

Bases de données documentaires et distribuées

Introduction à la recherche d'information

Auteurs: Raphaël Fournier-S'niehotta, Michel Crucianu, Marin Ferecatu
(fournier@cnam.fr, michel.crucianu@cnam.fr, marin.ferecatu@cnam.fr)

Département d'informatique
Conservatoire National des Arts & Métiers, Paris, France

Plan du cours

- 1 Moteurs de recherche
 - Bases documentaires et moteur de recherche
 - Moteurs

Motivation

- Un moteur de recherche est une application spécialisée dans la recherche, qui s'appuie sur un index.
- On a vu les avantages par rapport aux moteurs des bases de données
- La question naturelle : pourquoi ne pas utiliser directement le moteur de recherche comme gestionnaire des documents.
- Pourquoi s'embarasser de MongoDB alors qu'un moteur permet des recherches puissantes, efficaces, ainsi que le stockage et l'accès aux documents.

Motivation


- Un moteur de recherche est entièrement consacré à la recherche (donc à la lecture) la plus efficace possible de documents.
- il s'appuie pour cela sur des structures compactes, compressées, optimisées (les index inversés)
- En revanche, ce n'est pas un très bon outil pour les autres fonctionnalités d'une base de données.
- Le stockage par exemple n'est ni aussi robuste ni aussi stable,
- Il faut parfois reconstruire l'index à partir de la base originale.
- De même, les modifications fréquentes sont moins bien supportées
- Cela tient à la structure même des indexes (donc temps réel délicat)

Intégration

- L'utilisation la plus courante consiste donc à utiliser un moteur de recherche comme un **complément d'un serveur de base de données (relationnelle ou documentaire)**
- On confie aux moteurs de recherche des tâches que le serveur BD ne sait pas accomplir
- Essentiellement : les recherches non structurées.
- Dans le cas des bases NoSQL, l'absence fréquente de tout langage de requête fait du moteur de recherche associé un outil indispensable.
- Les moteurs sont aussi efficaces pour les requêtes structurées !

Inconvénient

- Il faut maintenir plusieurs systèmes
- il faut propager les données de l'un à l'autre
- Il existe des “rivers”, configurables pour cela (cours suivants)



Moteurs de recherche

- Nous allons vous présenter la pratique des moteurs de recherche
- Deux systèmes : Elastic Search, Solr
- Lucene : bibliothèque Java pour indexer et chercher du texte
- Les deux projets reposent sur Lucene
- Solr a transformé la librairie java Lucene en un serveur Web,
- Elasticsearch a métamorphosé Lucene en un serveur web distribué.
- Différences : entreprise / fondation, distribution des données, langage, etc.
- <http://solr-vs-elasticsearch.com/>


Moteurs de recherche

- Faciles d'installation tous les deux

```
docker pull snasello/elasticsearch
docker run -rm -it -p 9200:9200 snasello/elasticsearch --cluster.name=foobar
docker exec foobar /elasticsearch/bin/plugin --install mobz/elasticsearch-head
```

Test d'installation

```
{
  "status" : 200,
  "name" : "Serveur d'index",
  "cluster_name" : "philippe",
  "version" : {
    "number" : "1.5.0",
    "...": "...",
    "lucene_version" : "4.10.2"
  },
  "tagline" : "You Know, for Search"
}
```



ElasticSearch

- Toutes les interactions avec un serveur ElasticSearch passent par une interface REST basée sur JSON.
- ElasticSearch organise les données selon trois niveaux:
 - l'index regroupe des chemins d'accès à un collection de documents;
 - le type désigne le format du document indexé;
 - l'identifiant sert de clé d'accès à un document;
 - chaque document a un numéro de version.
- Pour indexer un de nos films dans l'index nfe204, avec le type movies, on exécute la commande suivante:

```
curl -X PUT http://localhost:9200/nfe204/movies/movie:1 -data-binary @movie_1.json
```
- Le PUT crée une "ressource" (au sens Web/REST du terme)
- Réponse :

```
{ "_index": "nfe204", "_type": "movies", "_id": "movie:1", "_version": 1, "created": true }
```

The screenshot shows the Elasticsearch Head web interface in a browser window titled "elasticsearch-head". The address bar shows "localhost:9200/_plugin/head/". The main content area displays the following information:

- URL: <http://localhost:9200/>
- Authentication: "Se connecter" button, user "philippe", and cluster health "Santé du cluster: green (1 1)".
- Navigation: "Aperçu", "Index", "Navigateur", "Recherche Structurée [+]", "Autres requêtes [+]", and "Info" dropdown.
- Cluster Overview: "Aperçu du cluster" section with "Sort Cluster", "View Aliases", and "Index Filter" options, and a "Rafraîchir" button.
- Index Details: "nfe204" index with "size: 7.03ki (7.03ki)" and "docs: 1 (1)". It includes "Info" and "Actions" dropdowns.
- Index Server: "Serveur d'index" section with a star icon, "Info" and "Actions" dropdowns, and a green box containing the number "0".

ElasticSearch

- Pour récupérer la ressource créée :

```
curl -X GET http://localhost:9200/nfe204/movies/movie:1
```