Voyage au cœur d'un index Lucene

Comprendre les moteurs de recherche de l'intérieure

Quentin Lobbé
Phd @TélécomParisTech

Inspiré des travaux d'Adrien Grand
Software Ingeneer @Elasticsearch

Qui suis je ?

> 2015 Doctorant @Télécom Paris Tech

> 2013 – 2015 Ingénieur R&D Moteur de recherche @Twenga

www.twenga.fr

> 500 Millions d'offres ecommerce
> 15 langues
> 10000 requêtes secondes
> répondre en moins de 15 ms

Un moteur de recherche !?

> Le search est partout !

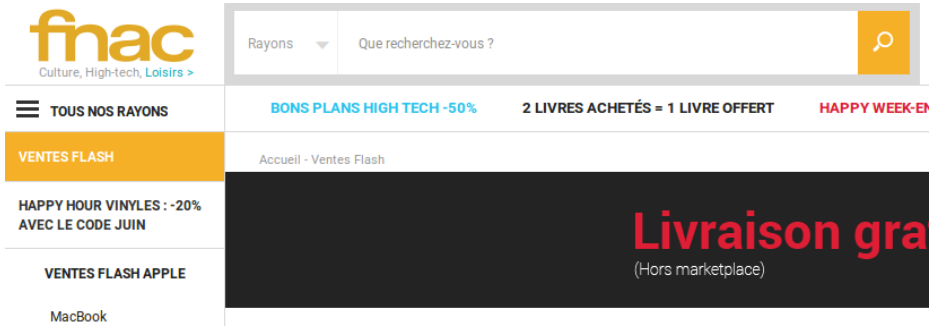

L'écosystème du Search en open source

> Fondation Apache – Java
> Librairie d'indexation
> 2001

> Fondation Apache – Java
> Serveur de search
> 2006

> Entreprise – Java
> Serveur de search (et bien plus …)
> 2012
> Valorisation à hauteur de 700 M$

Focus sur élasticsearch

elastic

> suite de logiciels open source autour du search
> stratégie basée sur la vente de service
> stack orientée big data, logs utilisateurs, logs machines

elasticsearch.

logstash

> traitement des logs

kibana

> visualisation on top of elasticsearch

beats, watcher, shield, marvel ...

Quelques ressources

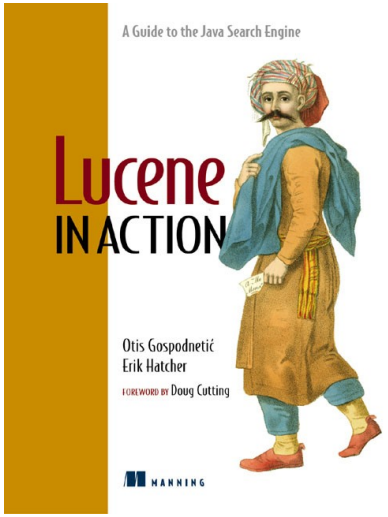

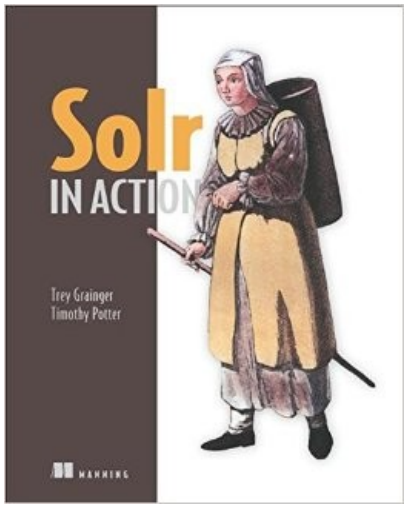

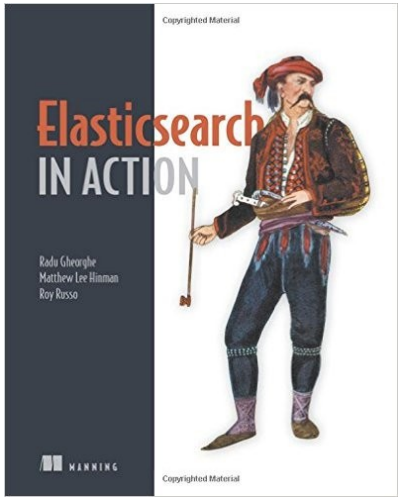

> https://www.elastic.co/blog
> https://lucidworks.com/blog/
> https://blog.algolia.com/
> blogs perso des commiters Lucene

Algolia → exalead → altavista

> Solution propriétaire, en SAAS

> Elasticsearch & Solr

Comment configurer un serveur de search ?

