

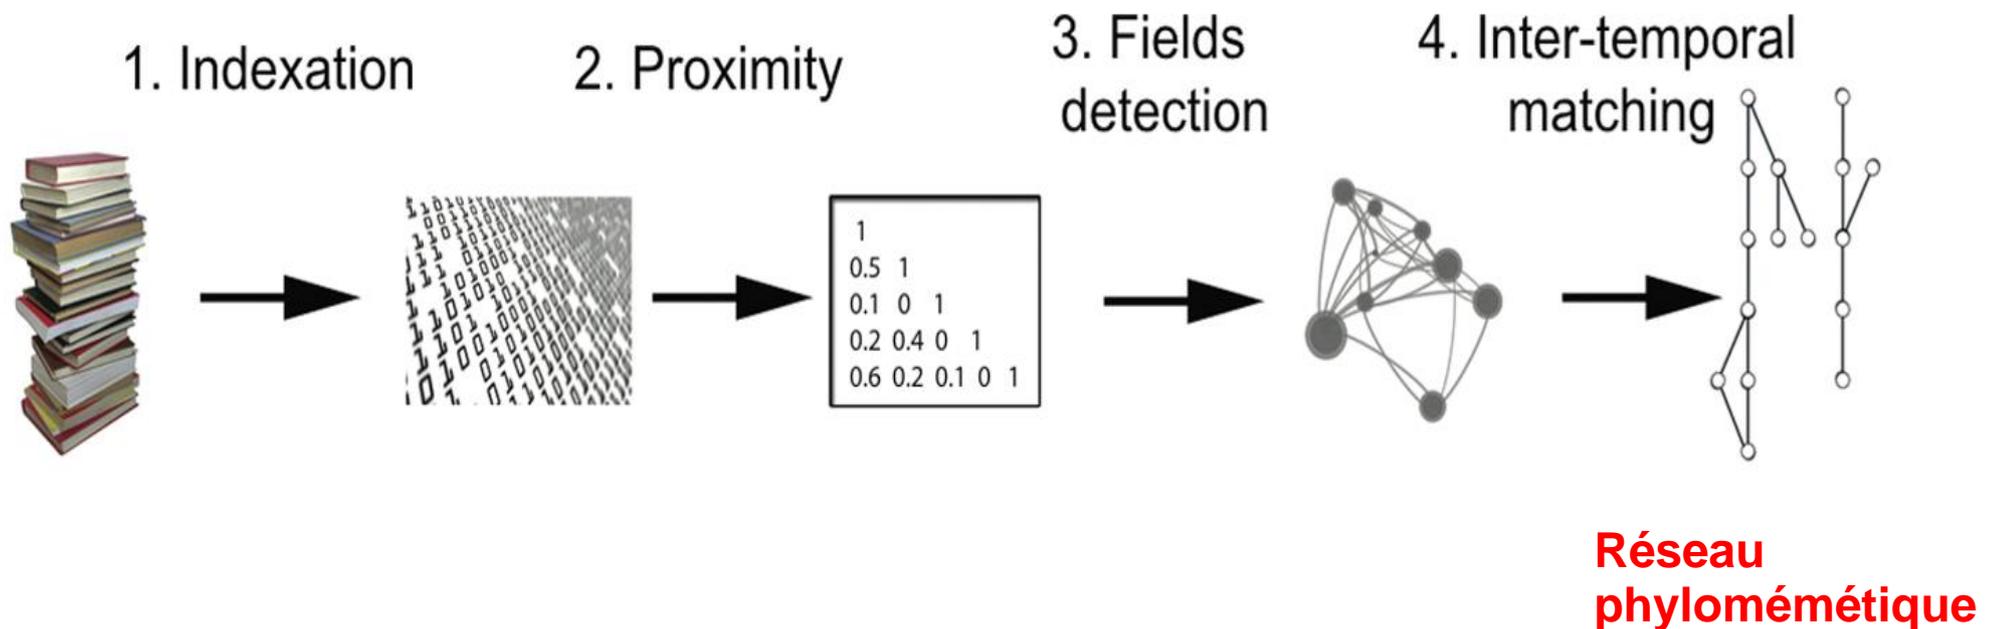
# Construction de réseaux « phylomémétiques »

## Axe 3 : Dynamacité

- Partenaires :
  - LIP6 : B. Amann, H. Naacke
  - IRISA : D. Gross-Amblard, Z. Miklos
  - CAMS-EHESS : D. Chavalarias, ....
- Recrutements :
  - Juan Pablo Stocca (sept-déc. 2013), ingénieur
  - Alexis Guichard (avril-sept, 2014), stage M2R/UPMC
  - Jonathan Lajus (avril-août, 2014), stage M2R/ENS

# Objectif

- Extraction d'une « Carte de l'évolution des Sciences » à partir d'un corpus scientifique (WoS)



David Chavalarias and Jean-Philippe Cointet. Phylomemetic Patterns in Science Evolution  
The Rise and Fall of Scientific Fields. PLoS ONE, 8(2) :e54847+, February 2013.

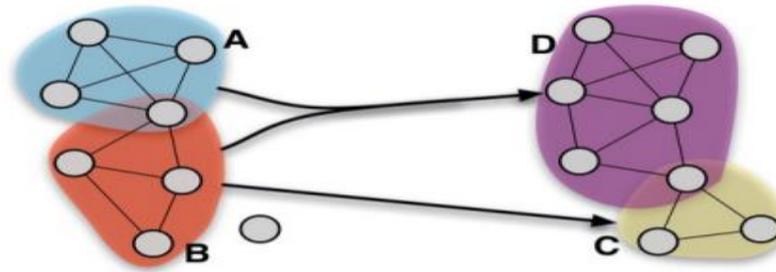
# Defis « Masse de Données »

