



Hands On Elasticsearch

Malloum Laya / David Pilato

Qui ?

\$ curl <http://localhost:9200/talk/speaker/TheMalloum>

```
{
  "nom" : "Malloum Laya",
  "jobs" : [
    { "boite" : "Logica", "mission" : "développeur", "duree" : 3 },
    { "boite" : "DGDDI (douane)", "mission" : "chef de projets", "duree" : 4 } ],
  "passions" : [ "famille", "informatique", "rap" ],
  "blog" : "http://malloum.fr/",
  "twitter" : [ "@TheMalloum", "@scrutmydocs" ],
  "email" : "malloum.laya@gmail.com"
}
```

\$ curl <http://localhost:9200/talk/speaker/dpilato>

```
{
  "nom" : "David Pilato",
  "jobs" : [
    { "boite" : "SRA Europe (SSII)", "mission" : "bon à tout faire", "duree" : 3 },
    { "boite" : "SFR", "mission" : "touche à tout", "duree" : 3 },
    { "boite" : "e-Brands / Vivendi", "mission" : "chef de projets", "duree" : 4 },
    { "boite" : "DGDDI (douane)", "mission" : "mouton à 5 pattes", "duree" : 8 },
    { "boite" : "IDEO Technologies", "mission" : "directeur technique", "duree" : 0 } ],
  "passions" : [ "famille", "job", "deejay" ],
  "blog" : "http://dev.david.pilato.fr/",
  "twitter" : [ "@dadoonet", "@elasticsearchfr", "@scrutmydocs" ],
  "email" : "david@pilato.fr"
}
```

Agenda

- Aperçu d'Elasticsearch
- Atelier 1 : indexons
- Atelier 2 : cherchons
- Atelier 3 : analysons



Elasticsearch

Les fondamentaux

Un moteur de recherche

- un moteur d'indexation de "documents"
- un moteur de recherche sur les index

Elasticsearch

- ◉ Moteur de recherche pour la génération NoSQL
- ◉ Basé sur le standard Apache Lucene
- ◉ Masque la complexité Java/Lucene à l'aide de services standards HTTP / RESTful / JSON
- ◉ Utilisable à partir de n'importe quelle technologie
- ◉ Ajoute la couche cloud manquante à Lucene avec distribution, réplication, fail over
- ◉ Très performant : distribution des calculs sur plusieurs nœuds
- ◉ C'est un **moteur**, pas une **interface graphique** !

Penser document !

- Changement de paradigme :
 - On ne pense plus SQL !
 - On indexe ce qu'on veut trouver !
- Un document, c'est :
 - Un objet JSON
 - Des propriétés simples (String, boolean, number)
 - Des propriétés complexes (array, object)
 - Des propriétés évoluées (geoloc, binary, attachments)

Ranger ses documents

- ◉ Elasticsearch met à notre disposition
 - ◉ Des types de document
 - ◉ Des index
- ◉ Le document 1 de type Tweet dans l'index Twitter :

```
{
  "text": "Bienvenue au Hands On Lab #elasticsearch pour #jduchess",
  "created_at": "2012-04-06T20:45:36.000Z",
  "source": "Twitter for iPad",
  "truncated": false,
  "retweet_count": 0,
  "hashtag": [ { "text": "elasticsearch", "start": 27, "end": 40 },
               { "text": "jduchess", "start": 47, "end": 55 } ],
  "user": { "id": 51172224, "name": "David Pilato",
            "screen_name": "dadoonet", "location": "France",
            "description": "Soft Architect, Project Manager, Senior Developer.\r\nAt this time, enjoying NoSQL
world : CouchDB, ElasticSearch.\r\nDeeJay 4 times a year, just for fun !" }
}
```

Agir avec Elasticsearch

- **API REST** : [http://host:port/\[index\]/\[type\]/\[_action/id\]](http://host:port/[index]/[type]/[_action/id])
Méthodes HTTP : GET, POST, PUT, DELETE

- **Documents**

- **curl -XPUT** <http://localhost:9200/twitter/tweet/1>
- **curl -XGET** <http://localhost:9200/twitter/tweet/1>
- **curl -XDELETE** <http://localhost:9200/twitter/tweet/1>

- **Recherche**

- **curl -XPOST** http://localhost:9200/twitter/tweet/_search
- **curl -XPOST** http://localhost:9200/twitter/_search
- **curl -XPOST** http://localhost:9200/_search

- **Meta données Elasticsearch**

- **curl -XGET** http://localhost:9200/twitter/_status
- **curl -XPOST** http://localhost:9200/_shutdown