> Vocabulaire
> Rôles
> Schéma
> Analyseurs
> RequestHandlers
> Indexation

Un peu de vocabulaire

> requête : question posée par un humain ou une machine au moteur de recherche

> index (*collection*) : structure de données et / ou ensemble de documents

> document : objet texte à indexer (page html, offre e-commerce, roman, log …)

> champ (*field*) : contenu (texte, entier, booléen, binaire …) associé au document

> terme (*token*) : élément de texte élémentaire indexé

Comprendre les rôles d'un serveur de search

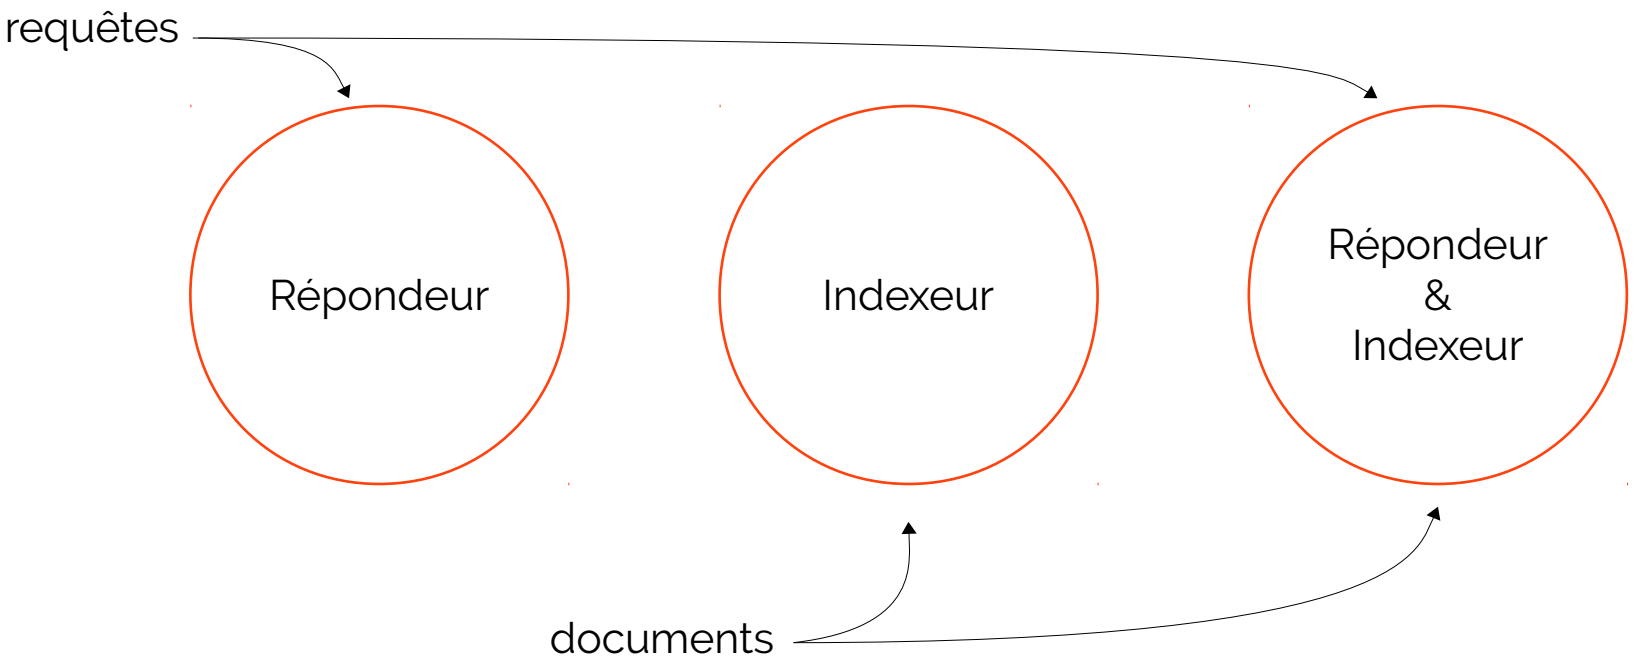

> Indexer est coûteux en terme de CPU et de mémoire

> Une application très sollicitée (beaucoup de requêtes) devra bien séparer les tâches

- ex : un master indexe et les slaves répondent (mettre en place une stratégie de mise à jour)

Définir un schéma / un mapping

> Le schéma décrit la structure du document à indexer

> On y définit des champs et des comportements / actions associés à chacun d'eux

> Le schéma doit être penser en terme d'indexation et de réponse aux requêtes

> Savoir construire un schéma demande beaucoup de pratique et des connaissances ad hoc

> Solr

```
<field name="id"  type="string"  indexed="true"  stored="true"  multiValued="false" required="true" />
<field name="active"  type="boolean"  indexed="true"  stored="true"  multiValued="false"/>
<field name="date"  type="date"   indexed="true"  stored="true"  docValues="true" multiValued="false"/>
```