- Passage à l'échelle
- Application actuelle :
  - 5 000 termes / 100 000 articles
- Application visée :
  - Web Of Science :
    - 12k journaux depuis 1990
    - 300 000 termes / 30 M articles
  - Analyse interactive et « temps-réel »
- Défis :
  - Complexité des phases clusterisation et analyse temporelle
  - Taille des résultats intermédiaires

# Approche en trois étapes

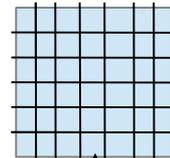
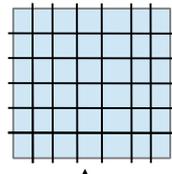
## 3. Analyse temporelle

**Concepts**  
(cliques, clusters)



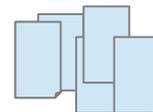
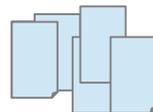
**2. Clustering**  
(fouille de texte/graphes)

Co-occurrences  
de **termes**  
(phrases)



**1. Extraction de termes**

**Corpus**  
(articles)



2010

2011

# Phase « Clusterisation »

Juan-Pablo Stocca / Jonathan Lajus

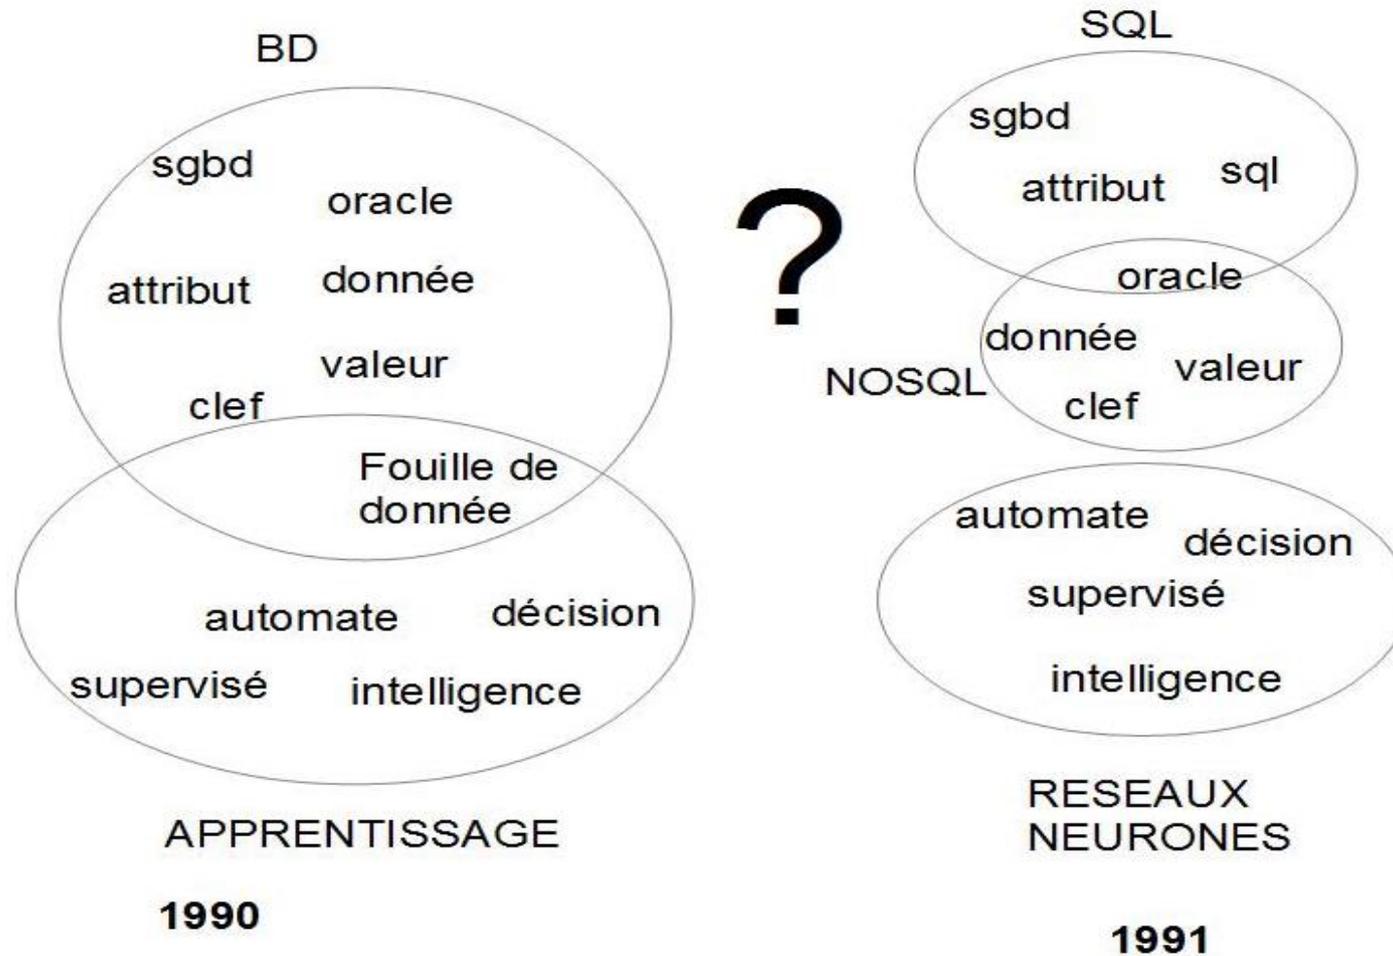
Extraction de concepts (ensembles de termes cohérentes) dans un grand corpus (3M documents)

- Génération d'un index inversé
- Génération de graphe de co-occurrences  $G(année)$
- Extraction de concepts de  $G(année)$ 
  - Percolation (polynomiale) de cliques maximales (NP complet)
    - Tomita et. al.
  - Optimisation de modularité
    - Louvain : partitionnement, taille de partitions normalisée

