Lucene (solr)

Given a dense vector q that models the query (information need) calculate the distance (Euclidean, cosine, dot product, etc.) between q and every vector d that represents a document

DenseVectorField type
Knn Query Parser

Nearest Neighborhood Search

Proximity Neighborhood Graph

- Vertices (documents) are mapped to nodes
- Edges between “similar” vertices

Navigable small world graph

<https://sease.io/2022/01/apache-solr-neural-search.html>

<https://sease.io/2023/01/apache-solr-neural-search-tutorial.html>

Hybrid Search

Combine

vector search

keyword-search


<https://sease.io/2023/12/hybrid-search-with-apache-solr.html>

Lucene in a search system: index

Lucene in a search system: **index**

Steps

1. Acquire content
2. Build document
3. **Analyze** document
4. **Index** documents



Step 1: Acquire and build content



Not supported by core Lucid

Collection depending on type may require:

- Crawler or spiders (web)
- Specific APIs provided by the application (e.g., Twitter, FourSquare, imdb)
- Scrapping <https://pypi.org/project/beautifulsoup4/>
- Complex software if scattered at various location, etc

Complex documents (e.g., XML, JSON, relational databases, pptx etc)

Tika the Apache Tika™ toolkit detects and extracts metadata and text from over a thousand different file types (such as PPT, XLS, and PDF)

<http://tika.apache.org/>

Step 1: Acquire and build content



OpenNLP library is a machine learning based toolkit for the processing of natural language text. It supports the most common NLP tasks, such as tokenization, sentence segmentation, part-of-speech tagging, named entity extraction, language detection, chunking (extracting sentences from unstructured text), parsing, and coreference resolution (find all expressions that refer to the same entity in the text)

<https://opennlp.apache.org/>

Step 2: Build Documents

Create documents by adding fields

Fields may be

- indexed or not
 - Indexed fields may or may not be analyzed (i.e., tokenized with an `Analyzer`)
 - *Non-analyzed fields view the entire value as a single token* (useful for URLs, paths, dates, social security numbers, ...)
- stored or not
 - Useful for fields that you'd like to display to users
- Optionally store term vectors and other options such as positional indexes

Step 2: Build Documents

Create documents by adding fields

Step 1 – Create a method to get a Lucene document from a text file.

Step 2 – **Create various fields** which are key value pairs containing keys as names and values as contents to be indexed.

Step 3 – Set field to be **analyzed or not, stored or not**

Step 4 – Add the newly-created fields to the document object and return it to the caller method.

Step 2: Build Documents (παλιότερη version)

```
private Document getDocument(File file) throws IOException {  
    Document document = new Document();  
  
    //index file contents  
    Field contentField = new Field(LuceneConstants.CONTENTES,  
    new FileReader(file))  
    //index file name  
    Field fileNameField = new Field(LuceneConstants.FILE_NAME, file.getName(), Field.Store.YES,Field.Index.NOT_ANALYZED);  
  
    //index file path  
    Field filePathField = new Field(LuceneConstants.FILE_PATH, file.getCanonicalPath(), Field.Store.YES,Field.Index.NOT_ANALYZED);  
  
    document.add(contentField);  
    document.add(fileNameField);  
    document.add(filePathField);  
  
    return document;  
}
```

Step 3:analyze and index

Create an `IndexWriter` and add documents to it with `addDocument()`;

Core indexing classes

- Analyzer

- Extracts tokens from a text stream

- IndexWriter

- create a new index, open an existing index, and
 - add, remove, or update documents in an index

- Directory

- Abstract class that represents the location of an index

παλιότερη version

```
Analyzer analyzer = new StandardAnalyzer();
```

```
// INDEX: Store the index in memory: (για την εργασία θα το αποθηκεύστε στο δίσκο – θα δημιουργηθεί μια φορά στην αρχή)
```

```
Directory directory = new RAMDirectory();
```

```
// To store an index on disk, use this instead:
```

```
// Directory directory = FSDirectory.open("/tmp/testindex");
```

```
IndexWriterConfig config = new IndexWriterConfig(analyzer);
```

```
IndexWriter iwriter = new IndexWriter(directory, config);
```

```
Document doc = new Document();
```

```
String text = "This is the text to be indexed.";
```

```
doc.add(new Field("fieldname", text, TextField.TYPE_STORED));
```

```
iwriter.addDocument(doc);
```

```
iwriter.close();
```

```
// SEARCH: Now search the index:
```

```
DirectoryReader ireader = DirectoryReader.open(directory);
```

```
IndexSearcher isearcher = new IndexSearcher(ireader);
```

```
// Parse a simple query that searches for "text":
```

```
QueryParser parser = new QueryParser("fieldname", analyzer);
```

```
Query query = parser.parse("text");
```

```
ScoreDoc[] hits = isearcher.search(query, null, 1000).scoreDocs;
```

```
// Iterate through the results:
```

```
for (int i = 0; i < hits.length; i++) {
```

```
    Document hitDoc = isearcher.doc(hits[i].doc);
```

```
}
```

```
ireader.close();
```

```
directory.close();
```

