# R+Hadoop = Rhadoop*



## Des logiciels libres complémentaires, une implémentation, une réponse au nouveau paradigme du bigdata !

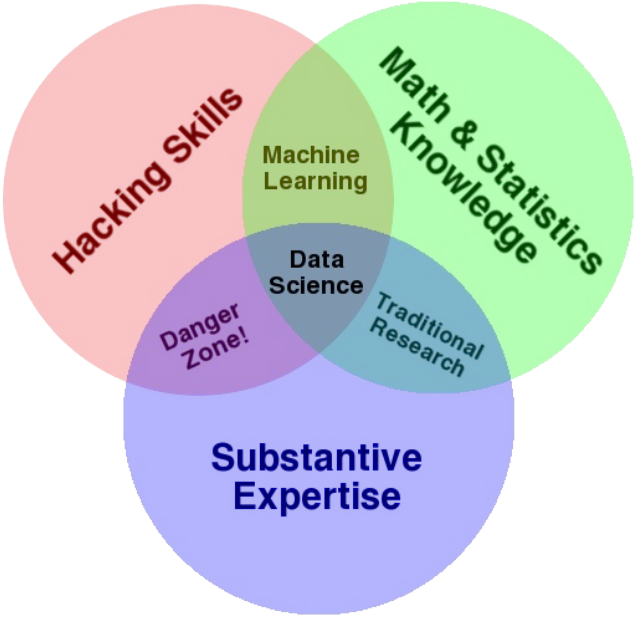

**Big Data =**

**Nosql =**

**Yarn =**

**Cloud =**

**Hadoop =**

**Mapreduce =**

**Pregel =**

**Dremel =**

**Buzz ?**

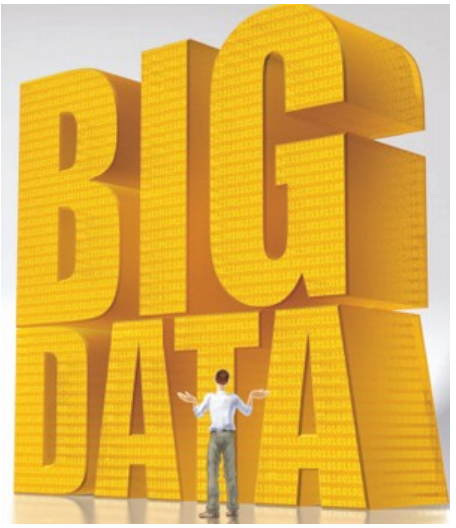


# Rappel historique, quelques chiffres :

## Evolution de la production mondiale de données depuis 2005

**-2005 : 130 Exaoctets**
**-2011 : 1800 Exaocets/1.8 Zettaoctets (1.8 x 10^21)**

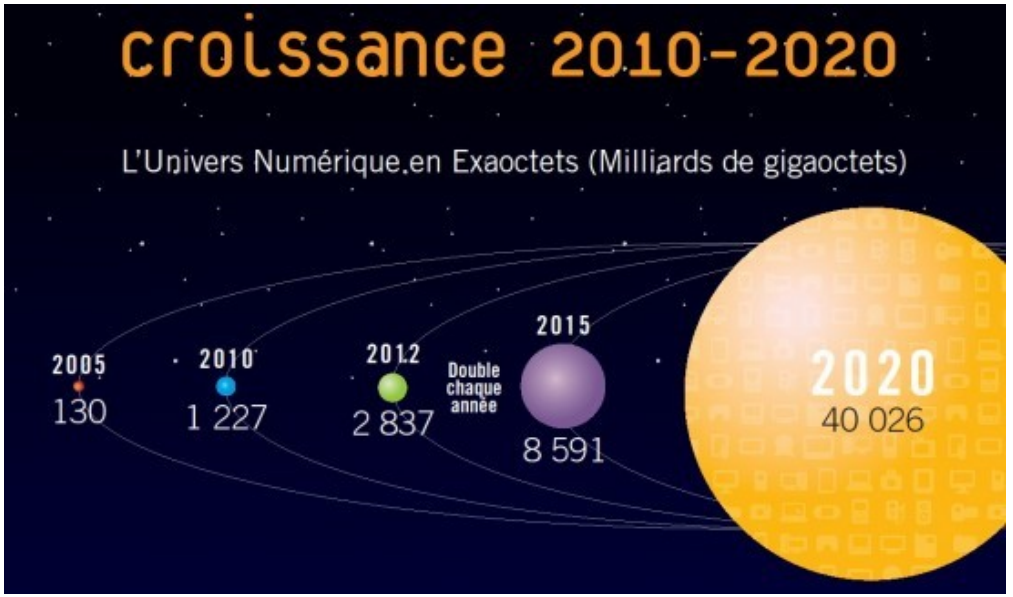


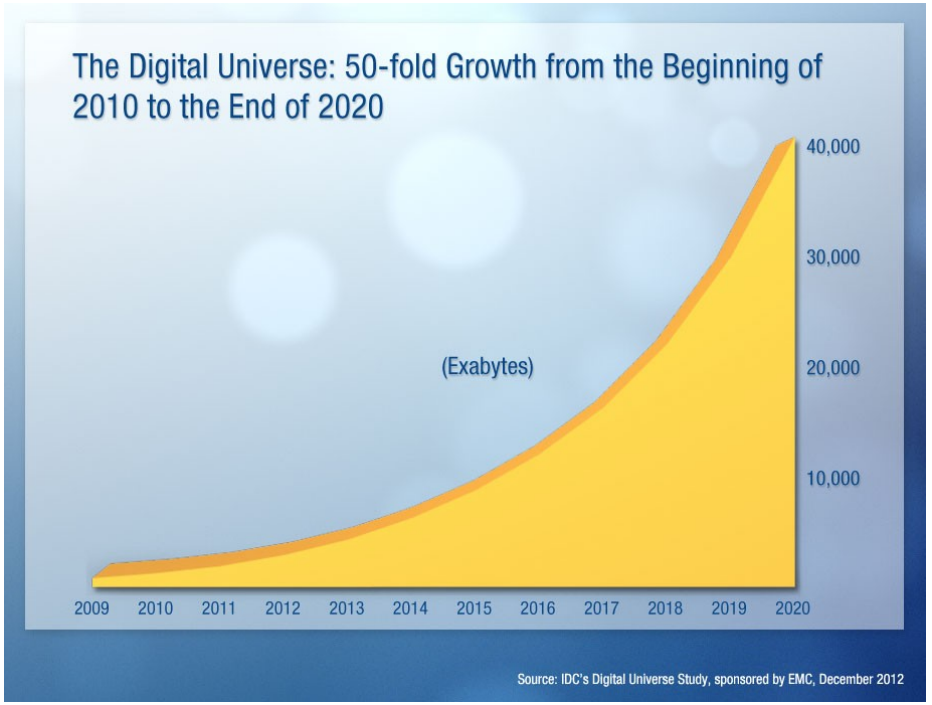


**173 million** blogs online

**107 trillion** emails sent in 2010

**566 billion** objects stored on Amazon's S3 cloud service by the end of 2011

**340 million** tweets posted to Twitter every day by its **140 million** active users

**50 billion** pages indexed by Google (December 2011)

**82 petabytes** stored on the largest Yahoo! Hadoop cluster

**60 hours** of video is uploaded to YouTube every minute. That's **1 hour** every second

**845 million** monthly active Facebook users resulting in an average of **15TB** of data collected each day

*Sources :IDC (International Data Conseil)*

