



# Apache SolrCloud pour la fouille de données Big Data

AURÉLIEN MAZOYER, SEARCH EXPERT, FRANCE LABS  
SOPHIACONF WORLDWIDE EVENT  
JULY 2015

# France Labs – Qui sommes-nous ?

## LES EXPERTS DU SEARCH:

- Consulting sur les meilleures technos open source de search
  - Apache Solr
  - Elasticsearch
  - Apache ManifoldCF
  - Formations, audit techniques, AMOA, MOE, MEP, LOL, MDR
- Editeur de Datafari:
  - Solution clé en main de recherche
  - Gestion de la sécurité
  - Big data
  - Multisource, multi-types
  - Sémantique



elasticsearch.



# Agenda

## Solr:

- Kezako ?
- Place dans les Data Science !
- C'est fastoche !

## SolrCloud:

- C'est le Big Data
- Kezako ?
- C'est fastoche !

## Solr et Data Science:

- Cas d'usages

# Solr – Kezako ?

- Moteur de recherche et d'analyse
- Fondation Apache
- Basé sur Lucene
- Fonctionnalités : autocomplétion, faceting, suggestions, highlighting...



# Solr et les Data Science

- ☞ L'axe de la fouille de données
- ☞ Pas d'algorithmes complexes
- ☞ Priorité à l'instantané
- ☞ Sommes, min, max, pourcentages, moyenne

# Solr c'est fastoche

🗨️ La preuve par l'exemple

# SolrCloud – C'est le Big Data

## ☺ Scalabilité horizontale pour:

- Gérer un index énorme
- Gérer un nombre massif de requêtes
- Gérer la haute disponibilité

## ☺ Même philosophie qu'Hadoop – Utilise Zookeeper


- Gère la configuration des systèmes distribués
- Conserve et gère les configs d'index du SolrCloud
- Conserve et gère le statut des shards enregistrés
- Les Solr s'abonnent et se désabonnent auprès du Zookeeper



# SolrCloud – Les shards

## Sharding :


- Un shard est un morceau d'index
- Une recherche distribuée se fait sur tous les shards (donc l'index complet)
- Utile pour gérer un gros index



# SolrCloud: Leaders/Replicas


🗨 Leaders et replicas pour la réplication:

- Pas de « maître/esclave » mais des « leaders/replicas » (un replica peut devenir un leader)
- Un leader et ses replicas contiennent le même shard
- Utile pour gérer une grosse charge de requêtes et pour la haute disponibilité



# SolrCloud - Illustration

- On veut répartir l'index sur 2 shards
- On veut un réplica par shard
- D'où 4 machines



# SolrCloud – Démo locale

- Démarrage d'un cluster local, check de la config et arrêt brutal d'un serveur

# SolrCloud – Démo AWS

- Indexation de 2.300.000 pages web pour jouer un peu
- Quasi instantané

# Solr et Big Data – Cas d’usages

## BOX:

- Index de 10 To
- 10 Mds docs
- 100 M requêtes / jour

## Bloomberg

- 80 Mds docs
- Doc ~ 50 Ko, variance 1ko -> 100 Mo
- Centaines de champs
- <10 requêtes / seconde

# FRANCELABS

EXPERTS DU SEARCH



QUESTIONS ? (Que représente le logo France Labs ?!)

A VOTRE DISPOSITION AU COCKTAIL

 AURELIEN.MAZOYER@FRANCELABS.COM

 @FRANCELABS