Using Field options

Index	Store	TermVector	Example usage
NOT_ANALYZED	YES	NO	Identifiers, telephone/SSNs, URLs, dates, ...
ANALYZED	YES	WITH_POSITIONS_OFFSETS	Title, abstract
ANALYZED	NO	WITH_POSITIONS_OFFSETS	Body
NO	YES	NO	Document type, DB keys (if not used for searching)
NOT_ANALYZED	NO	NO	Hidden keywords

Analizers

Tokenizes the input text

- Common Analyzers
 - WhitespaceAnalyzer
Splits tokens on whitespace
 - SimpleAnalyzer
Splits tokens on non-letters, and then lowercases
 - StopAnalyzer
Same as SimpleAnalyzer, but also removes stop words
 - StandardAnalyzer
Most sophisticated analyzer that knows about certain token types, lowercases, removes stop words, ...

Analysis examples

“The quick brown fox jumped over the lazy dog”


- `WhitespaceAnalyzer`
 - `[The] [quick] [brown] [fox] [jumped] [over] [the] [lazy] [dog]`
- `SimpleAnalyzer`
 - `[the] [quick] [brown] [fox] [jumped] [over] [the] [lazy] [dog]`
- `StopAnalyzer`
 - `[quick] [brown] [fox] [jumped] [over] [lazy] [dog]`
- `StandardAnalyzer`
 - `[quick] [brown] [fox] [jumped] [over] [lazy] [dog]`

More analysis examples

- “XY&Z Corporation – xyz@example.com”
- WhitespaceAnalyzer
 - [XY&Z] [Corporation] [-] [xyz@example.com]
- SimpleAnalyzer
 - [xy] [z] [corporation] [xyz] [example] [com]
- StopAnalyzer
 - [xy] [z] [corporation] [xyz] [example] [com]
- StandardAnalyzer
 - [xy&z] [corporation] [xyz@example.com]

Lucene in a search system: **search**

Lucene in a search system: search



Search User Interface (UI)

No default search UI, but many useful modules

General instructions

- Simple (do not present a lot of options in the first page)
 search box better than 2-step process
- Result presentation is very important
 - highlight matches
 - make sort order clear, etc

Core searching classes

■ QueryParser

- Parses a textual representation of a query into a Query instance
- Constructed with an analyzer used to interpret query text in the same way as the documents are interpreted

■ Query

- Contains the results from the QueryParser which is passed to the searcher
- Abstract query class
- Concrete subclasses represent specific types of queries, e.g., matching terms in fields, boolean queries, phrase queries, ...

■ IndexSearcher

- Central class that exposes several search methods on an index
- Returns **TopDocs** with max n hits

παλιότερη version

```
Analyzer analyzer = new StandardAnalyzer();
```

//INDEX: Store the index in memory: (για την εργασία θα το αποθηκεύστε στο δίσκο – θα δημιουργηθεί μια φορά στην αρχή))

```
Directory directory = new RAMDirectory();
```

// To store an index on disk, use this instead:

```
// Directory directory = FSDirectory.open("/tmp/testindex");
```

```
IndexWriterConfig config = new IndexWriterConfig(analyzer);
```

```
IndexWriter iwriter = new IndexWriter(directory, config);
```

```
Document doc = new Document();
```

```
String text = "This is the text to be indexed.";
```

```
doc.add(new Field("fieldname", text, TextField.TYPE_STORED));
```

```
iwriter.addDocument(doc);
```

```
iwriter.close();
```

// QUERY: Now search the index:

```
DirectoryReader ireader = DirectoryReader.open(directory);
```

```
IndexSearcher isearcher = new IndexSearcher(ireader);
```

// Parse a simple query that searches for "text":

```
QueryParser parser = new QueryParser("fieldname", analyzer);
```

```
Query query = parser.parse("text");
```

```
ScoreDoc[] hits = isearcher.search(query, null, 1000).scoreDocs;
```

// Iterate through the results:

```
for (int i = 0; i < hits.length; i++) {
```

```
    Document hitDoc = isearcher.doc(hits[i].doc);
```

```
}
```

```
ireader.close();
```

```
directory.close();
```