# Génération de graphe de co-occurrences

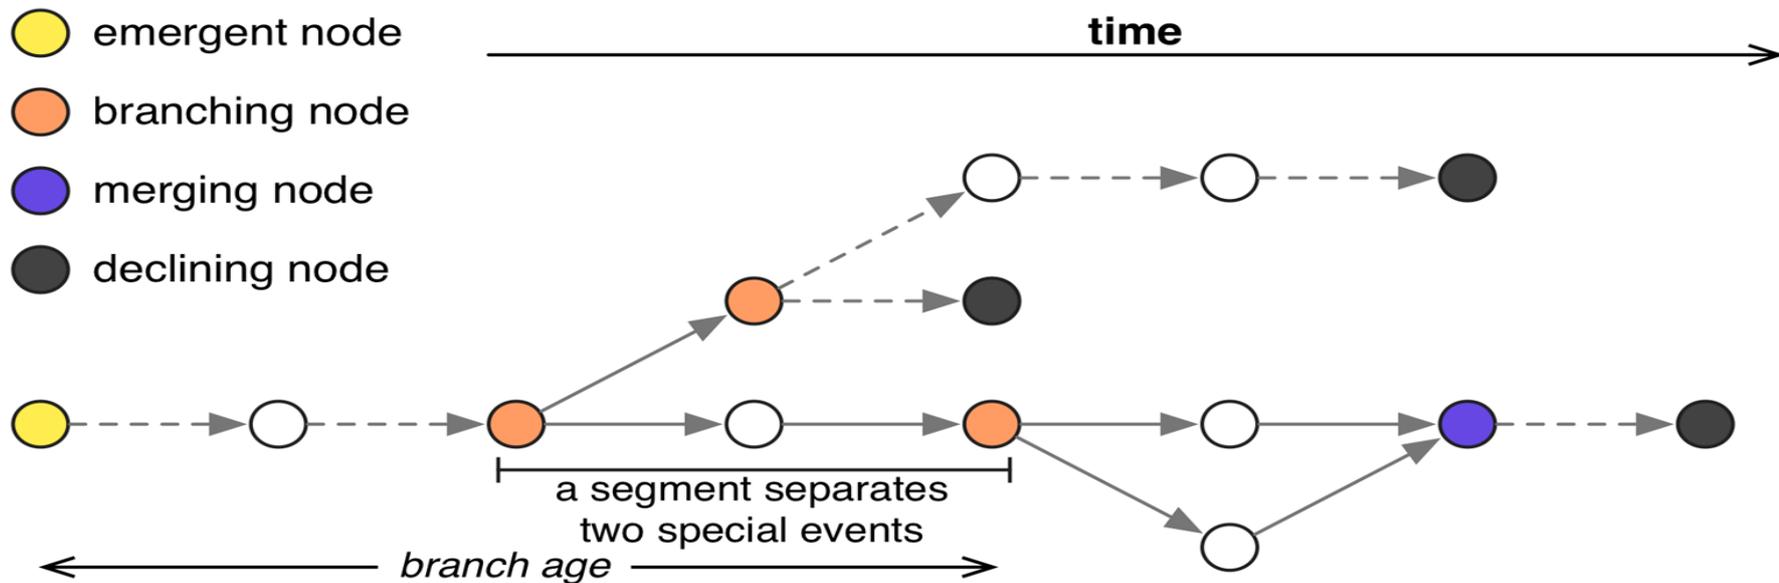
- Occurrences  $O = \{ (\text{doc}, \text{terme}) \}$  : scripte Python
- Co-occurrences  $G = \{ (\text{terme}, \text{terme}) \}$  : Spark / Hadoop
- Analyse de  $G(1990)$ :
  - 865k sommets, 290M arêtes
  - Composantes connexes : 5, taille min=2, taille max = 290k
  - Arêtes par sommet: avg=336k, max=757k
- Résultats :
  - Tomita et.al. : difficilement parallélisable
  - Louvain: valeurs de modularité très/trop faibles
- Solution :
  - Filtrage d'arêtes et de termes (stopwords, degré de nœuds, Pagerank, ...)
  - Plus d'expériences nécessaires ...

# Phase « Alignement de concepts »



# Phylométrie

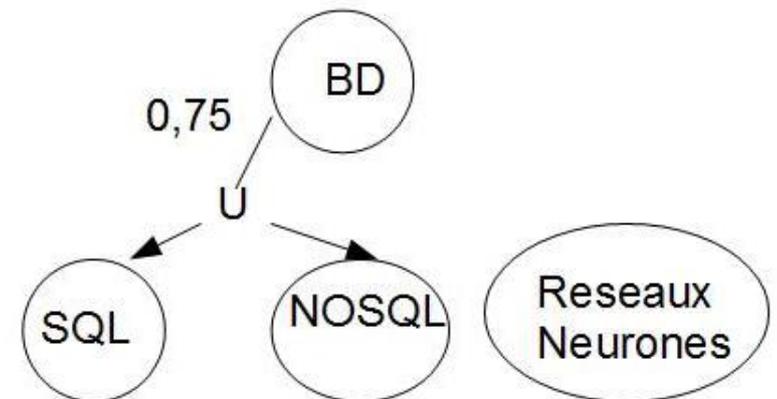
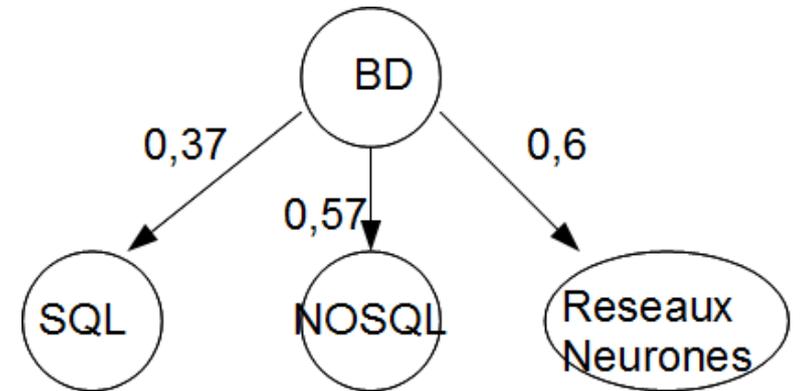
- Inspiré des arbres phylogénétiques



David Chavalarias and Jean-Philippe Cointet. Phylomemetic Patterns in Science Evolution  
The Rise and Fall of Scientific Fields. PLoS ONE, 8(2) :e54847+, February 2013.