> Elasticsearch

```
"id" : { "type" : "string", "index" : "analyzed", "analyzer" : "trans_standard" },

"description" : { "type" : "string", "index" : "analyzed", "analyzer" : "trans_standard" },

"created_at" : { "type" : "long", "index" : "not_analyzed" }, ( ... )
```

Les analyseurs : une combinaison de tokenizers et de filtres

> Un analyseur standardise le traitement des textes à indexer et des requêtes utilisateurs

> L'analyseur examine le texte d'un champ et génère un *token stream* sur lequel il applique et articule un ensemble de tokenizers et de filtres

```
Apache Lucene is a high-performance, full-featured text search engine library
```

> Un tokenizer divise le texte en termes (token) en se basant sur les espaces, la ponctuation …

- ex : whitespace tokenizer

```
Apache | Lucene | is | a | high-performance, | full-featured | text | search | engine | library
```

- Standard Tokenizer, Lower Case Tokenizer, N-Gram Tokenizer, Regular Expression Tokenizer, …

> Un filtre sélectionne, écarte, transforme … certains termes du *token stream*

```
Apache | Lucene ⟶ Lucene
```

> L'analyser intervient à l'indexation et au traitement d'une requête

Les requests handlers

> Un request handler définit la logique et les traitements appliqués aux requêtes

- ajouter des paramètres à la requête, les modifier, en supprimer ...
- jouer plusieurs requêtes en parallèle
- modifier le format de retour de la réponse

http://localhost:8800/solr/indexTest/select?q=toto&fq=type:website&fl=url

Introduction à l'indexation

> Plusieurs formats sont disponibles en entrée de l'indexation (xml, csv …)

> L'indexation peut se connecter à d'autres SBD (mongo db, mysql, hadoop …)

> Comment rendre les documents rapidement *searchable* ?

- Dupliquer les documents au besoin
- L'indexation est fonction des requêtes de search, penser son index en conséquence

> Troquer les performances de mise à jour pour une meilleure vitesse de search

- Grep vs indexation full-text
- Phrase queries vs shingles (n-grams)

> L'indexation est rapide

- 710 GB/h pour 4k docs !
- http://people.apache.org/~mikemccand/lucenebench/indexing.html

> Des stratégie avancée d'indexations peuvent être mises en place mais cela demande
Une bonne maîtrise de Lucene

> Back to basic

Comment fonctionne Lucene ?

> Indexer
> Insertion
> Suppression

Pourquoi s'intéresser à Lucene ?

> Pour comprendre le **coût d'usage** des APIs (éviter les boites noires)

- pour construire des applications de Search rapides et performantes
- pour savoir quand commiter son index
- Pour savoir qu'elle stratégie d'indexation utiliser
- pour savoir si Lucene est le bon outil pour votre application

> Pour comprendre l'**espace occupé** par un index

- Pourquoi les *Term Vectors* représentent la moitié de la taille d'un index !?
- J'ai supprimé 20 % de mes documents mais la taille de l'index n'a pas changée !?

> Pour se réapproprier la pratique du search

> Parce que c'est incroyablement intéressant

Mon premier index naïf

> Hash table ? Pourquoi pas mais :

- Associer un document à un mot
- Ne fonctionne pas pour les range / prefix queries par exemple > l'index doit être trié ou triable

> Tree structure (tree map ou B tree), une structure d'index classique de sbd (mysql, mongo …)