# Et l'evolution des disques durs ( taille & débit ) !

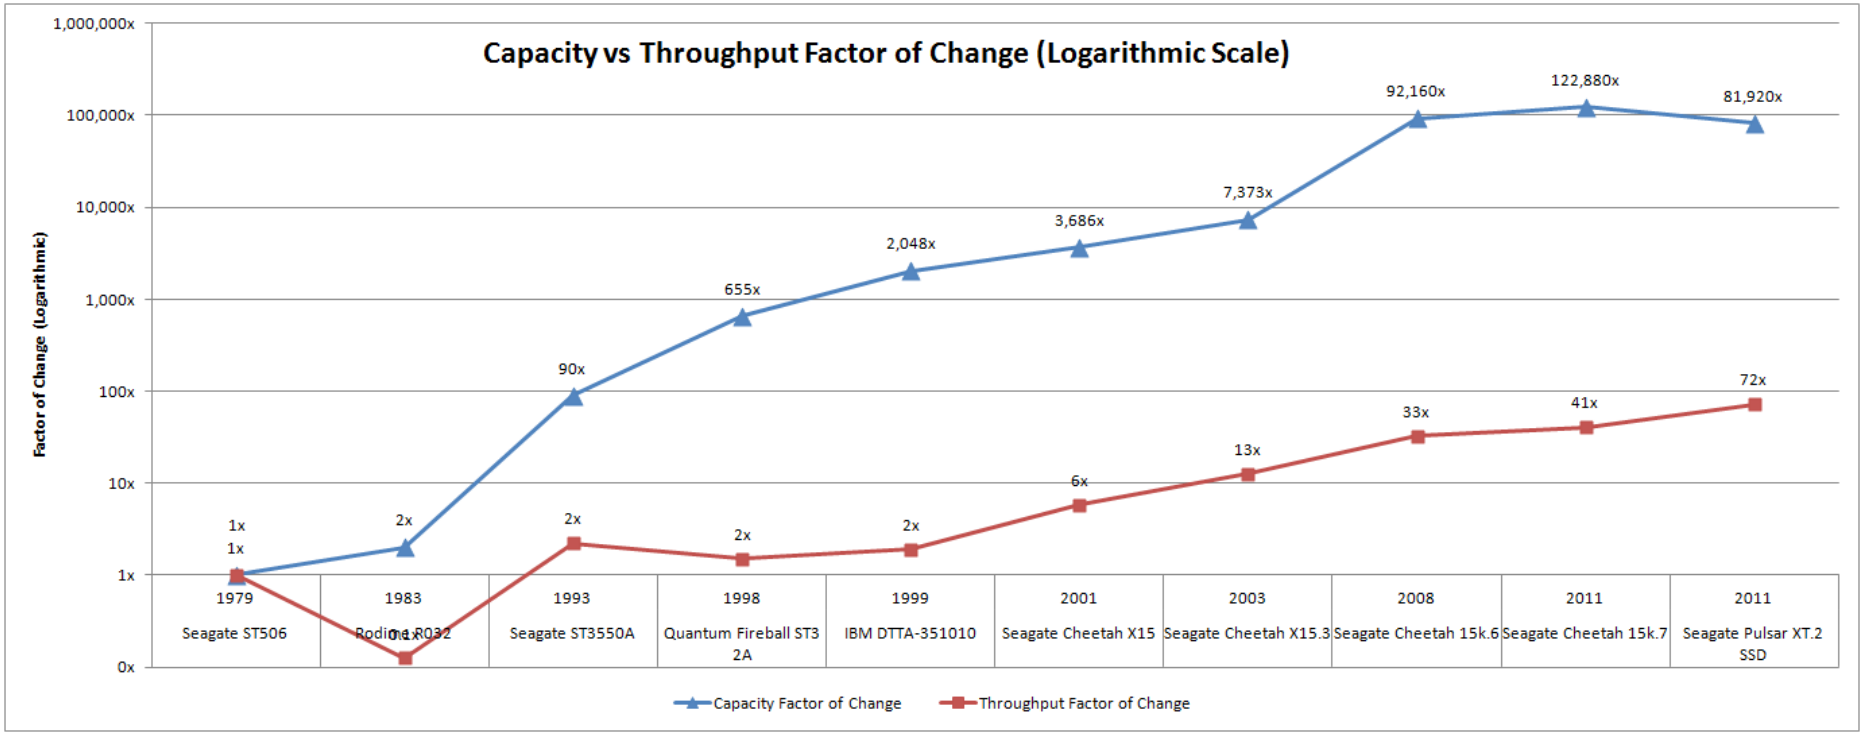


## Loi de Kryder Vs Loi de Moore

*http://en.wikipedia.org/wiki/Kryder's_Law*

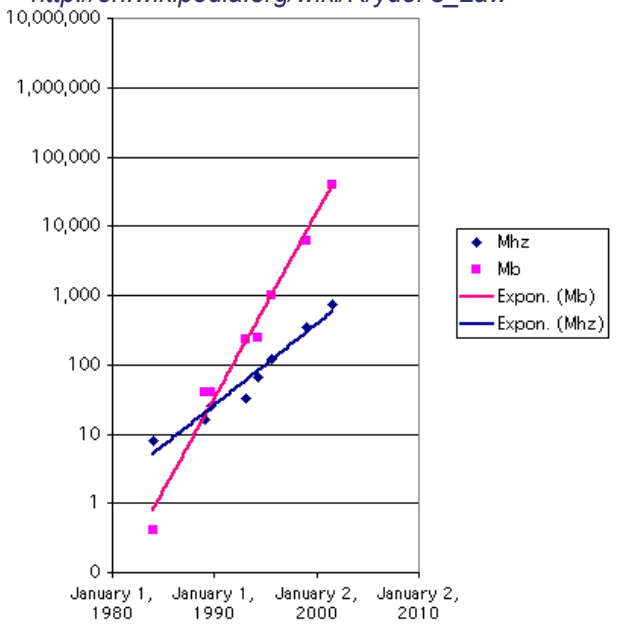

# Changement de paradigme ...

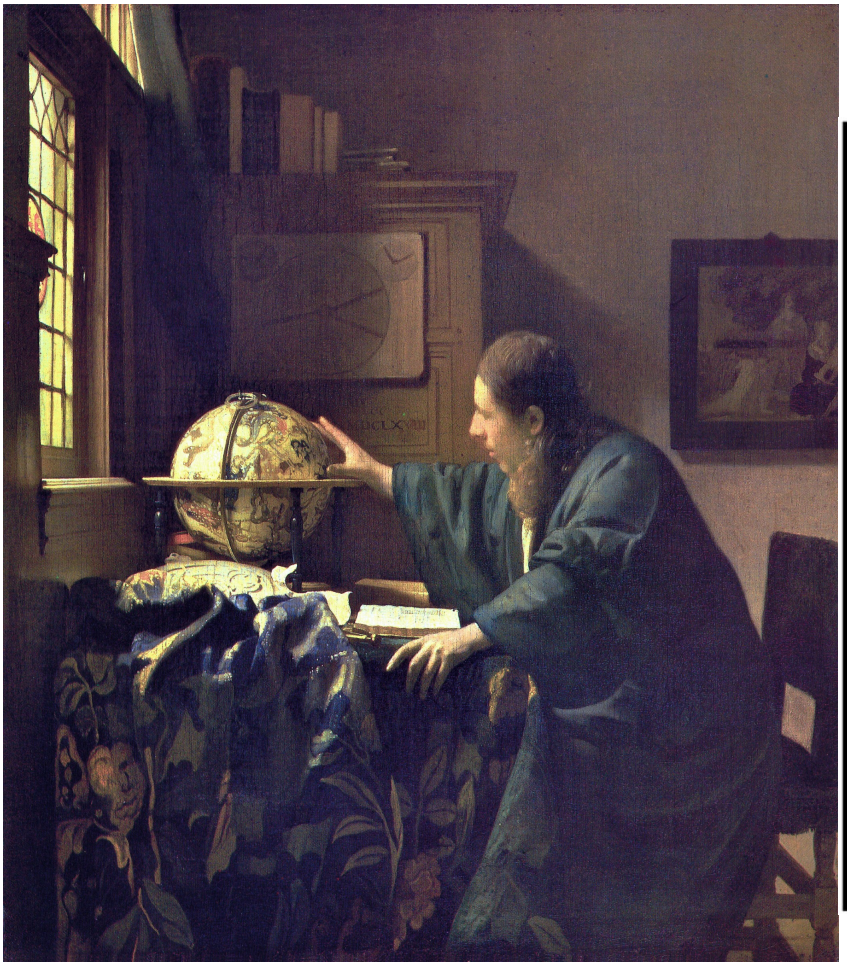

*L'astronome – Vermeer - 1668*

**Geocentric** **Heliocentric**

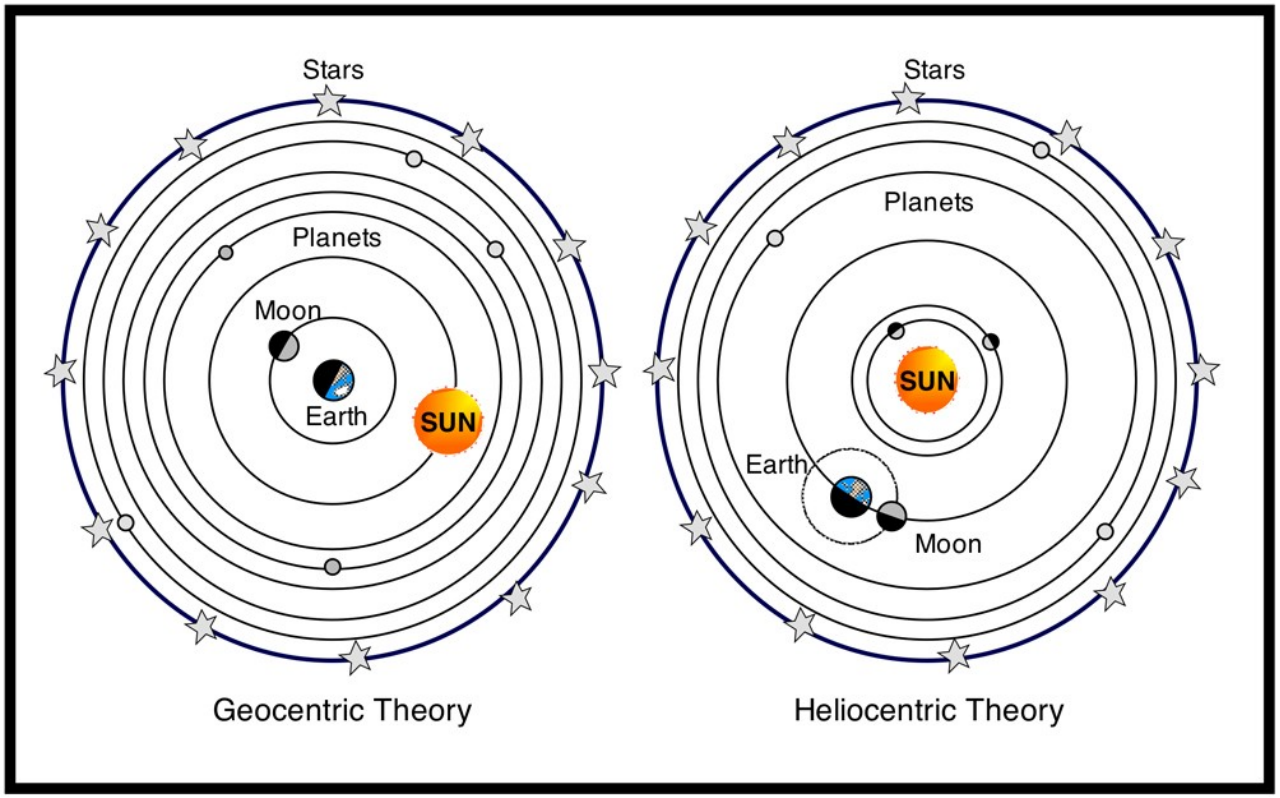

*The Great Wave of Kanagawa – K. Hosukai (1760-1849)*

# Changement de paradigme :

**Déluge de donnée ou « datafication »**
**Changement quantitatif qui implique une rupture**

**Big Data, un double concept :**
**les 3 V : Volumétrie,Vélocité,Variabilité**
**(Véracité, Valeur …)**

**+**

**l'Algorithmique : Traitement des données**

## CPU Centric

Cluster de nœuds calculs avec à coté un espace de stockage

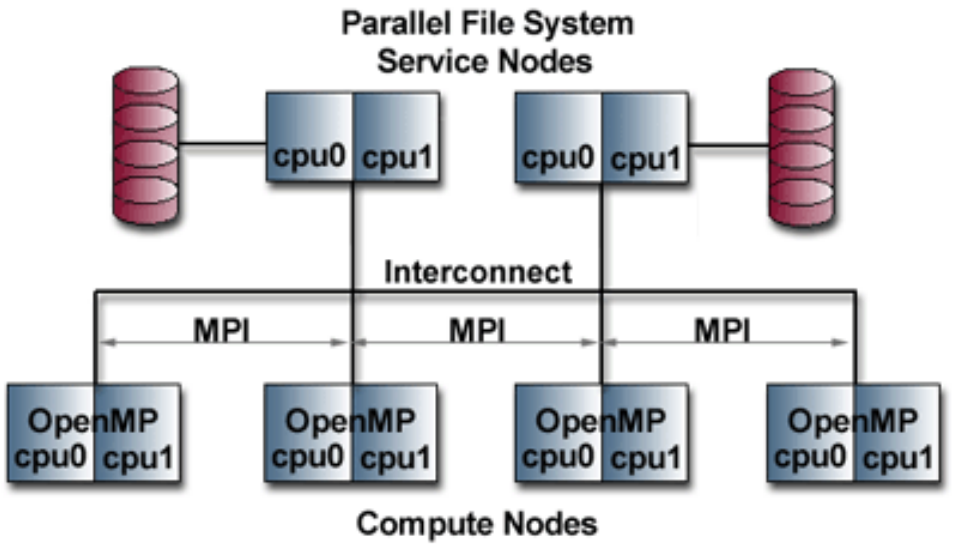


## Data Centric

Cluster de nœuds [calculs + stockage]