# Alignement par similarité

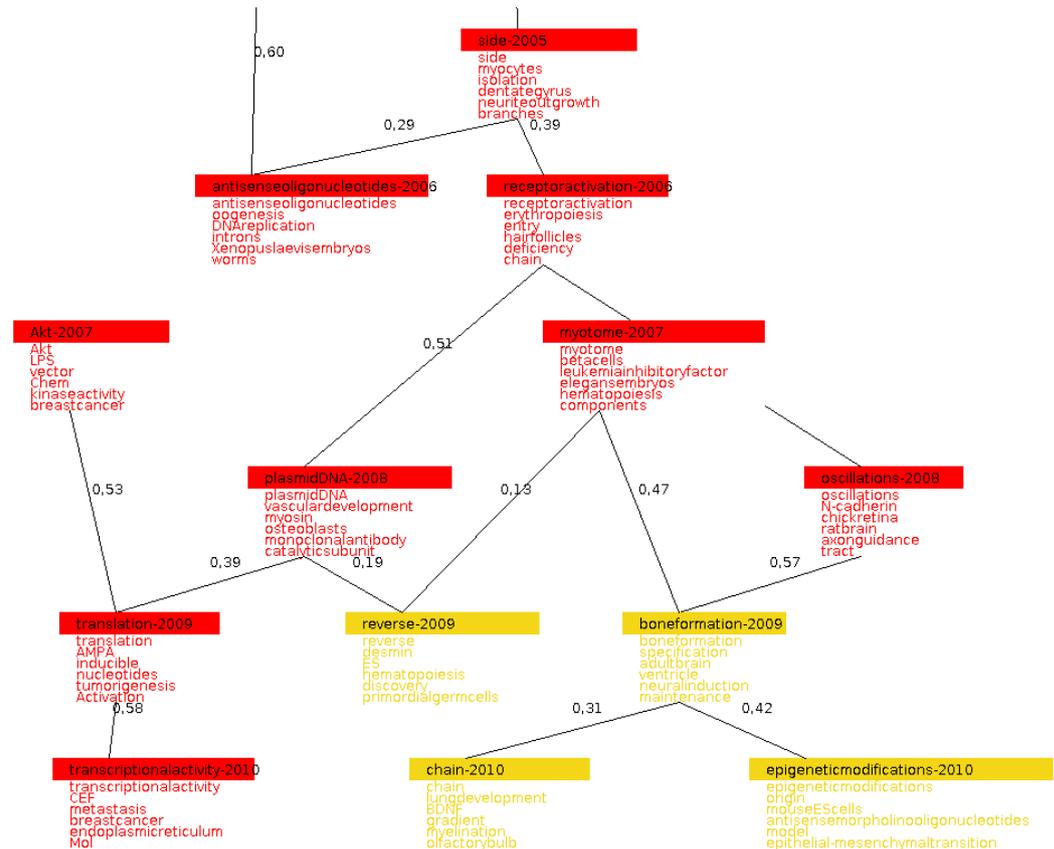
- Similarité Jaccard
- Filtrage par seuil  $s_0$
- Union de deux clusters
- Approche ascendante et descendante
- Optimisation : élaguer l'espace de recherche
  - Somme des similarités supérieure à la meilleure similarité