- Trié en amont pour des *range queries*
- O(log(n)) search

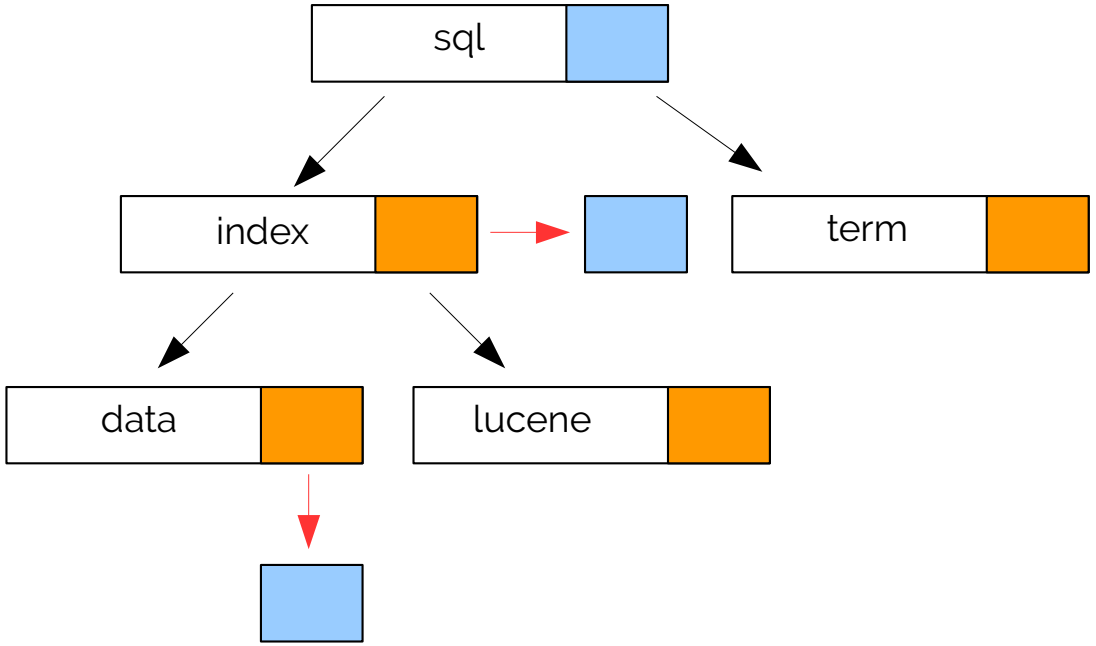

> Nous indexons deux livres

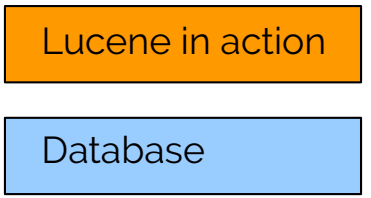

Mais Lucene ne fonctionne pas sur ce modèle !

> Découvrons la structure interne d'un index Lucene

Index Lucene

> Stocker les terms et les documents dans un tableau

- *binary search*

0	data	0,1
1	index	0,1
2	lucene	0
3	term	0
4	sql	1

0	Lucene in action
1	Database

Index Lucene

> Stocker les terms et les documents dans un tableau

- *binary search*

> segment

0	data	0,1
1	index	0,1
2	lucene	0
3	term	0
4	sql	1

term ordinal | term dict | postings list

0	Lucene in action
1	Database

doc id | document

Intersection entre 2 *postings lists*

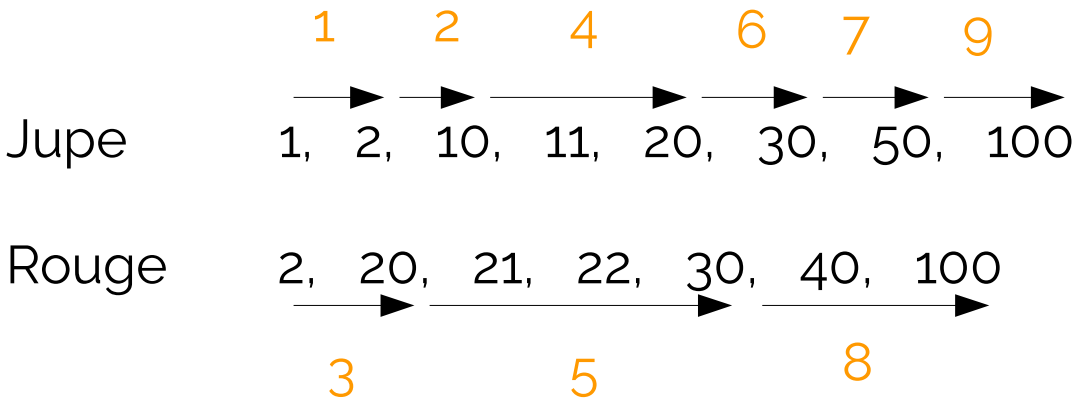

> la structure des postings lists permet de ne pas visiter l'ensemble des documents d'un index

- *leap-frog*

Insertion

> Insertion = enregistrer un nouveau segment

> Merger les segments quand ils sont trop nombreux

- Concaténer les docs, merger les terms dicts & postings lists (*merge sort*)

0	data	0
1	index	0
2	lucene	0
3	term	0

0	Lucene in action

0	data	0
1	index	0
2	sql	0

0	Database

0	data	0
1	index	0
2	lucene	0
3	term	0

0	Lucene in action
1	Database

> Comment ajouter un document ?

Insertion

> Insertion = enregistrer un nouveau segment

> Merger les segments quand ils sont trop nombreux

- Concaténer les docs, merger les terms dicts & postings lists (*merge sort*)

0	data	0
1	index	0
2	lucene	0
3	term	0

0	Lucene in action

0	data	1
1	index	1
2	sql	1

1	Database

0	data	0,1
1	index	0,1
2	lucene	0
3	term	0
4	sql	1

0	Lucene in action
1	Database

Suppression

> Suppression = changer un bit

> Ignorer les documents supprimés pour le search et le merge

> On va de préférence merger les segments avec beaucoup de suppressions

0	data	0,1
1	index	0,1
2	lucene	0
3	term	0
4	sql	1

0	Lucene in action	0
1	Database	1

live docs: 1 = live, 0 = deleted

Pour / Contre

> La mise à jour implique l'écriture d'un nouveau segment
- Mettre à jour un seul doc est coûteux, préférer une mise à jour par lots
- L'écriture est séquentielle

> Un segment n'est jamais réellement modifié sur le disque (*immutable data*)
- Filesystem-cache-friendly
- Lock-free !