Quelques notions

- **Nœud (node)** : Une instance d'Elasticsearch (~ machine ?)
- **Cluster** : Un ensemble de nœuds
- **Partition (shard)** : permet de découper un index en plusieurs parties pour y distribuer les documents
- **Réplication (replica)** : recopie d'une partition en une ou plusieurs copies dans l'ensemble du cluster
- **Partition primaire (primary shard)** : partition élue "principale" dans l'ensemble du cluster. C'est là que se fait l'indexation par Lucene. Il n'y en a qu'une seule par shard dans l'ensemble du cluster.
- **Partition secondaire (secondary shard)** : partitions secondaires stockant les replicas des partitions primaires.

Atelier 0

On prépare le terrain

Agir en Java

```
// Création du noeud. Il s'agit d'une instance d'Elasticsearch complète !  
Node node = NodeBuilder.nodeBuilder().node();  
  
// Les opérations courantes (put, get, search, delete) se font à l'aide d'un client !  
Client client = node.client();  
  
// On peut aussi faire des opérations d'administration (état du cluster, suppression index, ...) !  
AdminClient client = node.client().admin();
```

Atelier 0

• Récupérer la distribution Elasticsearch

ES 0.19.8, elasticsearch.yml modifié, plugins : MOBZ Head, BigDesk, Paramedic
`curl -OL -k https://github.com/downloads/elasticsearchfr/hands-on/elasticsearch-0.19.9-handson.zip`

• Cloner la repository

`git clone https://github.com/elasticsearchfr/hands-on.git`

• Regarder les sources du test 0

`src/test/java/org/elasticsearchfr/handson/ex0/NodeTest.java`

Atelier 1

On indexe des bières ;-)

Indexer en Java

```
// On peut fabriquer du json à la main
String json = "{ \"field\": \"value\" }";

// En utilisant le XContent d'Elasticsearch
XContentBuilder xcb = XContentFactory.jsonBuilder()
    .startObject()
    .field("field", "value")
    .endObject();
String json = xcb.toString();

// Sérialiser JavaBean en JSon
// On peut utiliser Jackson : http://wiki.fasterxml.com/JacksonHome
Beer beer = new Beer("Heineken", Colour.PALE, 0.33, 3);
ObjectMapper mapper = new ObjectMapper();
String json = mapper.writeValueAsString(beer);

// On peut indexer !
client.prepareIndex("index", "type").setSource(json).execute().actionGet();
client.prepareIndex("index", "type", "id").setSource(xcb).execute().actionGet();

// Insérer en mode Bulk
BulkRequestBuilder brb = node.client().prepareBulk();

// Ajouter des actions à réaliser
brb.add(new IndexRequest("index", "type").source(json));

// Exécuter le bulk
brb.execute().actionGet();
```

Récupérer en Java

```
// Récupérer
```

```
GetResponse gr = client.prepareGet("index", "type", "id").execute().actionGet();
```

```
// Désérialiser de JSon vers JavaBean
```

```
ObjectMapper mapper = new ObjectMapper();
```

```
Beer beer = mapper.readValue(gr.getSourceAsBytes(), Beer.class);
```

Effacer en Java

```
// Effacer  
client.prepareDelete("index", "type", "id").execute().get();
```

Atelier 1

- Regarder les sources du test 1

`src/test/java/org/elasticsearchfr/handson/ex1/IndexTest.java`

Atelier 2

On cherche des bières ;-)

Différentes recherches

Type	Description
<u>Match All</u>	Recherche tout le contenu (pratique avec des filtres)
<u>QueryString</u>	Recherche avec analyse, jokers (syntaxe Lucene possible* +, -, FROM, TO, ^)
<u>Term</u>	Recherche d'un terme sans analyse préalable
<u>Text</u>	Recherche d'un texte avec analyse (par défaut OR sur chaque token)
<u>Wildcard</u>	Recherche avec joker (*, ?)
<u>Bool</u>	Recherche multi-critères (MUST, MUST NOT, SHOULD)
<u>Range</u>	Recherche intervalle (>, >=, <, <=)
<u>Prefix</u>	Commence par (plus efficace que wildcard*)
<u>Filtered</u>	Filtrage (couplage de filtres et de queries)
<u>Fuzzy like this</u>	Permet des recherches par vraisemblance de termes
<u>More like this</u>	Permet de trouver des documents avec un minimum de termes