$$\frac{An(BC)}{AU(BC)} \leq \frac{AnB}{AUB} + \frac{AnC}{AUC}$$

# Identification de catégories

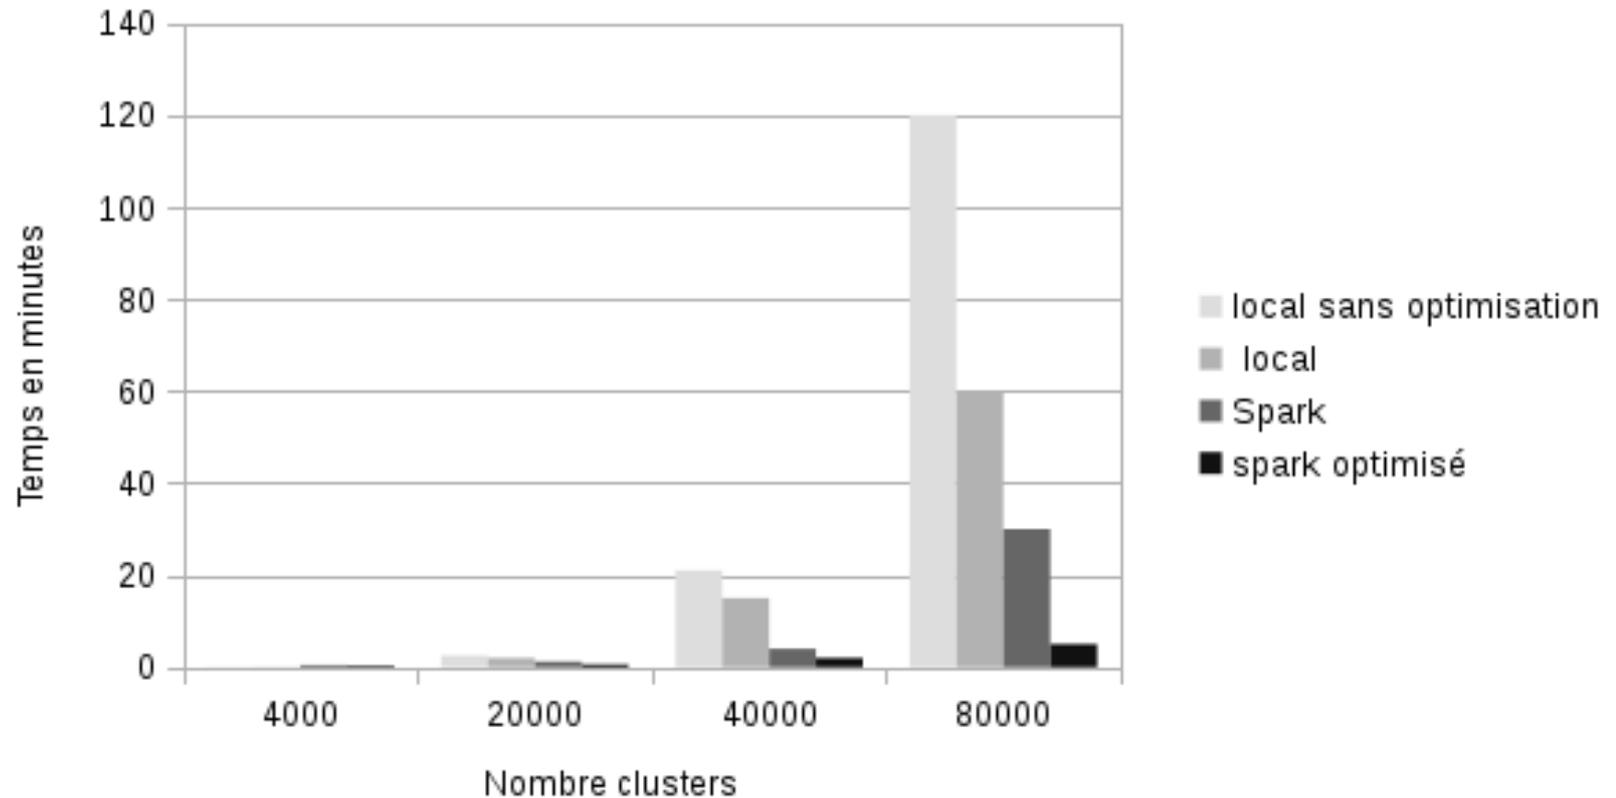
- Catégories de termes :
  - Hérités
  - Recombinés
  - Émergents
- Différencier les termes d'un concept
- Trouver un nom :
  - Aux domaines
  - Aux concepts