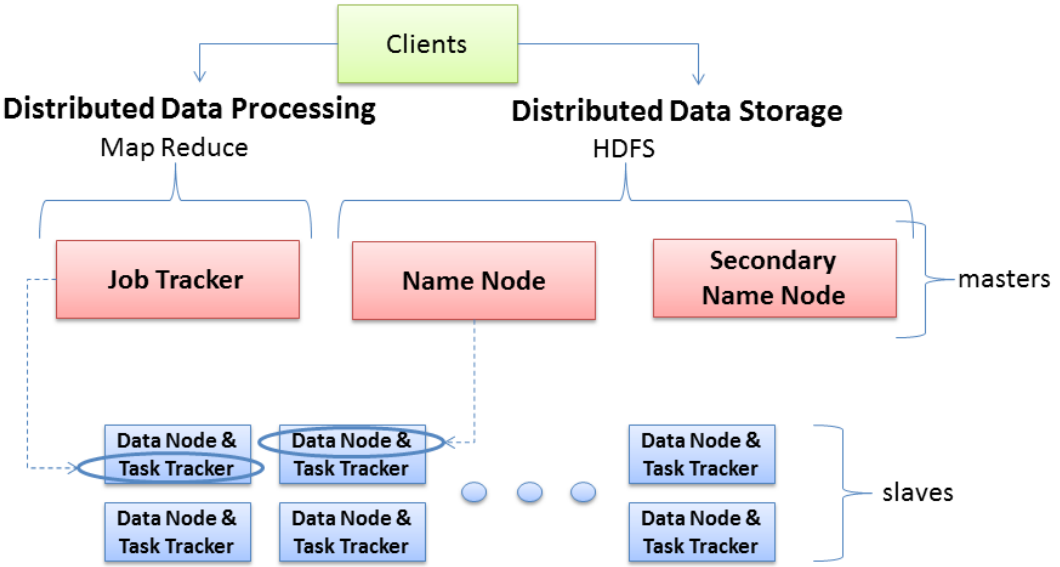


**HPC – MPI (Message Passing Interface)**

**Hadoop – Mapreduce – HDFS**

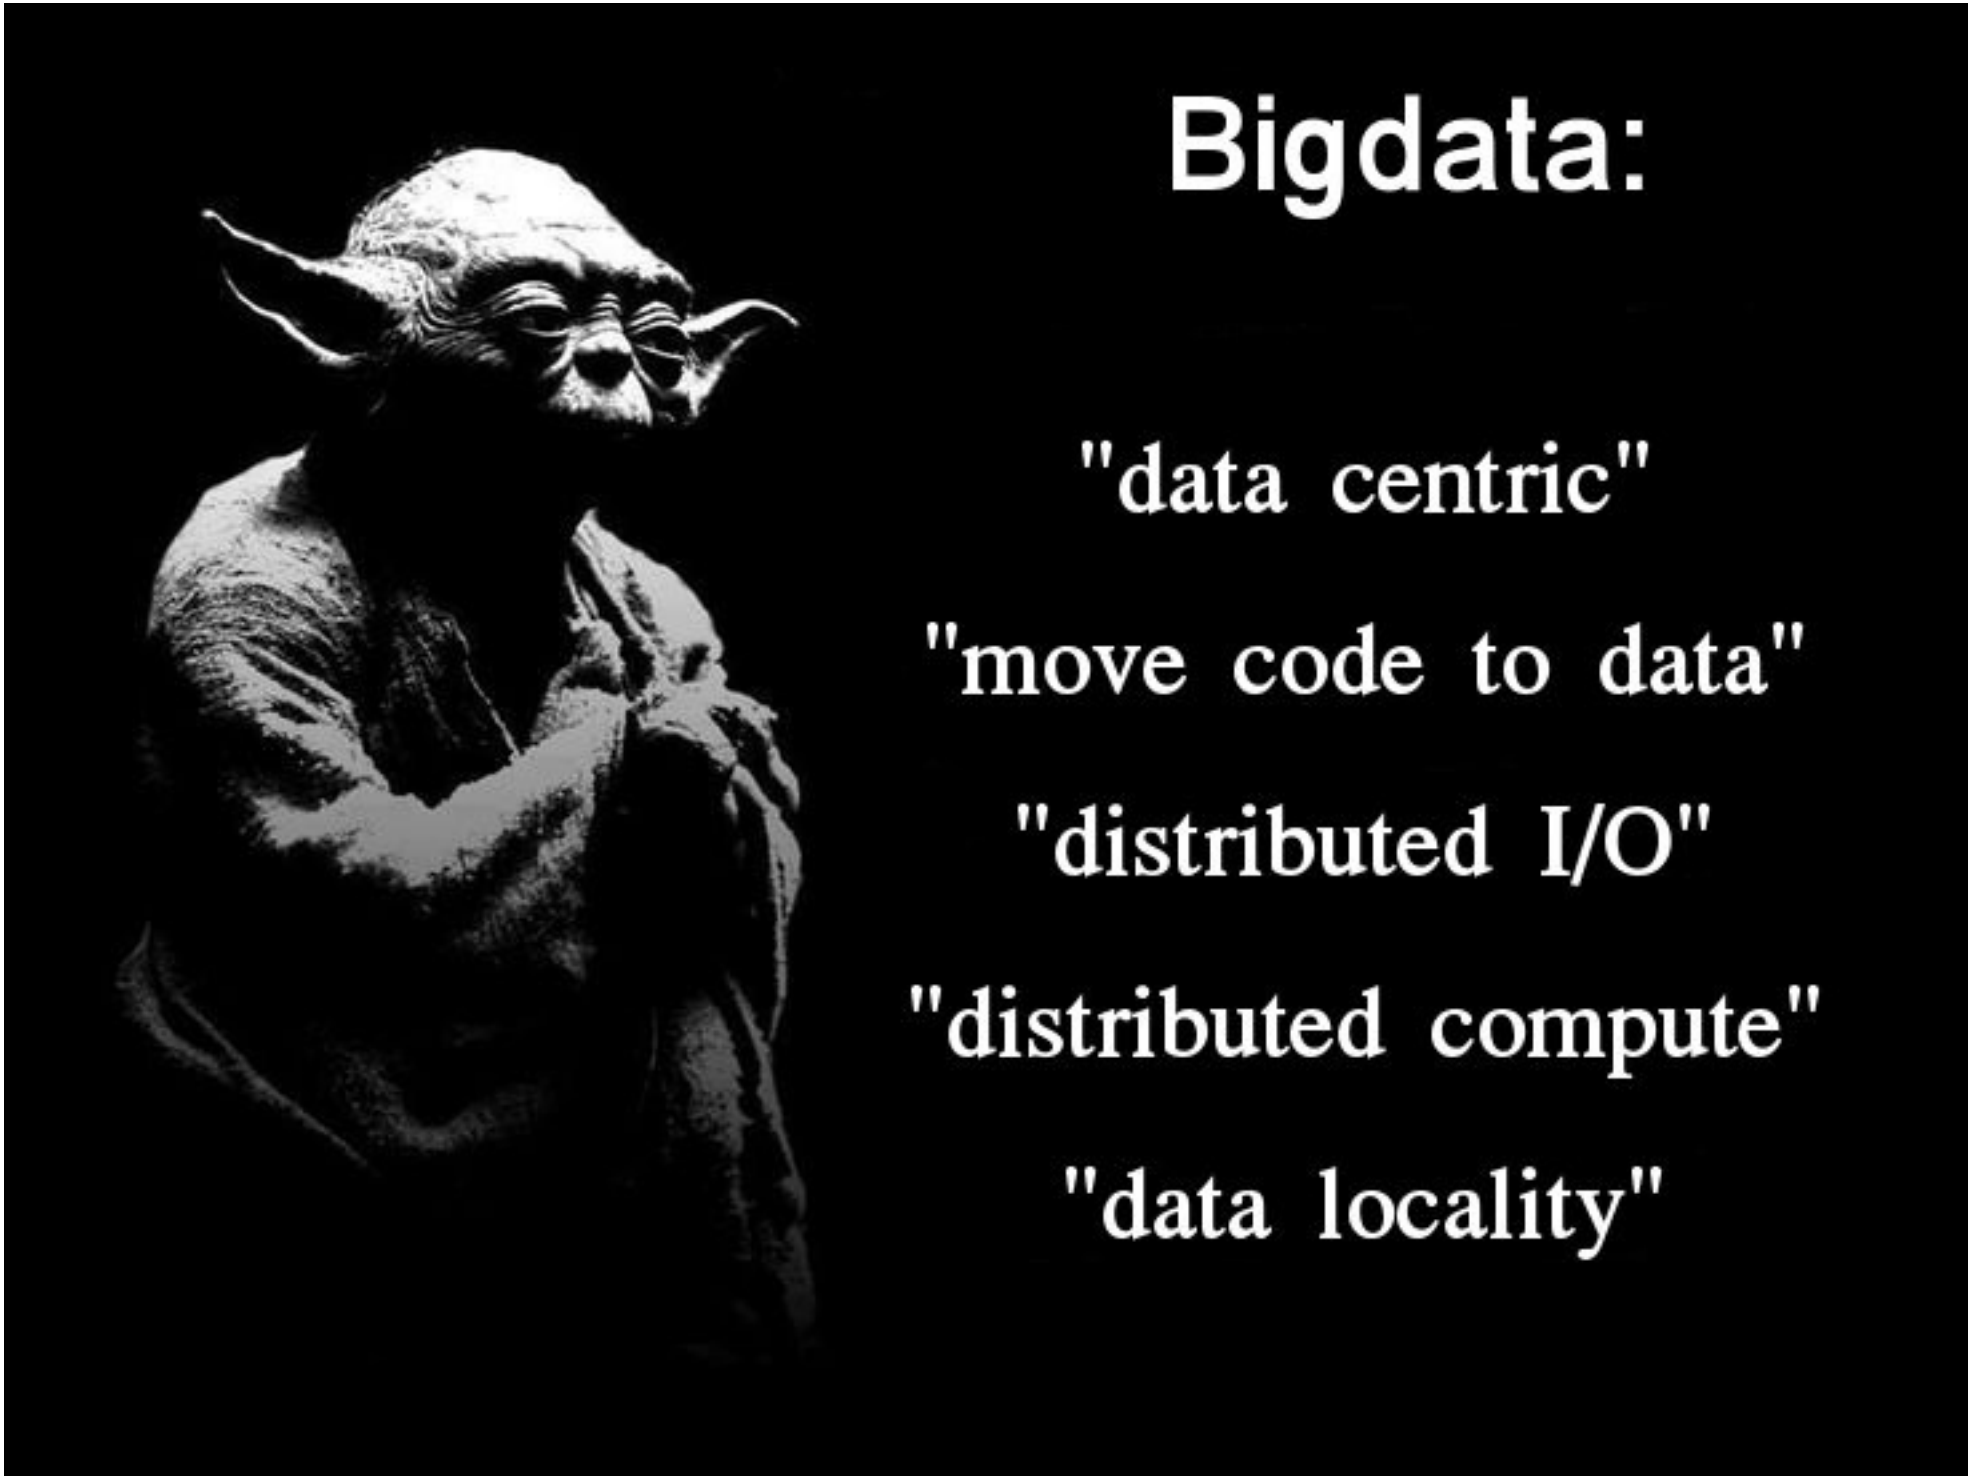
Bigdata:
"data centric"
"move code to data"
"distributed I/O"
"distributed compute"
"data locality"