Chercher en Java

```
// Lancer une recherche
SearchResponse sr = client.prepareSearch().setQuery(qb).execute().actionGet();

// Fabriquer un QueryBuilder (qb)
// MatchAll
QueryBuilder qb = QueryBuilders.matchAllQuery();

// TermQuery
QueryBuilder qb = QueryBuilders.termQuery("field", "value");

// TextQuery
QueryBuilder qb = QueryBuilders.textQuery("field", "you can enter a text here");

// QueryString
QueryBuilder qb = QueryBuilders.queryString("you can enter a text here");

// RangeQuery
QueryBuilder qb = QueryBuilders.rangeQuery("field").from(5).to(10);

// BoolQuery
QueryBuilder qb = QueryBuilders.boolQuery()
    .must(QueryBuilders.textQuery("field1", "value"))
    .mustNot(QueryBuilders.textQuery("field2", "value"))
    .should(QueryBuilders.rangeQuery("field3").from(0).to(5));
```

Les résultats

```
// Lancer une recherche
SearchResponse sr = client.prepareSearch().setQuery(qb).execute().actionGet();

// Récupérer le temps d'exécution
long nbHits = sr.getTookInMillis();

// Récupérer le nombre de hits
long nbHits = sr.getHits().getTotalHits();

// Récupérer les hits
SearchHit[] hits = sr.getHits().getHits();

// Lire un hit
SearchHit hit = hits[0];

// Récupérer les coordonnées du document
hit.getIndex();
hit.getType();
hit.getId();

// Récupérer la pertinence du document
hit.getScore();

// Récupérer le document source au format Json
hit.getSourceAsString();
```

Atelier 2

- Regarder les sources du test 2

`src/test/java/org/elasticsearchfr/handson/ex2/SearchTest.java`

Atelier 3


La bière vue sous un autre angle
Les facettes

Les facettes

ID	Marque	Taille	Prix
1	Heineken	0.25	3.50
2	Grimbergen	0.25	4.00
3	Kriek	0.25	3.80
4	Heineken	0.5	6.80
5	Grimbergen	0.5	7.80
6	Kriek	0.5	7.50
7	Heineken	1	12.00
8	Grimbergen	1	14.00
9	Kriek	1	14.00

Term Facet

ID	Marque	Taille	Prix
1	Heineken	0.25	3.50
2	Grimbergen	0.25	4.00
3	Kriek		
4	Heineken		
5	Grimbergen		
6	Kriek		
7	Heineken		
8	Grimbergen		
9	Kriek		



Marque	Count
Heineken	3
Grimbergen	3
Kriek	3

1	12.00
1	14.00
1	14.00

TermFacet en Java

```
// Fabriquer une TermFacet (facet)
AbstractFacetBuilder facet = FacetBuilders.termsFacet("bybrand").field("marque");

// Avec la recherche
SearchResponse sr = client.prepareSearch().setQuery(qb).addFacet(facet).execute().actionGet();

// Facette en retour
TermsFacet bybrand = sr.getFacets().facet("bybrand");
for (TermsFacet.Entry entry : bybrand) {
    String marque = entry.getTerm();
    int nb = entry.count();
}
```

Range Facet

	ID	Marque		Taille		Prix		
	1	Heineken		0.25		3.50		
	2	Grimbergen		0.25		4.00		
Ranges		Count	Min	Max	Moy	Total		
x < 5		3	3.50	4.00	3.77	11.30		3.80
5 <= x < 10		3	6.80	7.80	7.37	22.10		6.80
10 <= x		3	12.00	14.00	13.33	40.00		7.80
	7	Heineken		1		12.00		
	8	Grimbergen		1		14.00		
	9	Kriek		1		14.00		

RangeFacet en Java

```
// Fabriquer une TermFacet (facet)
AbstractFacetBuilder facet = FacetBuilders.rangeFacet("byprice")
    .field("price")
    .addUnboundedFrom(5)
    .addRange(5, 10)
    .addUnboundedTo(10);

// Avec la recherche
SearchResponse sr = client.prepareSearch().setQuery(qb).addFacet(facet).execute().actionGet();

// Facette en retour
RangeFacet byprice = sr.getFacets().facet("byprice");
for (RangeFacet.Entry entry : byprice) {
    entry.to();
    entry.from();
    entry.min();
    entry.max();
    entry.mean();
    entry.count();
}
```

Atelier 3

- Regarder les sources du test 3

`src/test/java/org/elasticsearchfr/handson/ex3/FacetTest.java`



Mailing List ES France

elasticsearch-fr@googlegroups.com