> Les terms sont dédupliqués
- Sauver de l'espace pour les terms de haute fréquence

> Les docs sont uniquement identifiés par des *ordinal*
- Pratique pour la communication cross API
- Lucene peut interroger plusieurs indexes pour une même requête

> Les terms sont uniquement identifiés par des *ordinal*
- Important pour le tri : comparer des Long plutôt que des String
- Important pour les facets

> **Lucene peut utiliser plusieurs index contrairement à d'autre bases de données !**

D'autres fonctionnalités ?

> Nous n'avons vu que le Search

> Lucene permet d'aller plus loin encore

- term vectors
- norms
- numeric doc values
- binary doc values
- sorted doc values
- sorted set doc values

Term Vectors (une évolution de l'index inversé)

> Index inversé par documents (et non plus par terms)

> Utilisé pour *more-like-this* search (similarité entre deux documents)

> Utilisé pour le *highlighting*

0	data	0,1
1	index	0,1
2	lucene	0
3	term	0
4	sql	1

		terms	freq	pos	offset
0	Lucene in action	data	1	2	[10 ,14]
		index	1	3	[15,20]
		lucene	2	1,4	...
		term	2	7,9	...
1	Database	data	1	1	...
		index	1	3	...
		sql	3	2,4	...

> On peut facilement croisé l'index d'un document avec l'index de l'ensemble des documents
Pour trouver des documents similaires

Doc Values

> Associer un champ (*field*) à un document

> Une valeur par document stockée sous forme de colonne

> Numérique ou binaire

> Utilisé pour le trie et le ranking (score personnalisé)

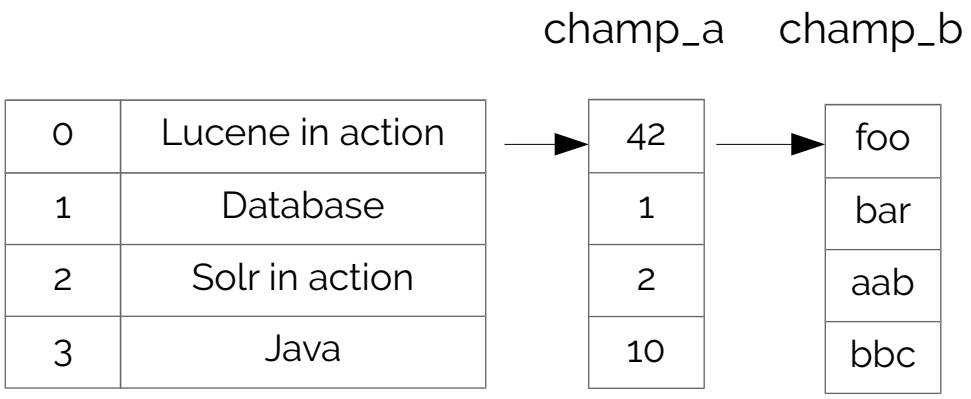

Sorted Doc Values

> Associer un champ à un document via un ordinal

- Champ monovalué : Améliore le trie
- Champ multivalué : Permet le faceting

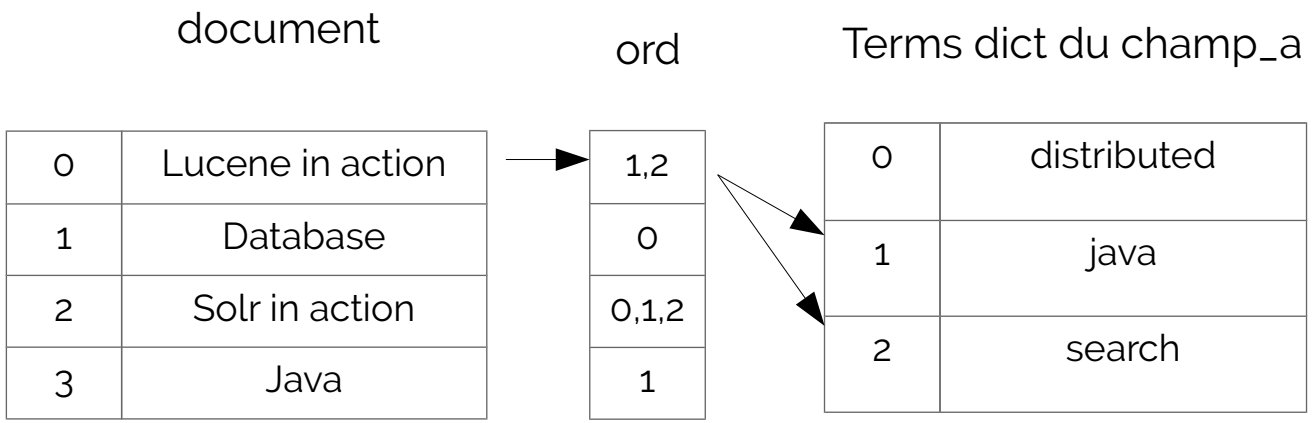

Faceting

> Recherche par dimension pour une requête (calculé à la volée)