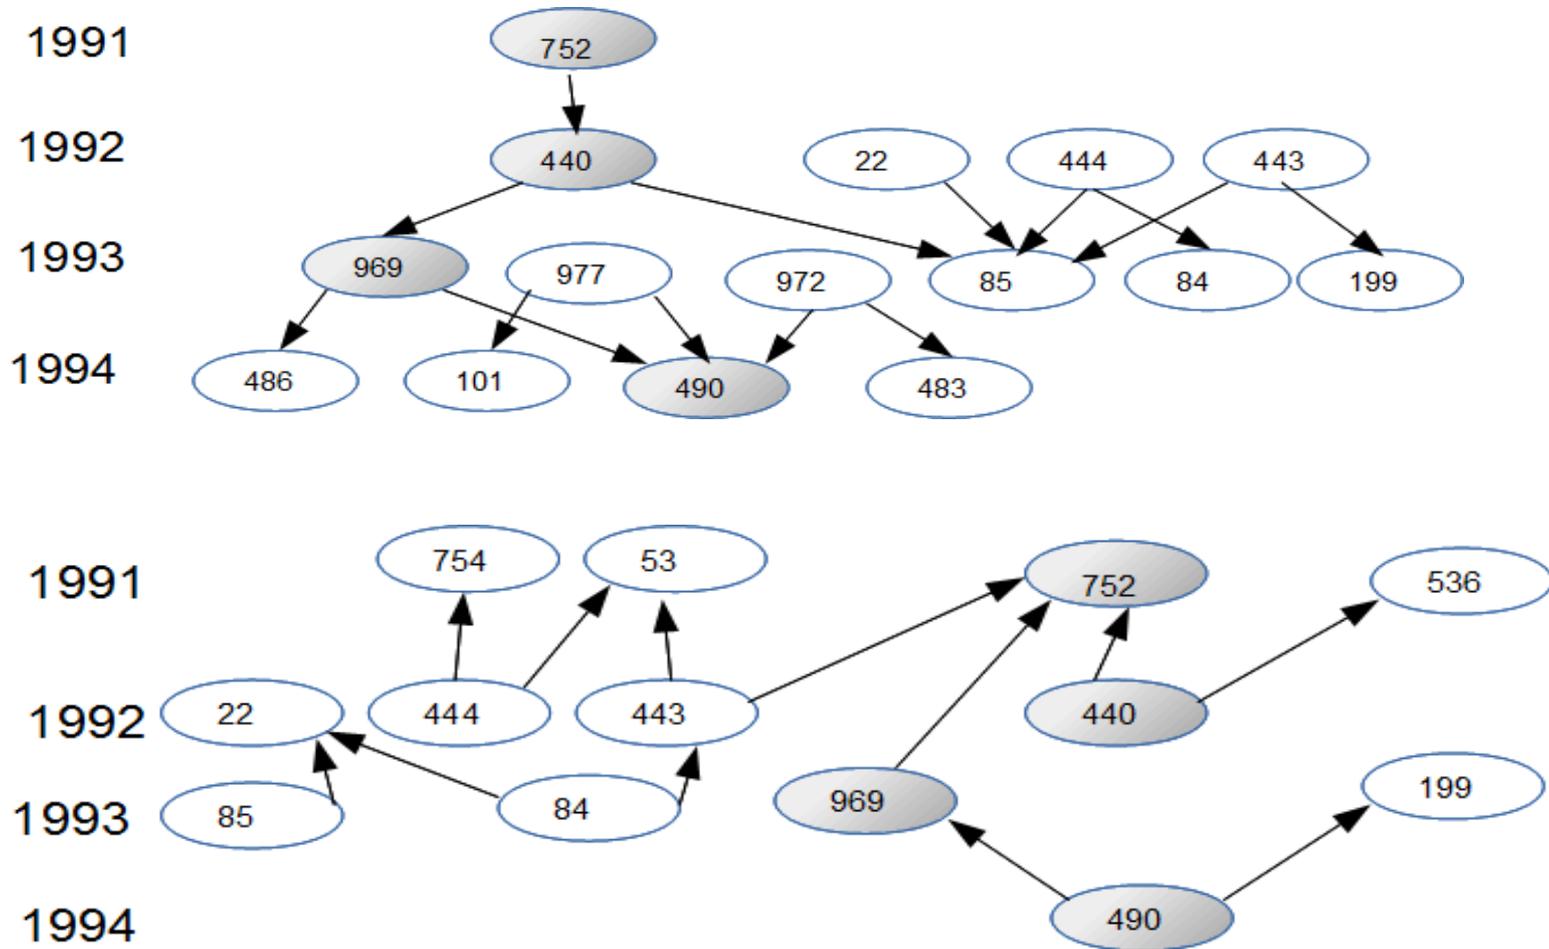
# Spark

- Programmation parallèle + données distribuées
  - Algèbre sur les RDDs (Resilient Distributed Datasets) : selection, union, join, ...
  - Implantation Map-Reduce (Hadoop)
- Algorithme :
  - Cluster année  $t$  :  $C_i, \dots$
  - Cluster année  $t+1$  :  $C_j, C_k, \dots$
  - Produit cartésien :  $(C_i, C_j), (C_i, C_k), \dots$
  - Jointure :  $(C_i, (C_j, C_k)), \dots$
  - Filtrage par le seuil  $s_1$  pour le niveau de précision

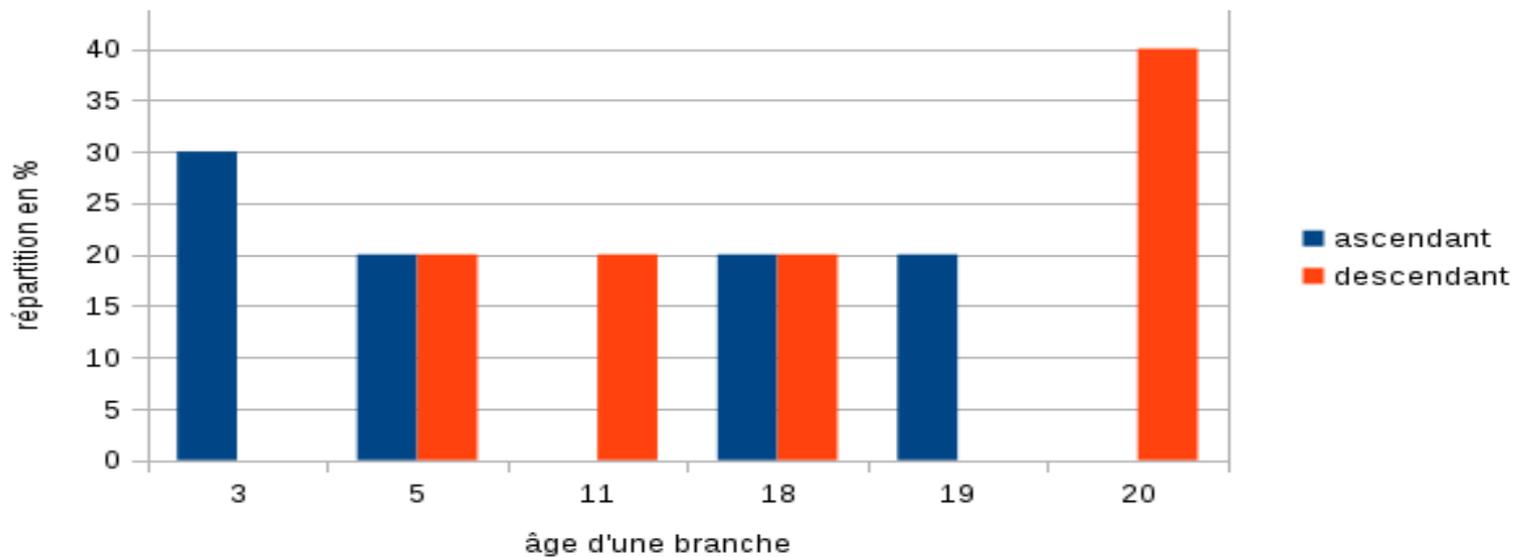
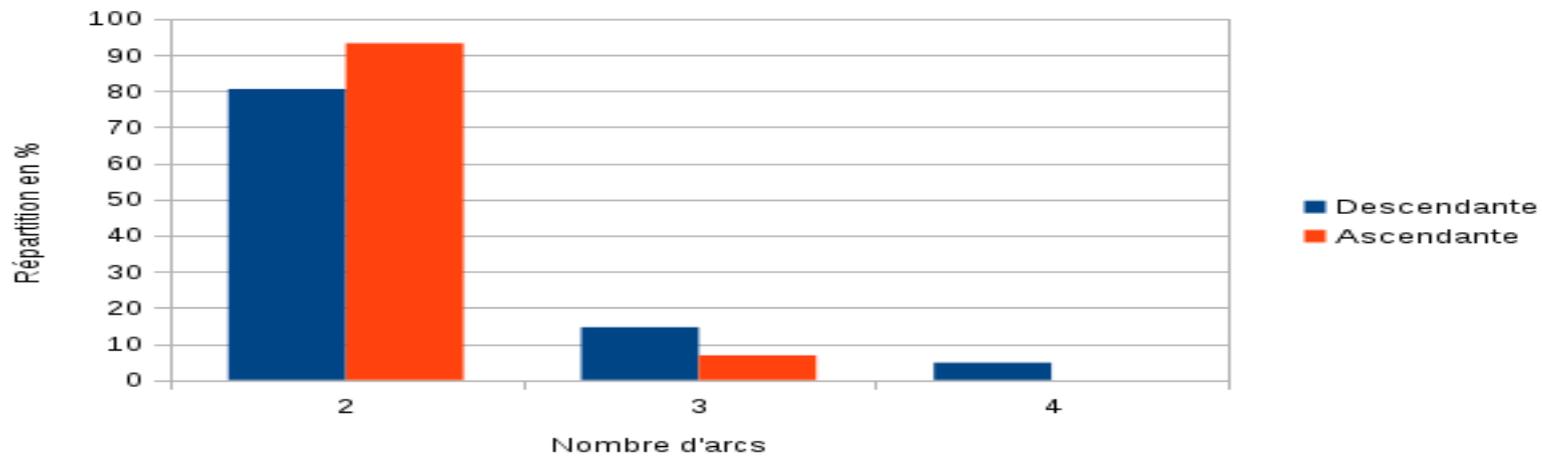
# Expérimentations : temps d'exécution



