


LES BASES NoSQL ET LES OUTILS DE TYPE HADOOP

Philippe Lacomme


placomme@isima.fr

Tel. 04 73 40 75 85




<http://www.isima.fr/~lacomme/NoSQL/>

4 enjeux



- **Stocker** (Comment ?)
- Extraire (fouille de données)
- Restituer
- Exploiter les données (nouvelle valorisation)


L'aspect connaissances



Trois éléments

- bases de données non relationnelles, appelées à tort **NoSQL** ;
- un système de distribution des traitements ;
- un système de stockages de données en mémoire pour accélérer les traitements.


Trois éléments




Autrefois....
Dans notre vieux temps



Problème 2



La vraie vie...



Bilan

- MCD/MLD → base relationnelle
- Adaptée au cas où les données ne changent que rarement de structure


Une solution : base NoSQL

- **Clé-valeur** : il s'agit de la représentation la plus simple. Cette structure est très adaptée à la gestion de caches ou pour fournir un accès rapide aux informations. Elle fonctionne comme un grand tableau associatif et retourne une valeur dont elle ne connaît pas la structure.
- **Clé-valeur avec contraintes d'intégrités** : une représentation évoluée qui autorise en plus la définition de contraintes d'intégrité.
- **Document** : une représentation qui ajoute au modèle **clé-valeur**, l'association d'une valeur à structure non plane, c'est-à-dire qui nécessiterait un ensemble de jointures en logique relationnelle.
- **Colonne** : une autre évolution du modèle **clé-valeur** qui permet de disposer d'un très grand nombre de valeurs sur une même ligne, permettant ainsi de stocker les relations de type **one-to-many**. Contrairement au système **clé-valeur**, celui-ci permet d'effectuer des requêtes par clé.
- **Graphe** : une représentation qui permet la modélisation, le stockage et la manipulation de données complexes liées par des relations non-triviales ou variables.

Existant

Type	Nom	Langage	Date création	Langage d'interrogation natif	Web Services	Bibliothèque (API)
Colonne	Hbase	Java	2007	Non	/	Java
	Hypertable	C++	2007	HQL	/	/
	Cloudata	Java	2011	CQL	REST	JAVA
Clé-Valeur	Membase	C et C++	2009	/	/	/
	Kyoto	C++	/	/	/	C, C++, Java, C#, Python, Ruby, Perl...
	Redis	C	2009	/	/	C, C++, Java, Python, Ruby, ...
	Oracle	/	2012	/	/	Java, C
Clé-Valeur/CI	Cassandra	Java	2008	/	/	Java, Python, PHP, Ruby...
	Voldemort	Java	2008	/	/	/
	Riak	Erlang, C, Javascript	2008	/	/	Java, Ruby, Python, PHP, Javascript
Document	CouchDB	C, Javascript	2005	/	REST	/
	MongoDB	C++	/	OUI	/	C, C++, Java, C#, Ruby, Javascript...
Graphe	Neo4j	Java	2003	SPARQL	REST	Java, Python, Ruby, PHP
	FlockDB	Scala	2010	/	/	/

Principe



Principe



Instance 1
a1=V1 a2=V2 a3=V3

Instance 2
a1=W1 a2=W2 a3=W3 a4=W4

Instance 3
a2=t2 a3=t3 a4=t4 a5=t5

OBJECT

Instance 1
a1=V1 a2=V2 a3=V3

```
DBObject = new BasicDBObject();  
DBObject.put("Numero", "3547");  
DBObject.put("Nom", "Chambord");  
DBObject.put("Prenom", "Emilie");  
coll.insert(dbObject);
```

Instance 2
a1=W1 a2=W2 a3=W3 a4=W4

```
DBObject = new BasicDBObject();  
DBObject.put("Numero", "85478");  
DBObject.put("Nom", "Castafiore");  
DBObject.put("Prenom", "Emilie");  
DBObject.put("Domicile", "Paris");  
coll.insert(dbObject);
```



MongoDB



Connexion




```
try
{
    MongoClient mongoClient = new MongoClient();
    DB db = mongoClient.getDB("bibliotheque");

    // Code

}
catch(Exception E)
{
    System.out.println(E.getMessage());
}
```

Le modèle classique



Parcelles

Numero	Designation	Prix/ha	Proprietaire
10101	Terrain à bâtir	500	Emilie Castafiore
11111	Friches	54	Emilie Chambord
80808	Landes	10	Emilie Castafiore
90909	Culture	25	Roland Momo
202022	Elevage	30	Sylvie Fabière

Propriétaires

Nom	Prénom	Domicile	Numero
Castafiore	Emilie	Paris	85478
Chambord	Emilie	Nice	3547
Dupont	Pierre	Avignon	542563
Fabiere	Sylvie	Bordeaux	52136
Momo	Roland	Toulouse	8547585
Tintin	Thierry	Clermont	78545