QueryParser syntax examples

Query expression	Document matches if...
java	Contains the term <i>java</i> in the default field
java junit java OR junit	Contains the term <i>java</i> or <i>junit</i> or both in the default field (<i>the default operator can be changed to AND</i>)
+java +junit java AND junit	Contains both <i>java</i> and <i>junit</i> in the default field
title:ant	Contains the term <i>ant</i> in the title field
title:extreme - subject:sports	Contains <i>extreme</i> in the title and not <i>sports</i> in subject
(agile OR extreme) AND java	Boolean expression matches
title:"junit in action"	Phrase matches in title
title:"junit action"~5	Proximity matches (within 5) in title
java*	Wildcard matches
java~	Fuzzy matches
lastmodified:[1/1/09 TO 12/31/09]	Range matches

Scoring

- Scoring function uses basic *tf-idf* scoring with
 - Programmable boost values for certain fields in documents
 - Length normalization
 - Boosts for documents containing more of the query terms
- IndexSearcher provides a method that explains the scoring of a document

Summary

To use Lucene

1. Create [Documents](#) by adding [Fields](#);
2. Create an [IndexWriter](#) and add documents to it with [addDocument\(\)](#);
3. Call [QueryParser.parse\(\)](#) to build a query from a string; and
4. Create an [IndexSearcher](#) and pass the query to its [search\(\)](#) method.

Summary: Lucene API packages

https://lucene.apache.org/core/9_10_0/core/index.html

The Lucene API is divided into several packages:

- **org.apache.lucene.analysis** defines an abstract Analyzer API for converting text from a **Reader** into a **TokenStream**, an enumeration of token Attributes. A TokenStream can be composed by applying TokenFilters to the output of a Tokenizer. Tokenizers and TokenFilters are strung together and applied with an Analyzer. analysis-common provides a **number of Analyzer** implementations, including StopAnalyzer and the grammar-based StandardAnalyzer.
- org.apache.lucene.codecs provides an abstraction over the encoding and decoding of the inverted index structure, as well as different implementations that can be chosen depending upon application needs.
- **org.apache.lucene.document** provides a simple Document class. A Document is simply a **set of named Fields**, whose values may be strings or instances of Reader.
- **org.apache.lucene.index** provides two primary classes: IndexWriter, which creates and adds documents to indices; and IndexReader, which accesses the data in the index.

Summary: Lucene API packages

https://lucene.apache.org/core/9_10_0/core/index.html

- `org.apache.lucene.search` provides data structures to represent queries (ie **TermQuery** for individual words, **PhraseQuery** for phrases, and **BooleanQuery** for boolean combinations of queries) and the **IndexSearcher** which turns queries into TopDocs. A number of QueryParsers are provided for producing query structures from strings or xml.
- `org.apache.lucene.store` defines an abstract class for storing persistent data, the **Directory**, which is a collection of named files written by an IndexOutput and read by an IndexInput. Multiple implementations are provided, but FSDirectory is generally recommended as it tries to use operating system disk buffer caches efficiently.
- `org.apache.lucene.util` contains a few handy data structures and util classes, ie FixedBitSet and PriorityQueue. `org.apache.lucene.analysis` defines an abstract Analyzer API for converting text from a Reader into a TokenStream, an enumeration of token Attributes.



<https://solr.apache.org/>

Lucene is a full-text search engine library, whereas Solr is a full-text search engine web application built on Lucene



Elasticsearch

<https://www.elastic.co/>

- Built on top of Lucene.
- ML functionality
- A distributed system/search engine for scaling horizontally
- Provides other features like thread-pool, [queues](#), node/[cluster](#) monitoring API, data monitoring API, Cluster management, etc.
- Hosts data on data [nodes](#). Each data node hosts one or more [indices](#), and each index is divided into [shards](#) with each shard holding part of the index's data. Each shard created in Elasticsearch is a separate Lucene instance or process.

Περιεχόμενα

- Ευρετήρια ζώνης
- Περίληψη αποτελεσμάτων
- Lucene (βασική εισαγωγή)
- Εργασία (λίγα περισσότερα)

Συλλογή εγγράφων

Η εργασία αφορά στο σχεδιασμό και υλοποίηση ενός συστήματος αναζήτησης πληροφορίας από ειδησεογραφικά άρθρα.

- CNN news από το 2011 έως το 2022

Μπορείτε να κατεβάσετε τα άρθρα από το kaggle:

<https://www.kaggle.com/datasets/hadasu92/cnn-articles-after-basic-cleaning/data>

Η συλλογή σας θα πρέπει να περιλαμβάνει τουλάχιστον 1.000 από αυτά τα άρθρα.