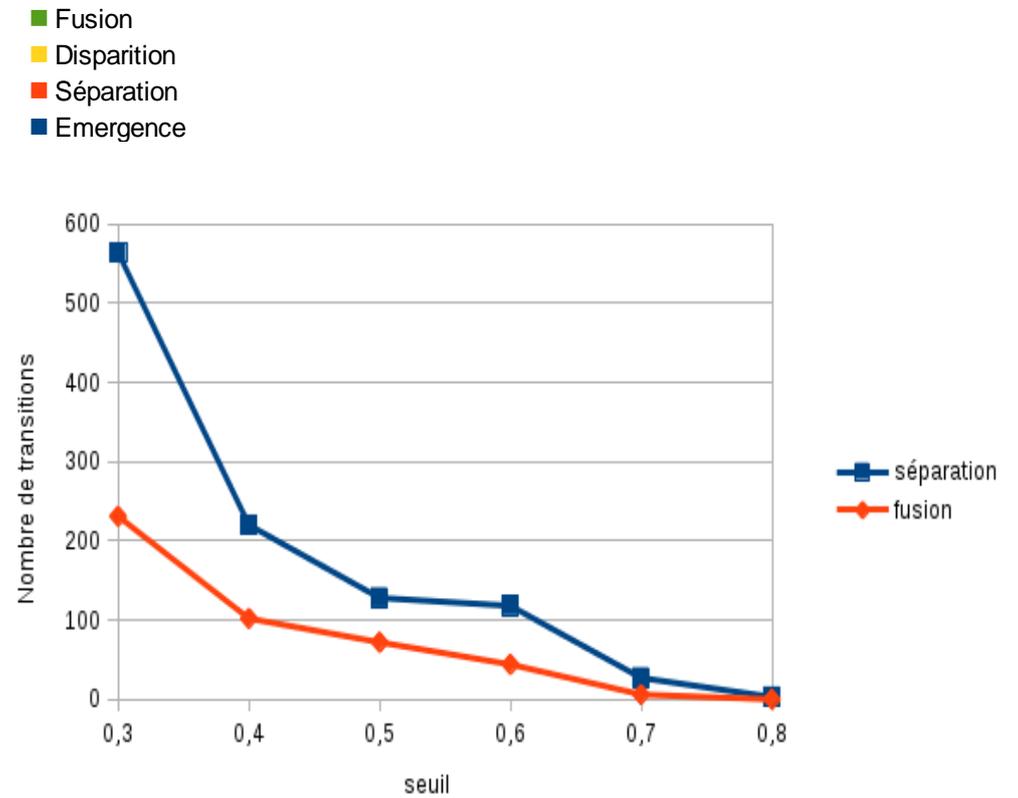
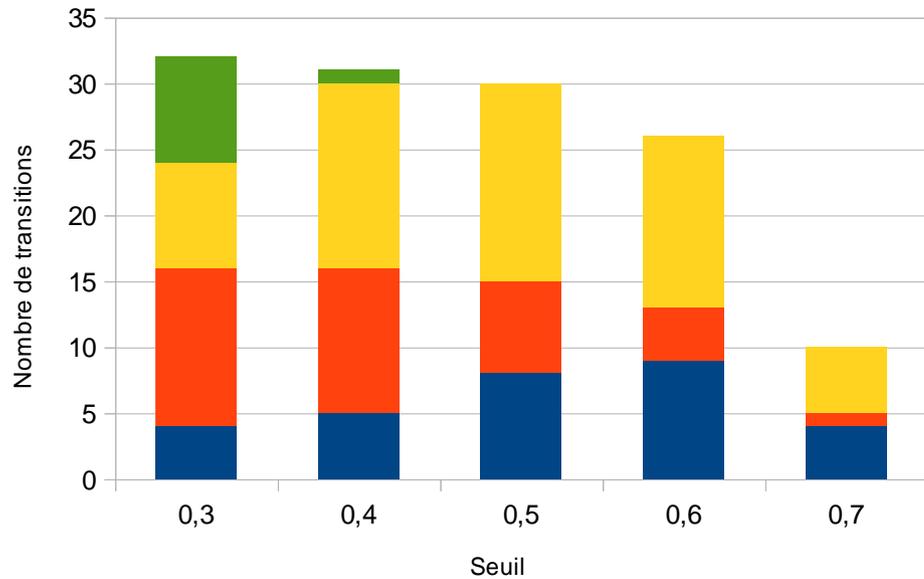
# Expérimentations : Impacts sur les transitions



# Expérimentations : Impacts sur les transitions



# Expérimentations : Impacts sur les seuils



# Travaux et résultats

- Travaux effectués : « étude de faisabilité »
  - Formalisation du problème
  - Réalisation Spark/Map-Reduce des phases Extraction et Clustering
  - Expérimentations sur un cluster Hadoop à Rennes et au LIP6
- Travaux futurs / perspectives :
  - Etudier d'autres critères / approches de clustering
  - Expérimentations qualité/performance (WoS complet)
  - Analyse interactive / incrémental / re-clustering / visualisation
  - Projet ANR en cours de soumission