# Big Data, un bref historique :

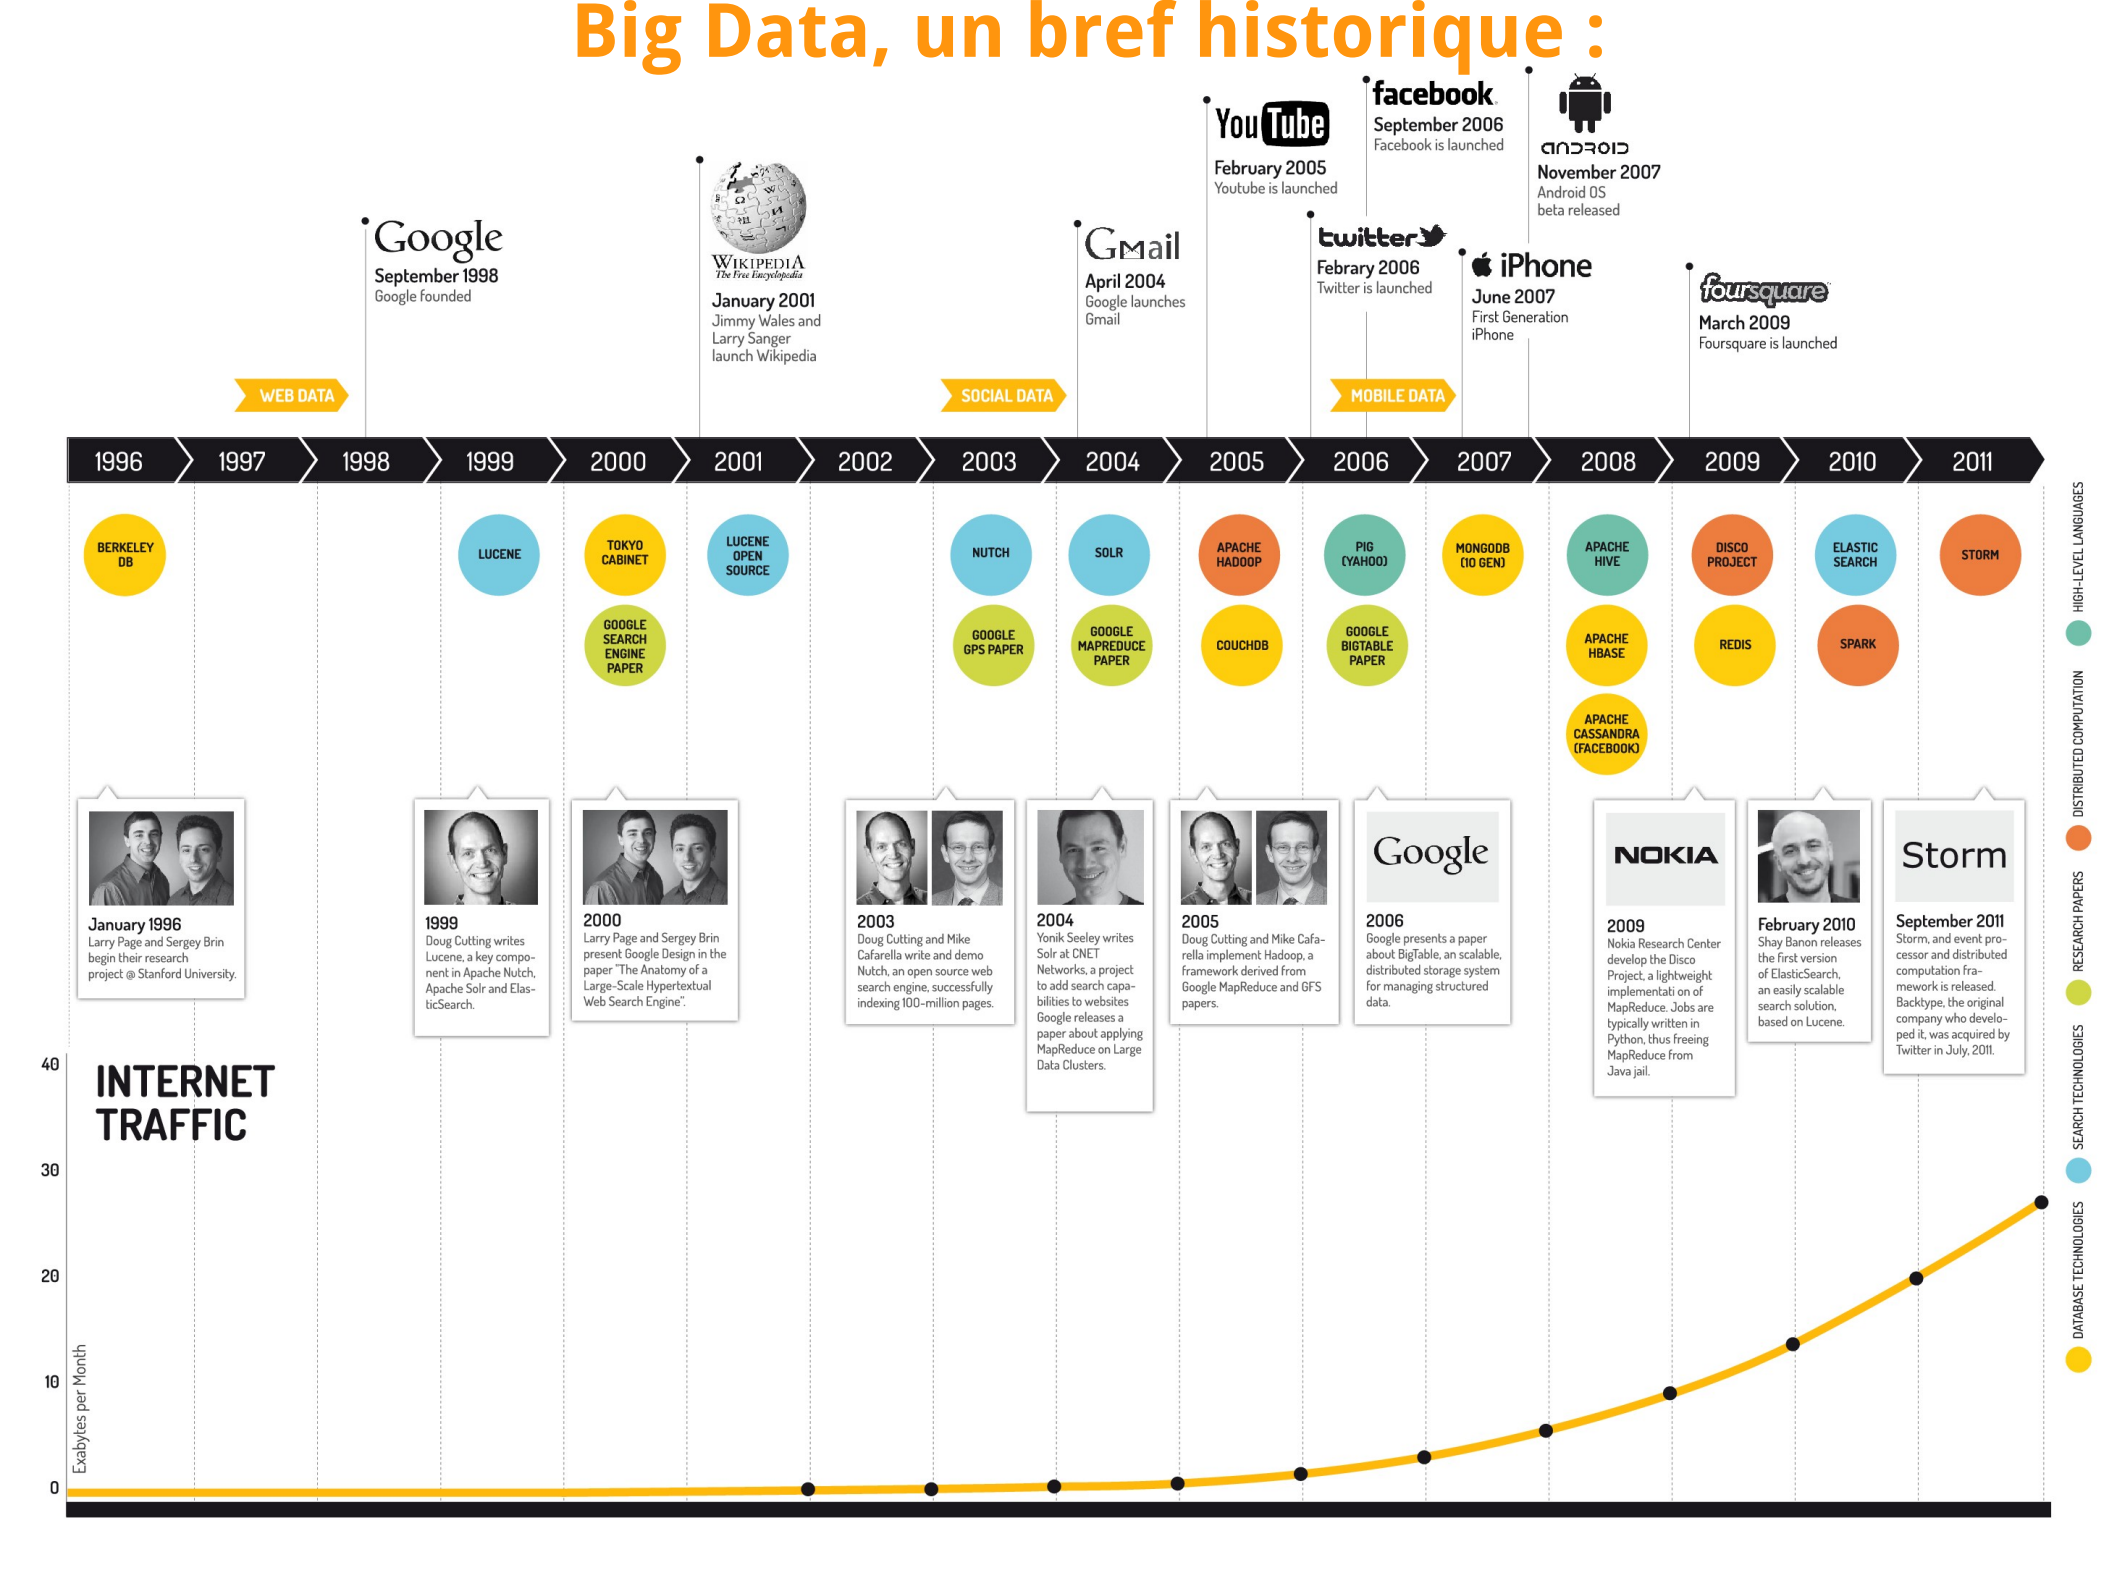

# Big Data, les précurseurs :

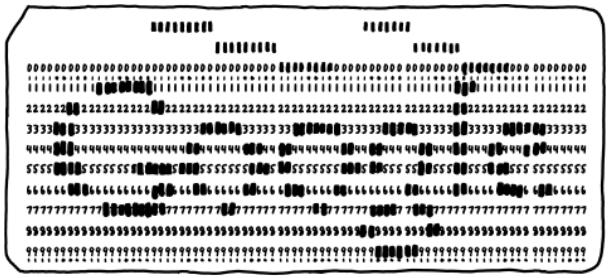

**2003 : Publication de Google FS**
**2004 : Publication de Google Mapreduce**
**2006 : Publication de Google BigTable**

**2006 : 1ere version Hadoop (Doug Cutting)**
**Hadoop = mapreduce + hdfs + hbase**

research.google.com/archive/gfs-sosp2003.pdf
research.google.com/archive/mapreduce-osdi04.pdf
research.google.com/archive/bigtable-osdi06.pdf