Εργασία

- Αναζήτηση με λέξεις κλειδιά [80% του βαθμού]
- Διανυσματική Αναζήτηση [20% του βαθμού]

Εργασία

(α) Ανάλυση κειμένου και κατασκευή ευρετηρίου.

Η Lucene παρέχει τη δυνατότητα για stemming, απαλοιφή stop words, επέκταση συνωνύμων, κλπ.

Κάποιες λειτουργίες, όπως η διόρθωση τυπογραφικών λαθών, ή η επέκταση ακρωνύμων, μπορούν να γίνουν εναλλακτικά κατά τη διάρκεια της αναζήτησης (τροποποιώντας το ερώτημα).

Επιλέξτε το είδος της ανάλυσης που θεωρείτε κατάλληλο και εξηγείστε την επιλογή σας.

Εργασία

(β) Αναζήτηση

Το σύστημά σας θα πρέπει να υποστηρίζει:

(α) αναζήτηση με λέξεις κλειδιά και

(β) αναζήτηση πεδίου, δηλαδή, εμφάνιση όρων σε συγκεκριμένα πεδία (π.χ., επικεφαλίδα, συγγραφέας, ημερομηνία).

Επιπρόσθετα, το σύστημά σας θα πρέπει να διατηρεί πληροφορία από την ιστορία των αναζητήσεων.

- Συγκεκριμένα, το σύστημα θα πρέπει να αποθηκεύει τα 20 προηγούμενα ερωτήματα μαζί με τα 5 πρώτα άρθρα της απάντησης.
- Χρησιμοποιήστε αυτή την πληροφορία με έναν κατάλληλο τρόπο ώστε να βελτιώσετε την αναζήτηση.

Εργασία

(γ) Παρουσίαση Αποτελεσμάτων.

Το σύστημά σας θα πρέπει να παρουσιάζει τα αποτελέσματα σε διάταξη με βάση τη συνάφεια τους με το ερώτημα όπως αυτή υπολογίζεται από την Lucene.

Επιπρόσθετα, θα πρέπει

- (1) Να παρουσιάζει τα αποτελέσματα ανά 10.
- (2) Να εμφανίζει τις λέξεις κλειδιά τονισμένες στο αποτέλεσμα.
- (3) Να παρέχει τη δυνατότητα αναδιάταξης των αποτελεσμάτων αλφαβητικά με βάση τον τίτλο τους.

Εργασία

Διανυσματική Αναζήτηση

Στόχος είναι η υποστήριξη διανυσματικής αναζήτησης.

Ο βασικός τρόπος διανυσματικής αναζήτησης που υποστηρίζει η Lucene είναι η δημιουργία ενός διανύσματος ανά έγγραφο.

Αν θέλετε, μπορείτε να χωρίσετε το έγγραφο σε μικρότερα τμήματα (chunks) και να δημιουργήσετε διανύσματα για αυτά, αλλά θα χρειαστεί ειδική διαχείριση και δεν ζητείται.

Εργασία

Διανυσματική Αναζήτηση

Θα πρέπει πρώτα να δημιουργήσετε διανύσματα (embeddings) με χρήση κάποιου υπάρχοντος μοντέλου (πχ all-MiniLM-L6-v2) και μετά να τα προσθέσετε σε αντίστοιχο πεδίο στο ευρετήριο (KnnVectorField).

Στη συνέχεια, θα δημιουργείται embeddings για κάθε ερώτημα και θα χρησιμοποιείτε το KnnVectorQuery για την επεξεργασία τους.

Χρήσιμη βιβλιοθήκη για τον υπολογισμό των embeddings: Deep Java Library (DJL)

Εργασία

Θα βαθμολογηθεί και η ευχρηστία του συστήματός σας.

Εργασία

Φάση 1:

Δύο στόχοι:

- (1) Εξοικείωση με τη συλλογή**
- (2) Αρχικά βήματα υλοποίησης**
 - (2α) Εγκατάσταση Lucene
 - (2b) Αρχικός σχεδιασμός

Τι θα παραδώσετε:

link στη github σελίδα που θα περιέχει

- (1) Περιγραφή της συλλογής και του Document (ποια fields)
- (2) Μια σύντομη (1-2 σελίδες) αρχική περιγραφή του συστήματος

Εργασία

Φάση 2:

Στόχος: Ολοκλήρωση της εργασίας

Τι θα παραδώσετε

Στη github σελίδα:

Περιγραφή της εργασίας (κείμενο)

Πηγαίος κώδικας

Ερωτήσεις;