> Effectuer un comptage par dimension

- Ex : taille de vêtements (M, L, XL ...) dans un site ecommerce

> Solution

- D'abord agréger les *ordinals* des documents dans une hash table
- Puis retrouver les valeurs de la dimension grâce aux *ordinals* des documents
- Linéaire O(#docs) en parcourant les ordinals
- Linéaire O(#dim) en parcourant beaucoup moins de dimensions

| 0 : 2, 1 : 3, 2 : 2 | ⟶ | distributed : 2, java : 3, search : 2 |

> Solution très efficace car les valeurs d'une dimension sont souvent peut nombreuses

Bon … mais concrètement …

Que se passe il lorsque l'on lance une requête ?

Soit la requête suivante

> ici, jouée dans Solr

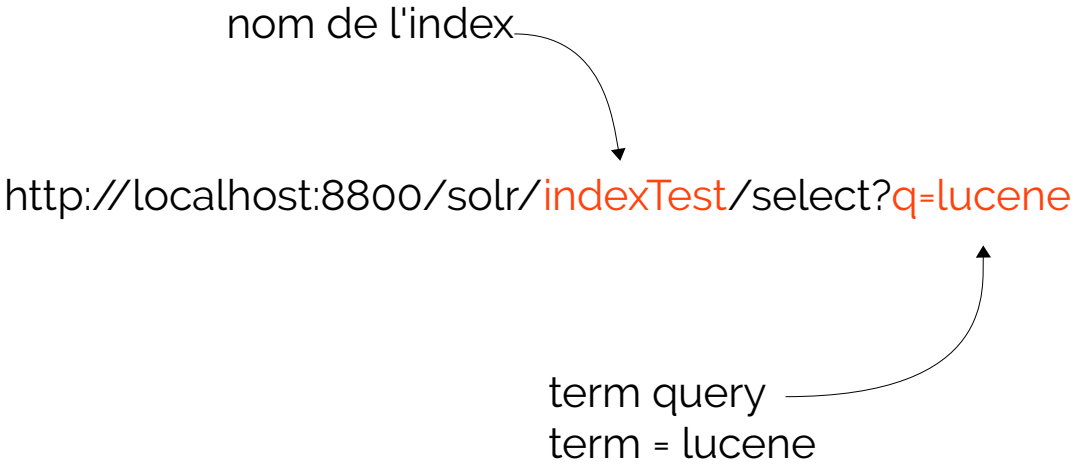

De la requête aux documents

> 4 étapes pour 4 structures de données

1. Terms Index → Retrouver le préfixe
2. Terms Dictionary → Retrouver le terme
3. Postings Lists → Retrouver les documents
4. Stored Fields → Retrouver les champs (le contenu)

Étape 1 : Terms index – partir des préfixes

> Parcourir chaque terme de l'index

- *In-memory FST storing* pour chaque préfixe
- Donne l'offset correspondant dans le terms dictionary
- Permet d'échouer rapidement si aucun terme n'a ce préfixe

> FST = finite state transducers

- Mapper chaque préfixe trié à son ordinal dans l'index
- Parcourir l'arbre nous donne l'ordinal