# Hadoop : un écosystème

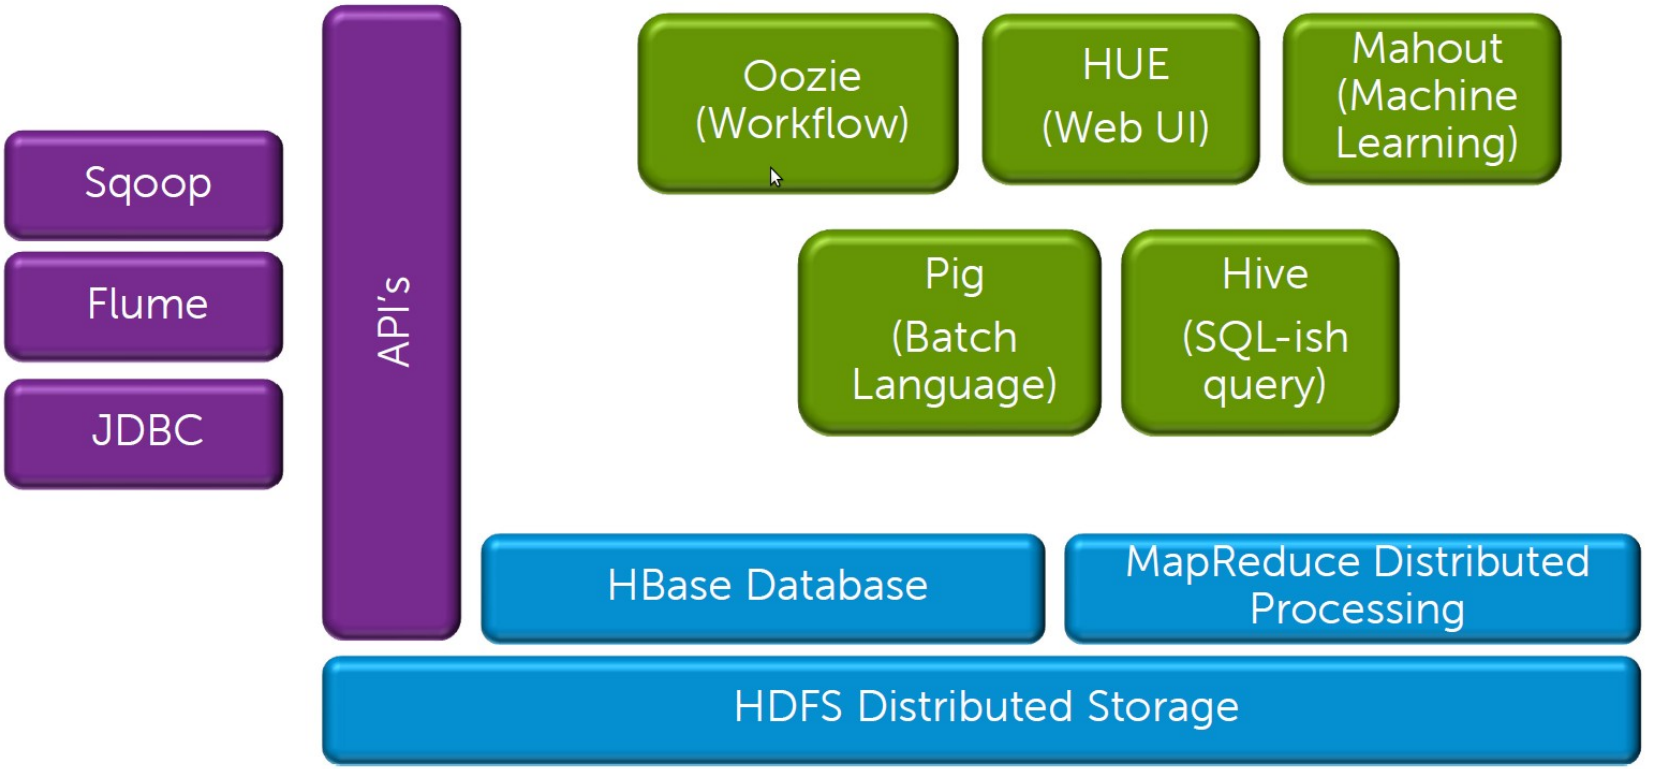


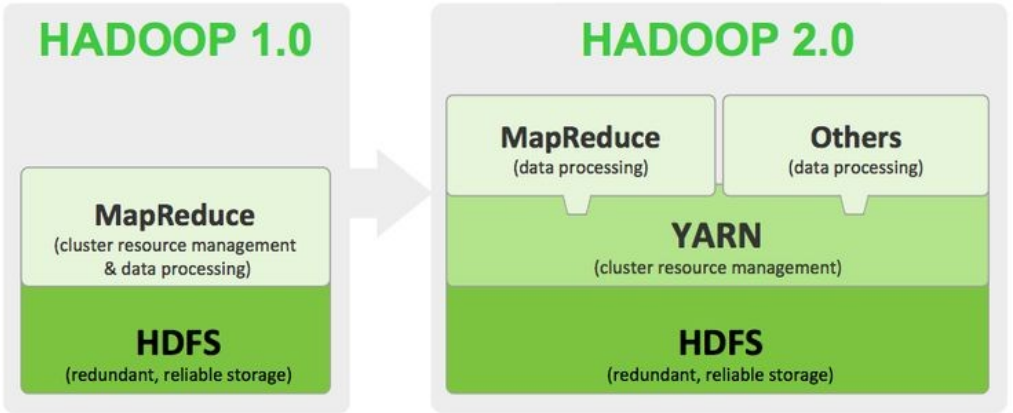

# RHadoop : 3 packages R

REVOLUTION ANALYTICS

https://github.com/RevolutionAnalytics/RHadoop/wiki/Downloads

**Rmr2** : librairie pour utiliser Hadoop Mapeduce
**Rhdfs** : librairie pour utiliser Hadoop HDFS
**Rhbase** :librairie pour utiliser Hadoop Hbase

```
library(rhdfs)
library(rhbase)
library(rmr2)

hdfs.init()

# Generate a 1:100 vector and dump it explicitly in the output defined
ints = to.dfs(1:100, output="/tmp/ints.out/")

# Define MapReduce and execute it
calc = mapreduce(input = ints, map = function(k, v) cbind(v, 2*v))

# Read data back from HDFS
results <- from.dfs(calc)

# Dump the results
results
```

Autre alternative: **Rhipe**

http://www.datadr.org/getpack.html

# Mapreduce :
# « Divide and conquer » « programmation fonctionnelle »

## 1960 - Karatsuba_algorithm, Divide & Conquer

http://en.wikipedia.org/wiki/Karatsuba_algorithm

## 1960 - Lisp par John McCarthy (MIT) :

« Fonctions Récursives d'expressions symboliques et leur évaluation par une Machine, partie I »

http://fr.wikipedia.org/wiki/Lisp

**Mapreduce consiste en deux fonctions map() et reduce().**

**map: (K1, V1) → list(K2, V2)** **reduce: (K2, list(V2)) → list(K3, V3)**

**Exemple : Moteur de recherche & PageRank**

ilpubs.stanford.edu/422/1/1999-66.pdf

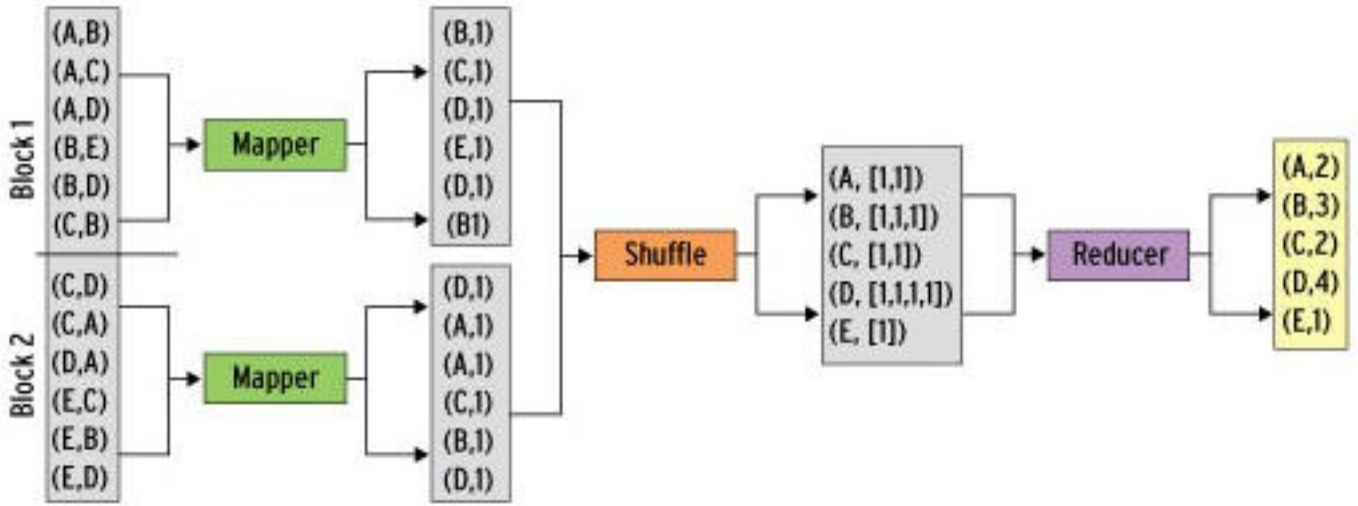

# Mapreduce : exemple de traitement de données météo

Trouver la température maximale par année

Données météorologique USA depuis 1900, http://www.ncdc.noaa.gov/

YYYY = Year

TTTTT = Temperature in units of 0.1 C; 9999 means missing

Q = Quality code

YYYY TTTTTQ

```
0029029070999991901010106004+64333+023450FM-12+000599999V0202701N015919999999N0000001N9-00781+99999102001ADDGF108991999999999999999
0029029070999991901010113004+64333+023450FM-12+000599999V0202901N008219999999N0000001N9-00721+99999102001ADDGF104991999999999999999
0029029070999991901010120004+64333+023450FM-12+000599999V0209991C000019999999N0000001N9-00941+99999102001ADDGF108991999999999999999
0029029070999991901010206004+64333+023450FM-12+000599999V0201801N008219999999N0000001N9-00611+99999101831ADDGF108991999999999999999
```