# Merci



# Travaux similaires

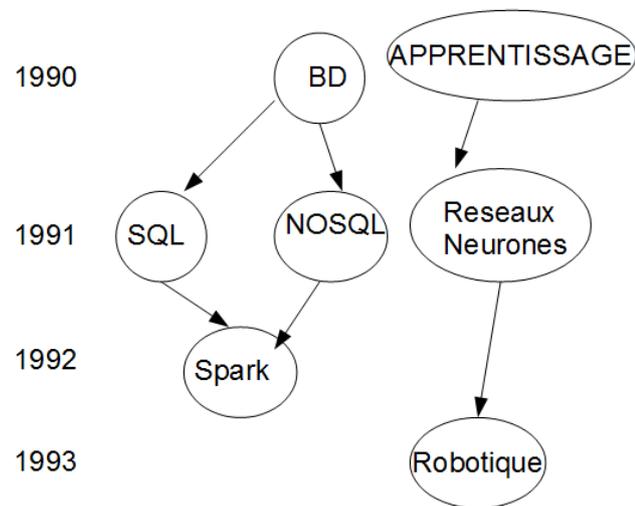
- Deux approches dans la littérature :
  - Détection des changements de clusters :
    - Système MONIC ( Modeling and Monitoring Cluster) \*
  - Clustering spatio-temporel :
    - Système SOAPs ( Spatial Object Association Patterns) \*\*

\* Myra Spiliopoulou and Irene Ntoutsis. The monic framework for cluster transition detection.

\*\* Hui Yang, Srinivasan Parthasarathy, and Sameep Mehta. A generalized framework for mining spatio-temporal patterns in scientific data. In Patterns in Scientific Data, ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining, pages 716721, 2005.

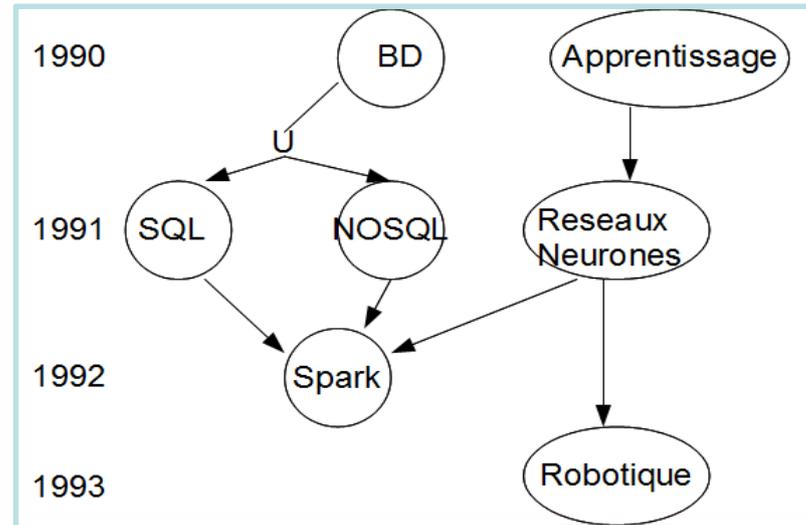
# Détection de transitions externes

- 6 transitions : émergence, disparition, fusion, séparation, ré-émergence, reconduction.
- Filtrage par seuil :
  - S0, similarité significative
  - S1, résolution du résultat

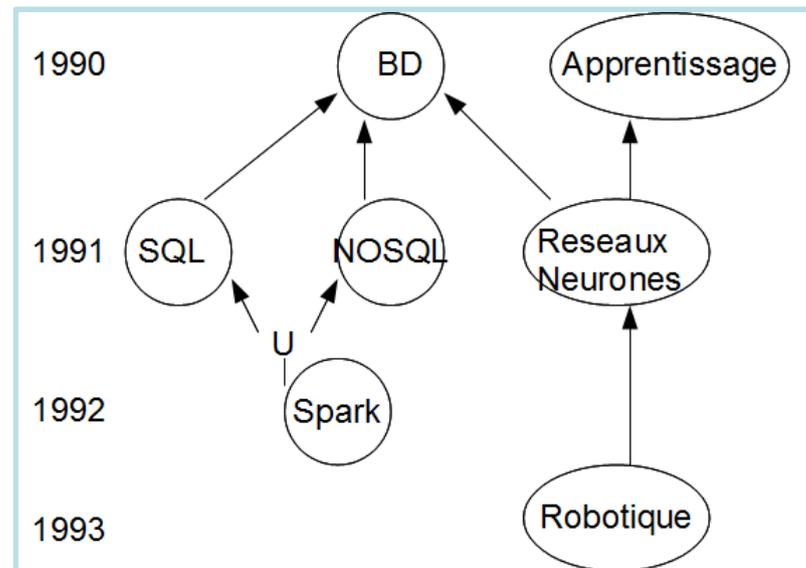


# Approche ascendante et descendante

Approche descendante



Approche ascendante



# Modèle et optimisation

- Calcul d'union : améliorer la complexité
- Solution : élaguer l'espace de recherche
  - Trier la liste des candidats par ordre décroissant
  - Somme des similarités supérieure à la meilleure similarité

$$\frac{A \cap (B \cup C)}{A \cup (B \cup C)} \leq \frac{A \cap B}{A \cup B} + \frac{A \cap C}{A \cup C}$$

# Conclusion

- Définition d'un modèle générique
- Ajout d'une transition de ré-émergence
- Définition de deux analyses d'alignement
- Optimisation pour l'union
- Solution Spark pour le passage à l'échelle
- Programmation d'un logiciel de visualisation avec seuil paramétrable :  
version Java 8 (spark), Java 7, Scala