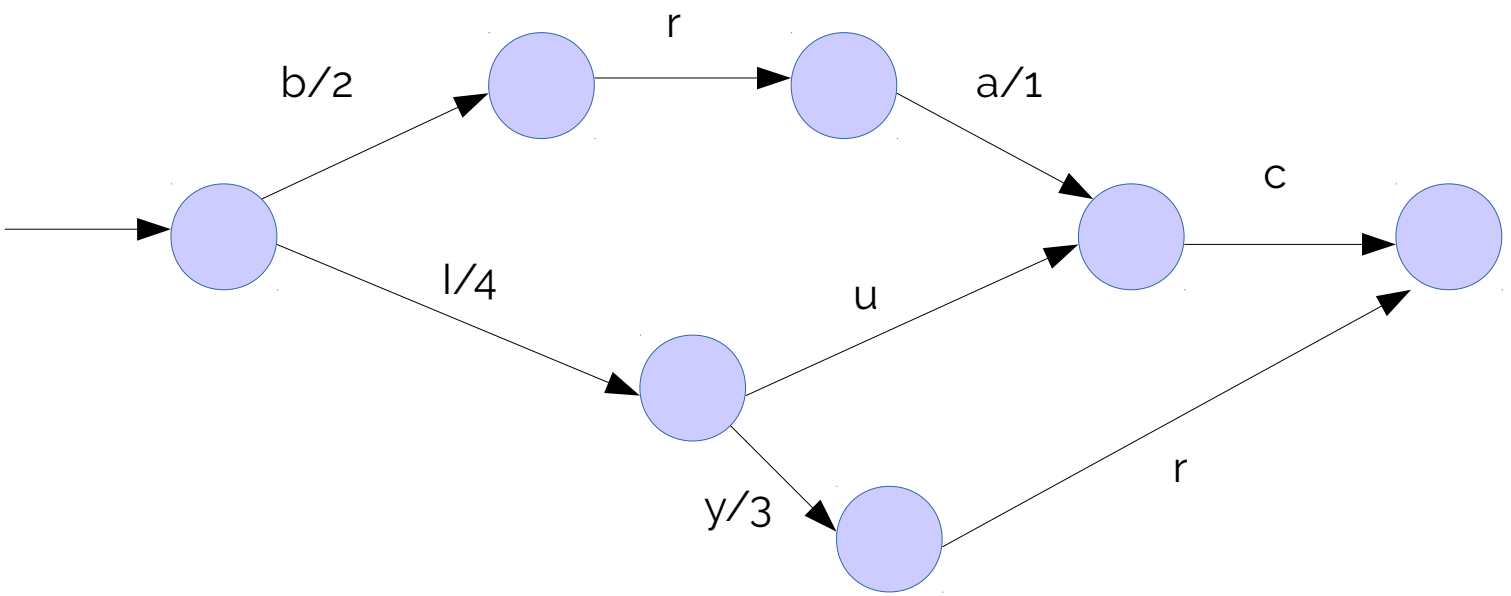

br = 2
brac = 3
luc = 4
lyr = 7

> pour q=lucene nous commencerons à chercher à l'ordinal 4 de l'index

Étape 2 : Terms dictionary

> Se rendre à l'offset du *terms dictionary* obtenu à l'étape 1

- Compression basée sur les préfixes communs

> Lire séquentiellement jusqu'à retrouver « lucene »

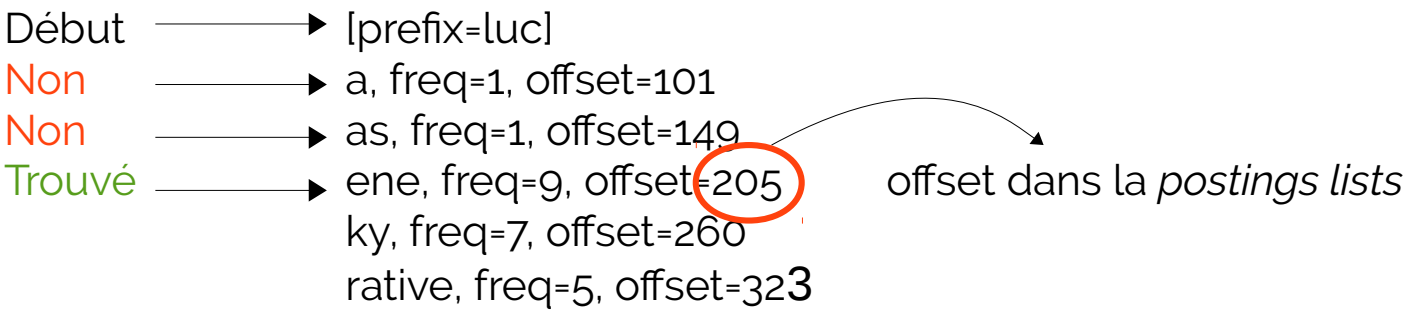

Étape 3 : Postings Lists

> L'objectif ici est de retrouver la liste de tous les documents contenant le terme « lucene »