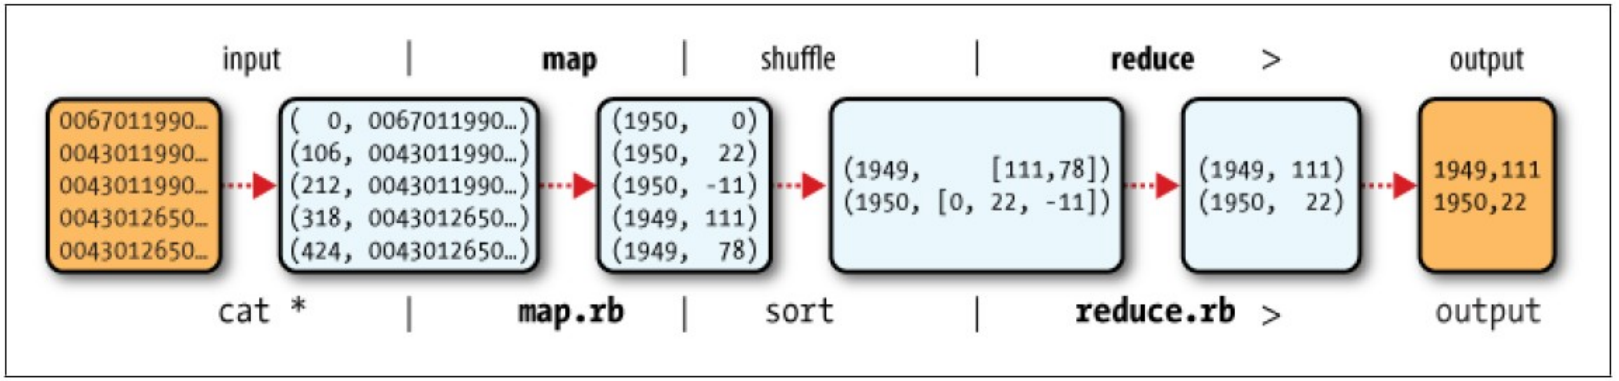


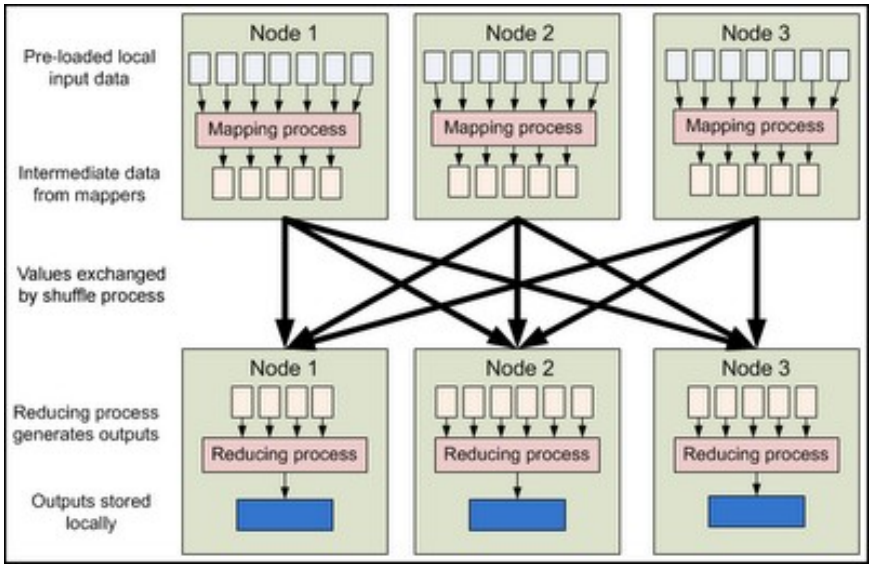


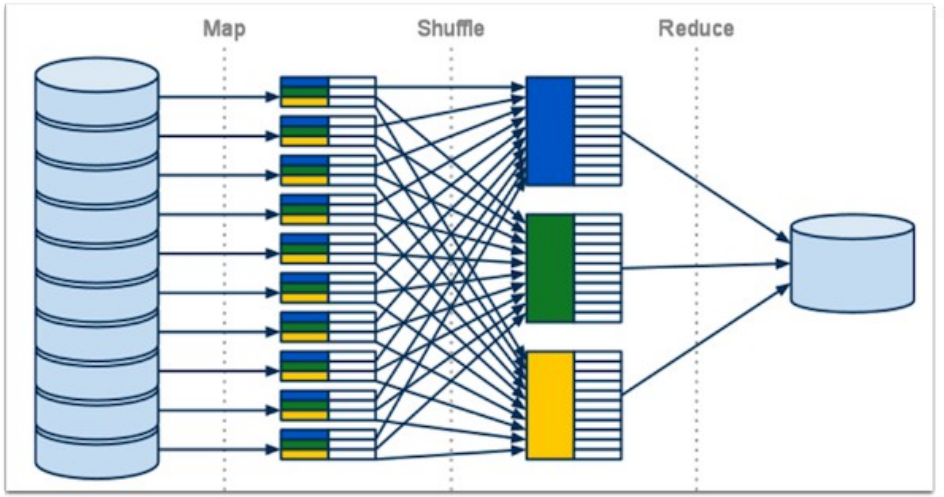

# HDFS

**HDFS** est un système de fichiers **distribué, extensible et portable** développé par Hadoop à partir du **GoogleFS**. Il a été conçu pour stocker de très gros volumes de données sur un grand nombre de machines équipées de **disques durs banalisés**. Il permet l'abstraction de l'architecture physique de stockage, afin de manipuler un système de fichiers distribué comme s'il s'agissait d'un disque dur unique.

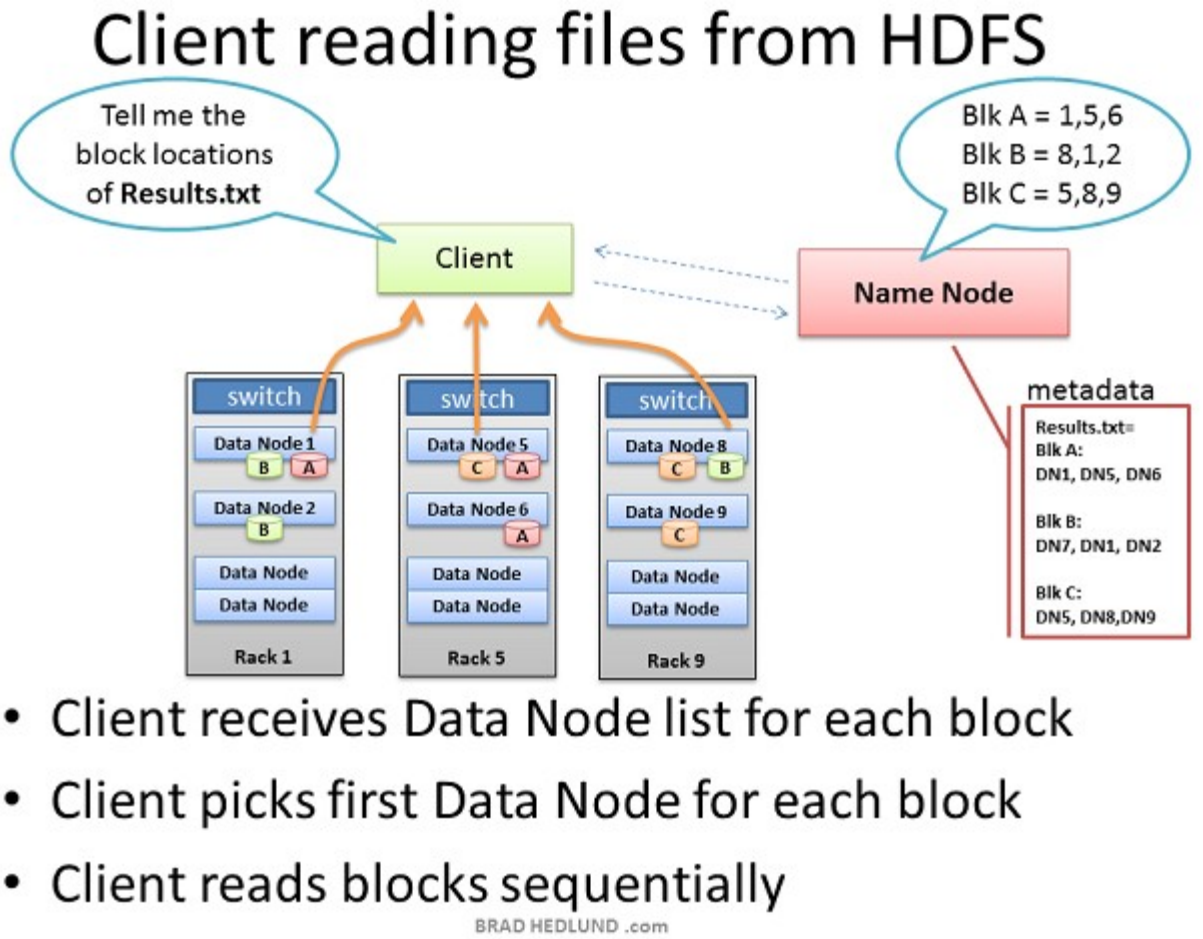


http://hadoop.apache.org/docs/stable1/hdfs_design.html
http://bradhedlund.com/2011/09/10/understanding-hadoop-clusters-and-the-network/

# Hbase,

## Nosql, CouchDB,MongoDB, Newsql, Giraph, Neo4j ,GraphLab ...

HBase est un système de gestion de base de données non-relationnelles distribué, écrit en Java, disposant d'un stockage structuré pour les grandes tables.
HBase est inspirée des publications de Google sur BigTable. Comme BigTable, elle est une base de données orientée colonnes.

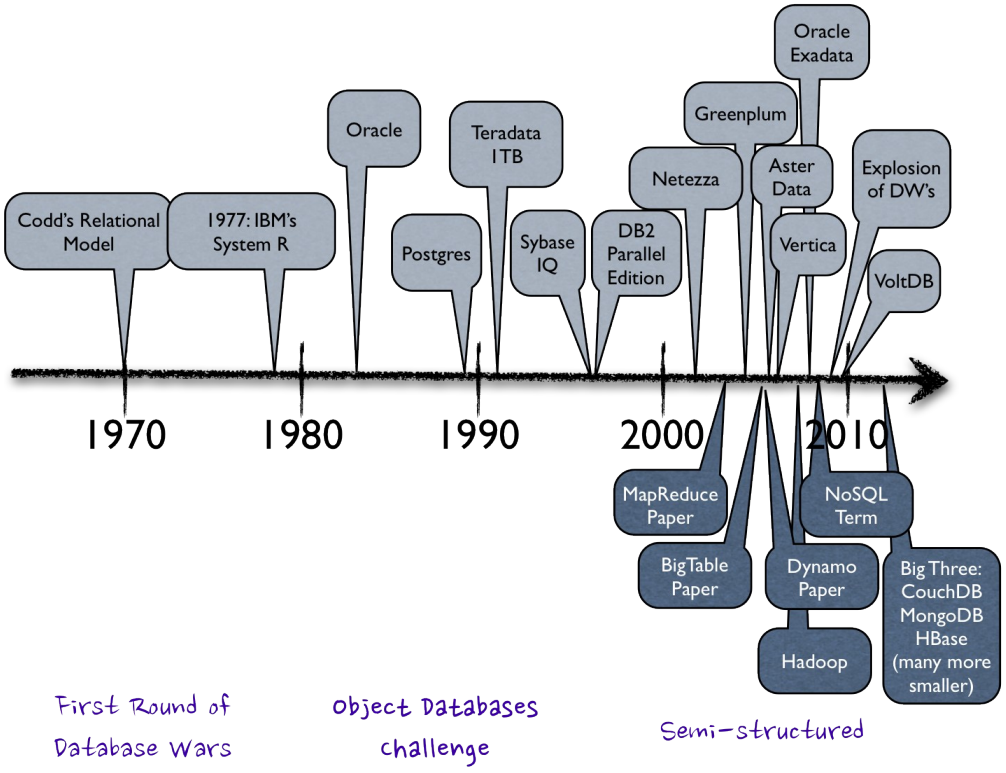


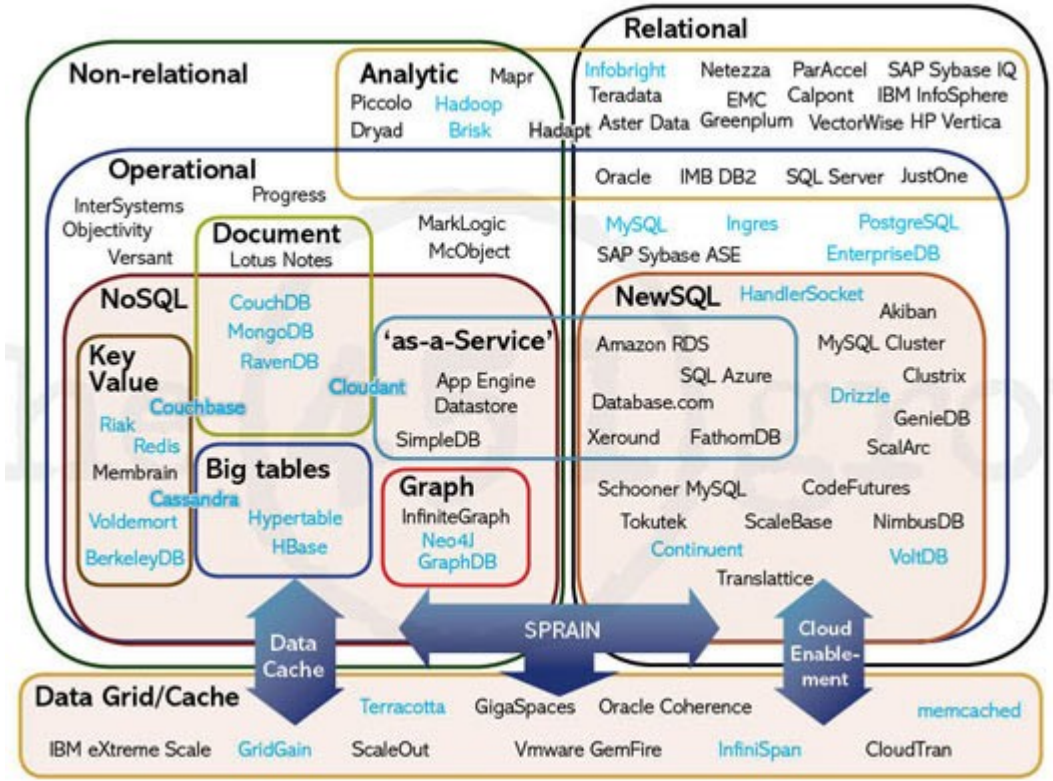


http://blogs.the451group.com/information_management/2011/04/15/nosql-newsql-and-beyond/

