

Base de données ArXiv

Le but de ce projet informatique est de traiter des données à travers le paradigme de programmation *MapReduce*, la structure de fichiers *HDFS* et à l'aide du package `rnr2` du logiciel R.

1 Récupération des données

Les données à récupérer se situent dans deux fichiers nommés

`cit-HepPh.txt.gz` et `cit-HepPh-dates.txt.gz`

Les fichiers sont accessibles sur la page

<http://snap.stanford.edu/data/cit-HepPh.html>

Le premier fichier décrit un graphe orienté représentant les citations entre des articles de physique théorique déposés sur l'archive ouverte ArXiv. Le second fichier donne les dates de publications de ces articles. Une fois décompressée, les deux fichiers peuvent être chargés dans R (dans les variables `citations` et `dates`) à l'aide de la commande `read.table`.

2 Traitement des données

Ce projet informatique est très libre, en particulier toutes les initiatives personnelles et les approches innovantes seront fortement appréciées. Néanmoins, l'un des buts étant de vous familiariser avec la problématique de la programmation *MapReduce*, il vous sera demandé d'implémenter chaque question en utilisant le modèle de programmation *MapReduce* à travers le package `rnr2`. Afin de vérifier la cohérence de vos résultats, vous pouvez éventuellement les comparer avec un traitement standard des données en R.

Attention : pour le traitement des données en *MapReduce*, on utilisera directement les données converties au format *HDFS* à l'aide des commandes

```
citations_bigdata <- to.dfs(citations)
```

```
dates_bigdata <- to.dfs(dates)
```

Il n'est pas autorisé d'utiliser des pré-traitements des données en R avant de les convertir en *HDFS* !

Voici quelques questions qui pourront être traitées avec *RHadoop* :

- Combien y a-t-il de nœuds (articles), d'arcs orientés (citations), d'arêtes (i.e. d'arcs non orientés)?

- Quel est le nombre moyen d'articles cités par article ? Représenter en diagramme la répartition du nombre d'article cités par nœud.
- Quel est le nombre moyen de citation par article ? Représenter en diagramme la répartition du nombre de citation pour chaque nœud.
- Etudier l'évolution temporelle du nombre d'articles cités par nœud.

Nous insistons sur le fait que les questions précédentes ne sont que des suggestions et n'ont pas vocation à être exhaustives. Toute prise d'initiative sera appréciée.

3 Travail à effectuer

Il est demandé de nous envoyer un compte-rendu sous la forme d'un fichier Rmarkdown (et le .pdf associé) avec vos codes *R* correctement commentés.