> Postings Lists = Liste triée de *docs Ids* delta encodés

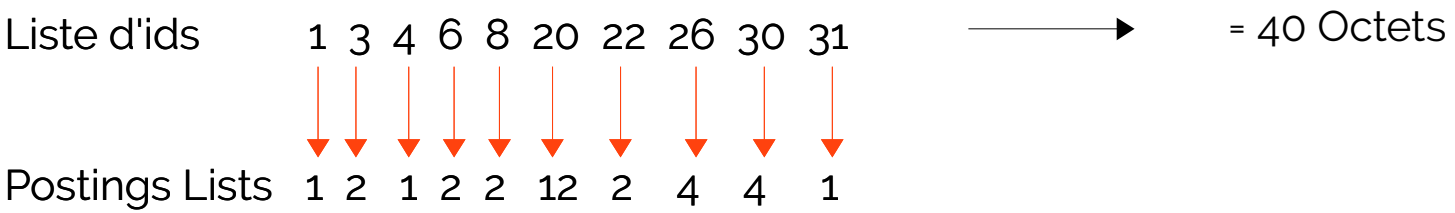

> Usuellement la *postings lists* est divisée en blocs fixes de N=128 valeurs

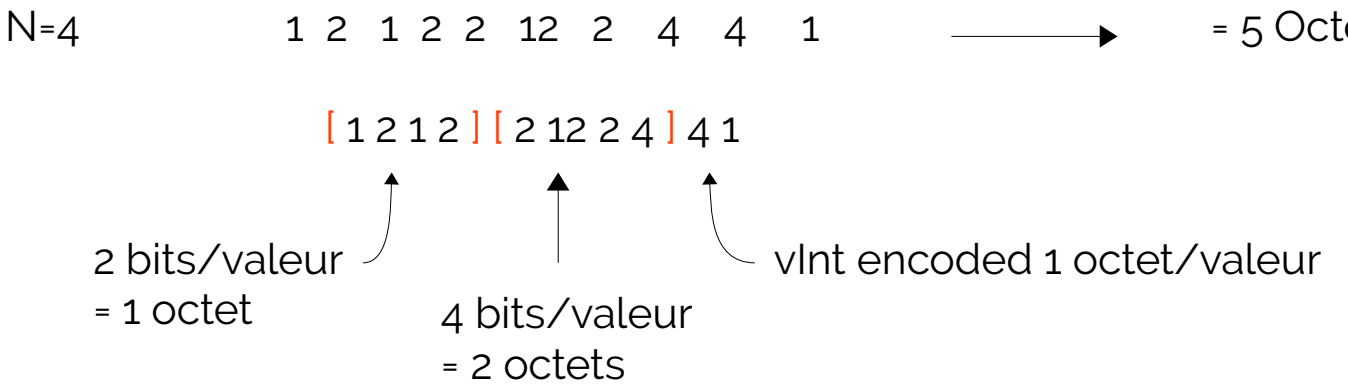

> Le nombre de bits alloués est fonction des valeurs (+ la valeur est petite – elle prend de place)

> vInt = code universel qui associe un nombre arbitraire d'octets à un entier (cf format MIDI)

Étape 4 : Stored fields

> 2 fichiers : l'index (*stored fields index*) et les données (*stored fields data*)

> Les données sont stockées séquentiellement dans un unique fichier

- d'abord en mémoire (buffer) puis sur disque tous les 16KB
- Compression LZ4

> Les *stored fields data* représentent 60 à 70 % de la taille de l'index

> La recherche dans l'index est simple (binary search), par bloc & docId, en mémoire

> Il faut décompresser chaque bloc puis un nouvel index nous donne l'offset de chaque document

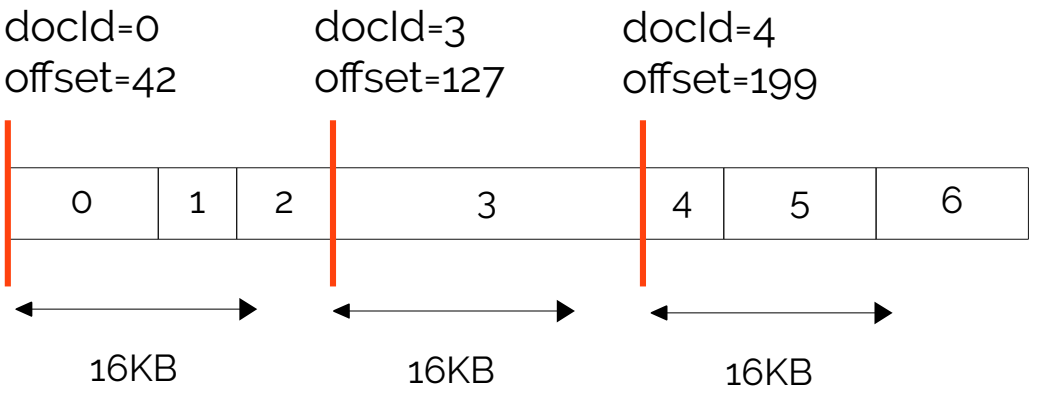

Le score lucene

> Comment sont ordonnés les documents résolvant ma requête ?

(normaliser le score
pour le rendre comparable
entre 2 requêtes
ici c'est la distance euclidienne)

boost à l'indexation
les champs les – volumineux
contribuent plus

$$score(q,d) = coord(q,d) \times queryNorm(q) * \sum_{t \in q} (tf(t \in d) * idf(t)^2 * t.getBoost() * norm(t,d))$$

nombre de termes
présents dans le doc

term freq

inverse doc freq

boost à la requête
défaut = 1

> Le score Lucene est modifiable ou remplaçable par un score maison

Merci !