# Hadoop , Rhadoop:
# Comment installer,tester, utiliser ? Quelques pistes :

## -Piste 1 : Université Paul Sabatier / DTSI

Cluster Hadoop 4 Noeuds (8xCPU/32GoRam/250Go HDD) + R + Rhadoop + Rstudio
Installation sur infrastructure virtualisée Vmware/Netapp, via Cloudera Manager CDH4
(solution sous optimale , limitée à de petits tests)

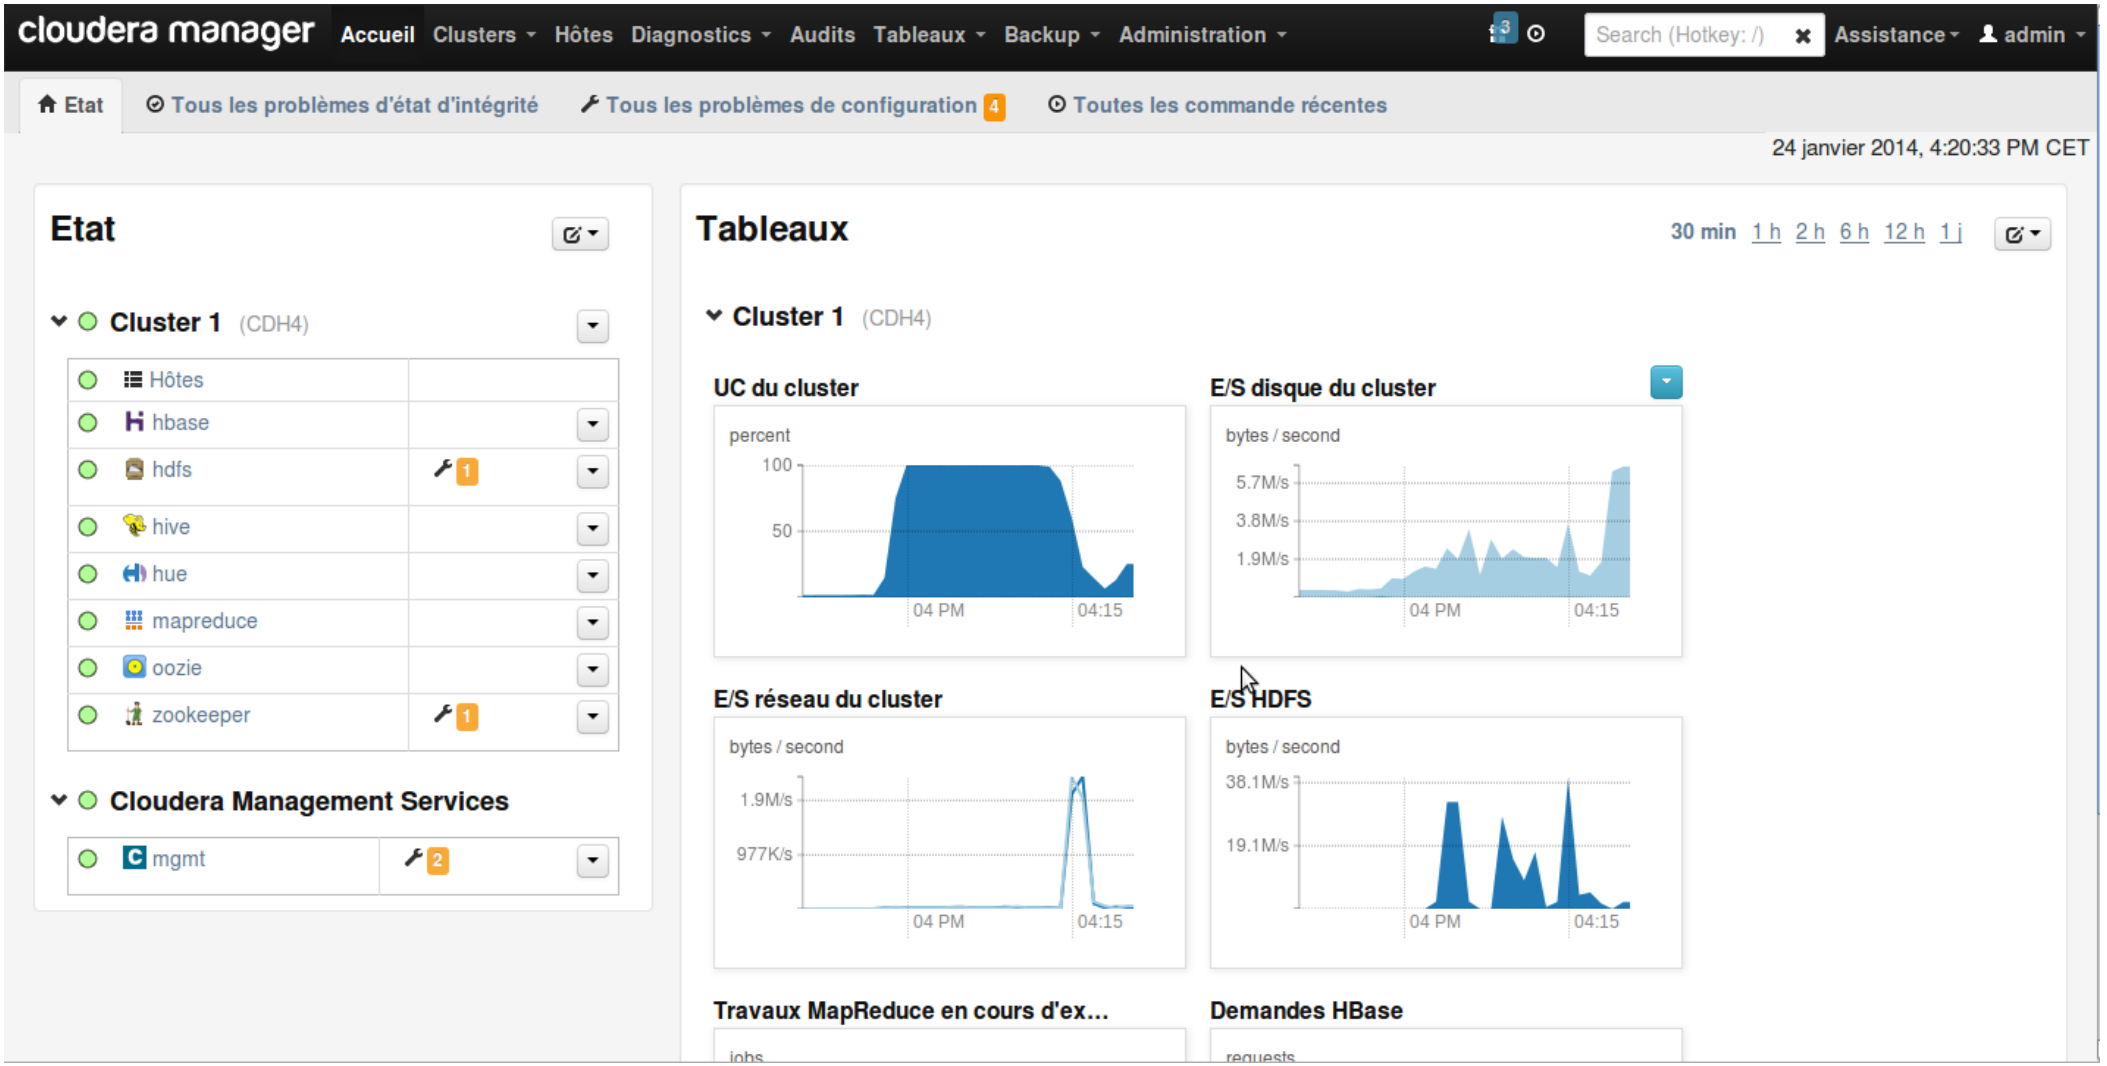

# Hadoop : en pratique

## Méthode 1 : appel natif d'un programme mapreduce écrit en java

Nous utilisons ici le programme « wordcount »

```
wget http://www.gutenberg.org/files/4300/old/ulyss12.txt
hadoop dfs -mkdir gutenberg/books
hadoop dfs -put ulyss12.txt  /data/gutenberg/books
hadoop jar $HADOOP_HOME/hadoop-examples.jar wordcount gutenberg/books  gutenberg/out
hadoop dfs -cat gutenberg/out/* |sort -rn -k2 |more
the  12621
of   7516
and  5929
…
```

## Méthode 2 : utilisation de la fonctionnalité de « streaming » autorisant la réutilisation de programmes écrits en Python, R , Perl , Bash,

```
hadoop jar  $HADOOP_HOME/hadoop-streaming.jar \
 -input REPIN \
 -output REPOUT \
 -mapper /bin/cat \
 -reducer /bin/wc
```

```
hadoop jar  $HADOOP_HOME/hadoop-streaming.jar \
 -input REPIN \
 -output REPOUT \
 -mapper monscript1.py \
 -reducer monscript2.py \
 -file  monscript1.py \
 -file  monscript2.py
```

```
hadoop jar  $HADOOP_HOME/hadoop-streaming.jar \
 -input REPIN \
 -output REPOUT \
 -mapper monscript1.R \
 -reducer monscript2.R \
 -file  monscript1.R \
 -file  monscript2.R
```

## Exemple 1 / jeu de donnée : stat-computing.org - Challenge 2009:

Horaires/Départs/Arrivées/Retards des compagnies aériennes USA (1987-2009)

120 millions d'entrées, 29 variables

```
dsrtadm@node1:~$ hadoop dfs -ls airline/data
Found 22 items
-rw-r--r--   3 dsrtadm hdfs  127162942 2014-01-22 22:32 airline/data/1987.csv
-rw-r--r--   3 dsrtadm hdfs  501039472 2014-01-22 22:31 airline/data/1988.csv
.....
-rw-r--r--   3 dsrtadm hdfs  671027265 2014-01-22 22:39 airline/data/2005.csv
-rw-r--r--   3 dsrtadm hdfs  672068096 2014-01-22 22:38 airline/data/2006.csv
-rw-r--r--   3 dsrtadm hdfs  702878193 2014-01-22 22:39 airline/data/2007.csv
-rw-r--r--   3 dsrtadm hdfs  689413344 2014-01-22 22:41 airline/data/2008.csv
```

## Traitement :

Générer un fichier de sortie : YEAR MONTH COUNT-DEPTDELAY AIRLINE_CODE AVG_DELAY(Ms)

```
hadoop jar $HADOOP_HOME/contrib/streaming/hadoop-streaming-*.jar \
-input airline/data \
-output dept-delay-month \
-mapper map.R \
-reducer reduce.R \
-file map.R -file reduce.R
```

Ou

```
R CMD BATCH  detpdelay.R
```

## Résultats :

```
hadoop dfs -cat dept-delay-month/part* \
| sort -rn -k3 |more
2008        7     102986     WN    9.946634
2008        5     102216     WN    9.428857
2008        3     101423     WN    12.7478
…
```

**LESSONS LEARNED: TIPS FOR TRAVELERS**

- Avoid flying during holidays and summer
- Fly in April, May, and September
- Watch the weather!
- Avoid airports (Newark, JFK, Chicago,...) with consistent delays
- Use carriers (Aloha, Hawaiian, Southwest,...) with superior on-time performance
- Fly early in the day
- Avoid flights that depart between 5 and 7 p.m.