Insertion d'information



```
MongoClient mongoClient = new MongoClient();  
DB db = mongoClient.getDB( "bibliotheque" );
```

```
DBCollection coll = db.getCollection("Auteur");
```

```
// insertion
```

```
BasicDBObject dbObject = new BasicDBObject();  
dbObject.put("Numero", "85478");  
dbObject.put("Nom", "Castafiore");  
dbObject.put("Prenom", "Emilie");  
dbObject.put("Domicile", "Paris");  
coll.insert(dbObject);
```

```
dbObject = new BasicDBObject();
```

```
dbObject.put("Numero", "3547");
```

```
dbObject.put("Nom", "Chambord");
```

```
dbObject.put("Prenom", "Emilie");
```

```
dbObject.put("Domicile", "Nice");  
coll.insert(dbObject);
```

```
    "_id" : { "$oid" : "52d7aec259b83266723cc082" }, "Numero" : "85478", "Nom" : "Castafiore", "Prenom" : "Emilie", "Domicile" : "Paris"}  
Affichage de tous les elements  
    "_id" : { "$oid" : "52d7aec259b83266723cc083" }, "Numero" : "85478", "Nom" : "Castafiore", "Prenom" : "Emilie", "Domicile" : "Paris"}  
    "_id" : { "$oid" : "52d7aec259b83266723cc083" }, "Numero" : "3547", "Nom" : "Chambord", "Prenom" : "Emilie", "Domicile" : "Nice"}  
    "_id" : {  
    "_id" : {  
    "_id" : {  
    "_id" : {  
    "v" : 1,  
    "Numero" : "85478", "Nom" : "Castafiore", "Prenom" : "Emilie"  
    "Numero" : "85478", "Nom" : "Castafiore", "Prenom" : "Emilie"  
    "Numero" : "3547", "Nom" : "Chambord", "Prenom" : "Emilie", "  
    "Numero" : "542563", "Nom" : "Dupont", "Prenom" : "Pierre", "  
    "Numero" : "52136", "Nom" : "Fabi re", "Prenom" : "Sylvie", "  
    "Numero" : "8547585", "Nom" : "Momo", "Prenom" : "Roland", "  
    "Numero" : "78545", "Nom" : "Tintin", "Prenom" : "Thierry", "
```

```
DBObject myDoc = coll.findOne();  
System.out.println(myDoc);
```

```
// Affichage
```

```
System.out.println("affichage de tous les elements");  
DBCursor cursor = coll.find();
```

```
while(cursor.hasNext())  
{  
    System.out.println(cursor.next());  
}
```

Liens table/collection



NUMERO_L	Titre	Prix
10101	aaaaa	10
11111	ee	54
80808	cccc	45
90909	ddddd	35
202022	bb	25

```
DBCollection coll_livre = db.getCollection("Parcelles");  
  
BasicDBObject dbObject_Livre = new BasicDBObject();  
dbObject_Livre.put("Numero", "10101");  
dbObject_Livre.put("Titre", "aaaaa");  
dbObject_Livre.put("Prix", 10);  
coll_livre.insert(dbObject_Livre);
```



ORACLE NoSQL

Ajouter

The Oracle logo, consisting of the word "ORACLE" in white, uppercase, sans-serif font, centered within a solid red rectangular background.

Nom	Numéro
Castafiore	85478
Chambord	3547
Dupont	542563
Fabière	52136
Momo	8547585
Tintin	78545

```
String keyString1 = "85478";
```

```
String valueString1 = "Castafiore";
```

```
Key une_cle1 = Key.createKey(keyString1);
```

```
Value une_valeur1 = Value.createValue(valueString1.getBytes());
```

```
store.put(une_cle1, une_valeur1);
```

Ajouter




Nom	Prénom	Domicile	Numero
Castafiore	Emilie	Paris	85478
Chambord	Emilie	Nice	3547
Dupont	Pierre	Avignon	542563
Fabiere	Sylvie	Bordeaux	52136
Momo	Roland	Toulouse	8547585
Tintin	Thierry	Clermont	78545

```
t_proprietaire un_proprietaire = new t_proprietaire ();  
un_proprietaire.nom = "Dupont";  
un_proprietaire.prenom = "Pierre";  
un_proprietaire.domicile = "Paris";
```

```
tableau_des_cles_de_recherche.clear();  
tableau_des_cles_de_recherche.add("Dupont");  
tableau_des_cles_de_recherche.add("Pierre");
```


```
Key myKey = Key.createKey(tableau_des_cles_de_recherche);  
Value myValue = Value.createValue(un_auteur.toString().getBytes());  
store.put(myKey, myValue);
```

Principes communs



Principe : accès direct

T : Tableaux associatifs



$T[i] \rightarrow$ accès en $O(1)$

Magique ou non ?




TP de Big Data

Michaël PLAN & Ana Alice BARROS NETO

Comparaison des performances de
bases relationnelles et non
relationnelles

Un énoncé « classique »



Magique ou non ?



Action	Nombre d'objets	 MySQL	 mongoDB
CREATE	100	5,54	1,172
	10000	470,931	1,092
	1000000	12641,552	57,096
SELECT	100	0,014	0
	10000	0,078	0,063
	1000000	3,759	4,244

Magique ou non ?



http://www.datastax.com/wp-content/themes/datastax-2014-08/files/NoSQL_Benchmarks_EndPoint.pdf?2



END POINT

Benchmarking Top NoSQL Databases

Apache Cassandra, Couchbase, HBase, and MongoDB

Originally Published: April 13, 2015

Revised: May 27, 2015

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

Magique ou non ?



http://www.datastax.com/wp-content/themes/datastax-2014-08/files/NoSQL_Benchmarks_EndPoint.pdf?2



Benchmarking Top NoSQL Databases

Apache Cassandra, Couchbase, HBase, and MongoDB

Originally Published: April 13, 2015


Revised: May 27, 2015

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

CALCULS DISTRIBUES


Hadoop and co.....

Trois éléments







Ecosystème Hadoop




Utilisation




Etape 3



Etape 3



Conclusion





Formation

2-3 Juin 2016



Installation, configuration, utilisation

13-14-15 Juin 2016



Contact : Loic Yon (resp. Formation Continue)
Tel. 04 73 40 50 42
Email : loic.yon@isima.fr