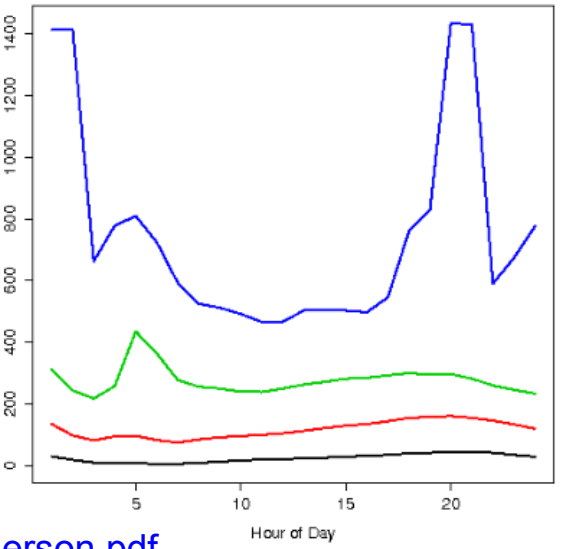


http://stat-computing.org/dataexpo/2009/posters/kane-emerson.pdf

http://stat-computing.org/dataexpo/2009/posters/wicklin-allison.pdf

# Piste 2 : Utiliser le cloud Amazon http://aws.amazon.com

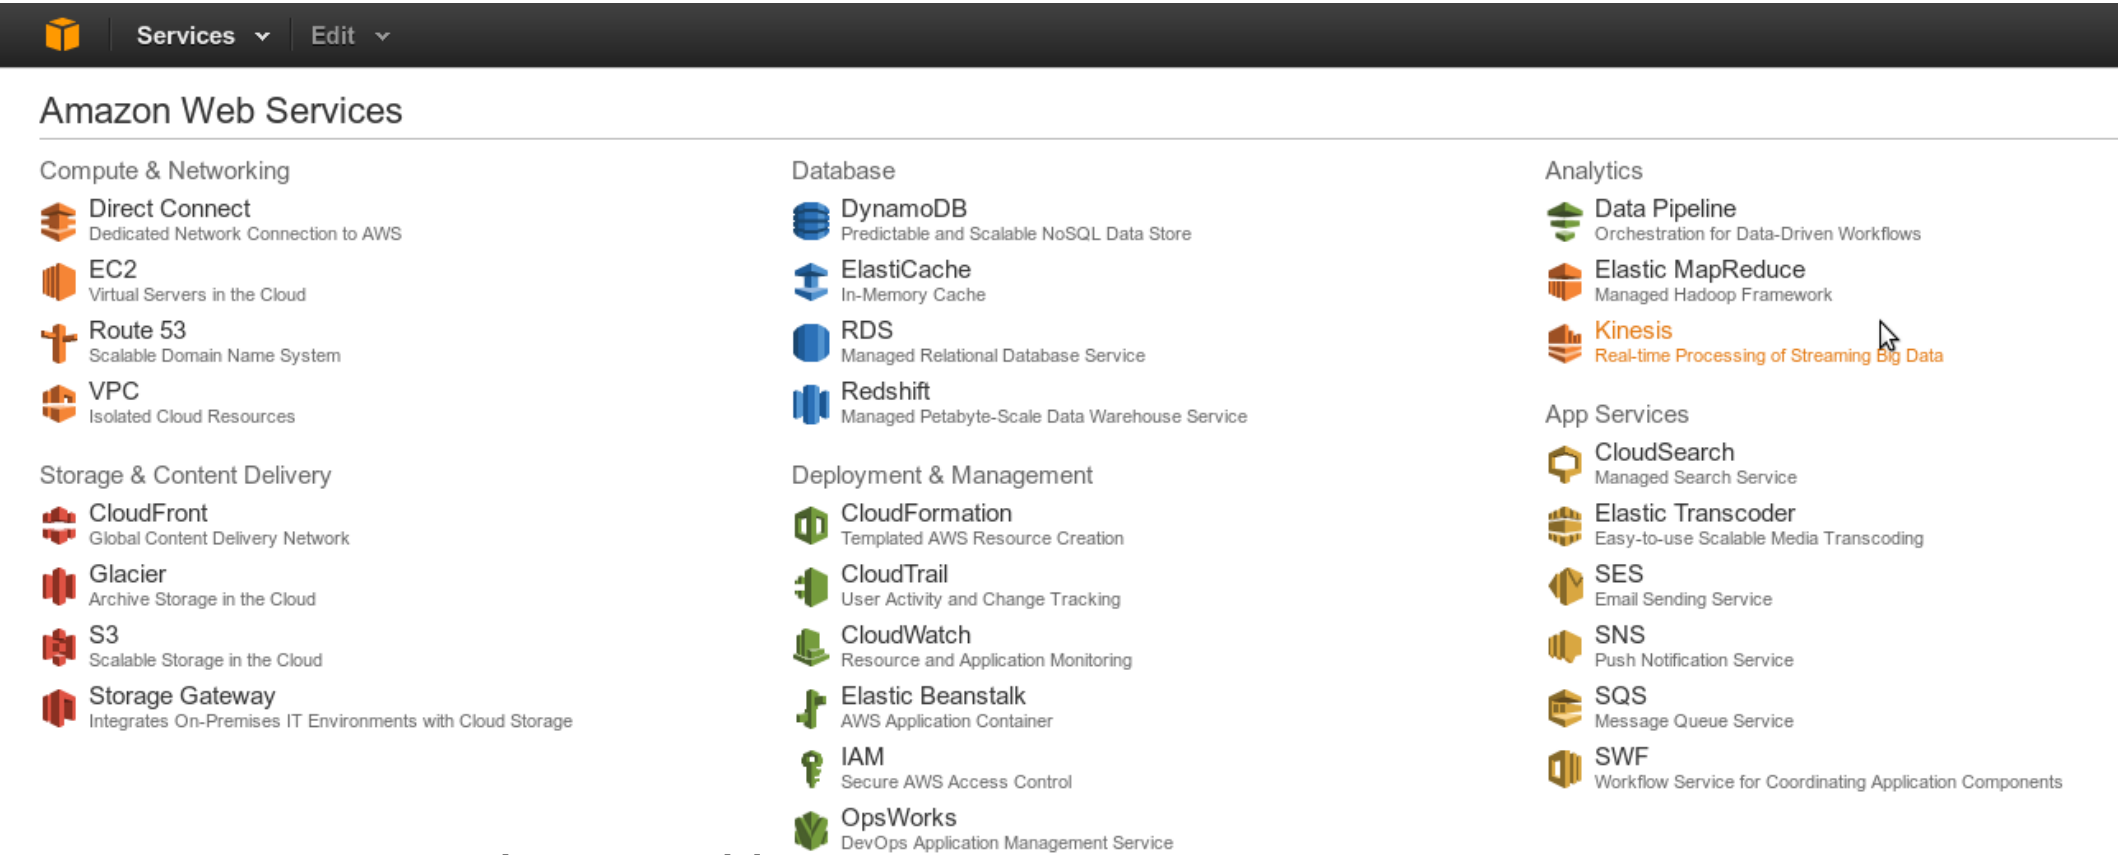


**Amazon EC2 instances pricing**

| VCPU | ECU | Mémoire (GiB) | Stockage des instances (Go) | Utilisation de Linux/UNIX |
|---|---|---|---|---|
| m1.small | 1 | 1.7 | 1 x 160 | $0.060 par heure |
| m1.med | 1 | 3.75 | 1 x 410 | $0.120 par heure |
| m1.large | 2 | 4 | 2 x 420 | $0.240 par heure |
| m1.xlarge | 4 | 8 | 15 | 4 x 420 $0.480 par heure |

**Spot (ponctuelle) / région USA Est (Virginie)**

| Instance | Linux |
|---|---|
| m1.small | $0.007 par heure |
| m1.med | $0.013 par heure |
| m1.large | $0.026 par heure |
| m1.xlarge | $0.052 par heure |

http://aws.amazon.com/fr/ec2/pricing/
http://aws.amazon.com/fr/s3/pricing/

# Méthode 1 : Amazon EMR (Elastic Map Reduce) :


Activer un cluster Hadoop 1.0 pré-configuré + Rhadoop de 10 Noeuds avec 10To stockage en ligne de commande (Activation en ~15 mn).
Utilisation de l'outil écrit en Ruby « elastic-mapreduce » d'Amazon

```
elastic-mapreduce --create --alive –master-instance-type=m1.large \
 --slave-instance-type=m1.medium --num-instances=10 --enable-debugging \
 --hadoop-version 1.0.3 --ami-version 2.4.2 --name 10-NODES-RHADOOP \
 --bootstrap-action s3://elasticmapreduce/bootstrap-actions/install-ganglia –bootstrap-action \
 s3://bigdataths/script/bootstrap-rhadoop3-deb6.sh \
 --jar s3://elasticmapreduce/libs/script-runner/script-runner.jar --step-name instpig --args \
"s3://elasticmapreduce/libs/pig/pig-script,--base-path,s3://elasticmapreduce/libs/pig/,--install-pig,--pig-versions,latest" \
 --jar s3://elasticmapreduce/libs/script-runner/script-runner.jar --step-name insthive --args \
"s3://elasticmapreduce/libs/hive/hive-script,--base-path,s3://elasticmapreduce/libs/hive/,--install-hive,--hive-versions,latest"

elastic-mapreduce --list

j-2GHO33PZ7U9N1     BOOTSTRAPPING  ec2-54-195-17-24.eu-west-1.compute.amazonaws.com  10-NODES-RHADOOP
   PENDING        Setup Hadoop Debugging
   PENDING        instpig
   PENDING        insthive

elastic-mapreduce  -j j-34TUDSWU0RK3J –ssh

elastic-mapreduce –terminate j-34TUDSWU0RK3J
```

Amazon Elastic MapReduce Ruby Client
http://elasticmapreduce.s3.amazonaws.com/elastic-mapreduce-ruby.zip

## Méthode 2 : Amazon EC2 et l'outil Whirr d'apache.


Activer un cluster de 10 nœuds + Hadoop personnalisé + Rhadoop , 10 To
en ligne de commande (Activation en ~15 mn)
Utilisation de « whirr » de la fondation apache.

```
1 compte Amazon AWS
1 machine locale linux (debian/ubuntu/centos)
Avoir installer whirr (et JDK)
1 fichier de conf « hadoop.properties »

whirr.service-name=hadoop
whirr.cluster-name=10-nodes-demo
whirr.instance-templates=1 jt+nn,9 dn+tt
whirr.provider=ec2
whirr.identity=[AWS ID]
whirr.credential=[AWS KEY]
whirr.private-key-file=${sys:user.home}/.ssh/id_rsa
whirr.public-key-file=${sys:user.home}/.ssh/id_rsa.pub
whirr.hadoop-install-runurl=cloudera/cdh/install
whirr.hadoop-configure-runurl=cloudera/cdh/post-configure


whirr launch-cluster --config hadoop.properties

whirr destroy-cluster --config hadoop.properties
```

http://www.evanconkle.com/2011/11/run-hadoop-cluster-ec2-easy-apache-whirr/

## Méthode 3 : Amazon EC2 et Cloudera manager installer

cloudera

Activer un cluster 10 nœuds + Hadoop personnalisé + Rhadoop , 10 To
en ligne de commande (Activation en ~15 mn)
Utilisation de «cloudera manager installer » installation graphique depuis un premier nœud sous linux dans le cloud amazon ec2.
Lancer le binaire « cloudera-manager-installer.bin » qui va détecter l'écosystème Amazon EC2 et proposer une installation complète via un Wizard ….

http://www.cloudera.com/content/cloudera-content/cloudera-docs/CM4Ent/latest/Cloudera-Manager-Installation-Guide/cmig_install_on_EC2.html

# *Merci !*
# *Des questions ?*