# Bases de données documentaires et distribuées
# Cours NFE04
## Map Reduce

Auteur : Philippe Rigaux

Département d'informatique
Conservatoire National des Arts & Métiers, Paris, France

# Les programmes vers les données, pas l'inverse !

Client serveur pour traiter des TOs de données ? **Ne marche pas**.

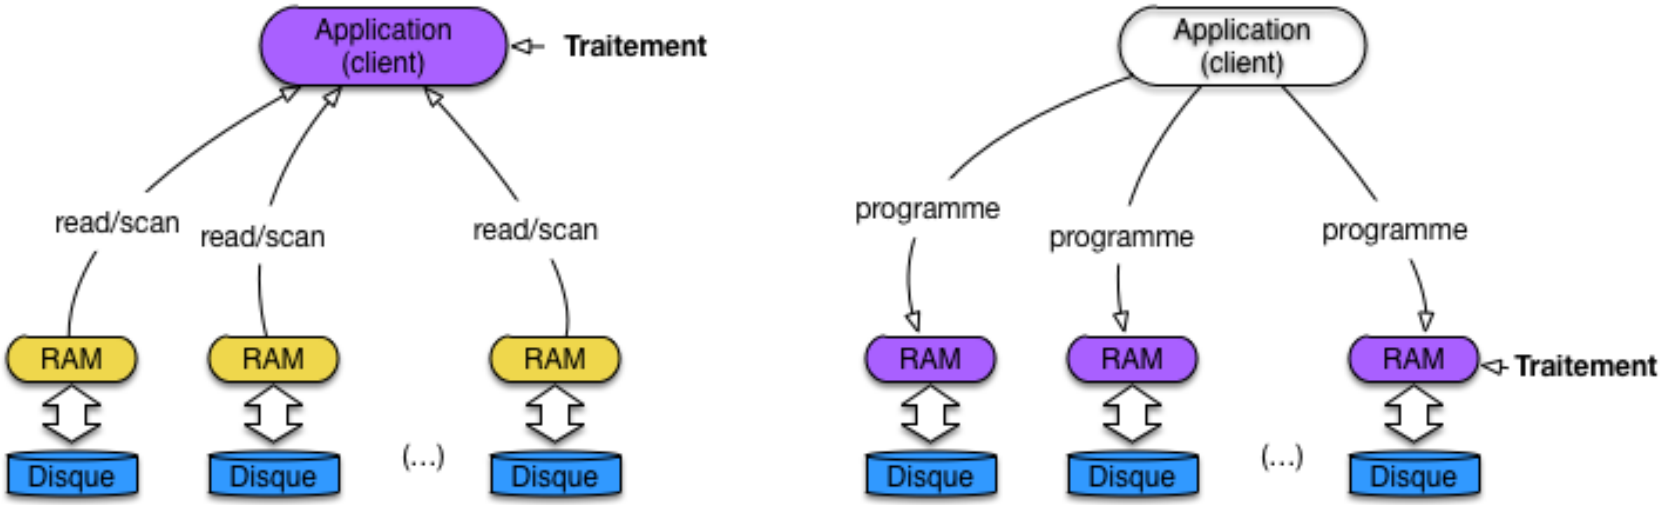


Il faut placer les traitements au plus près des données.

# Pourquoi un *framework*

Un framework **pilote** un traitement, conduit selon un processus générique (notion d'inversion de contrôle).

L'application "injecte" des fonctions dans le framework.
Exemples : Applications MVC, XSLT, Couches ORM, **MapReduce**.

Le framework applique les fonctions pendant l'exécution du processus.

- Une fonction *map()* à appliquer pendant la phase de Map
- Une fonction *reduce()* à appliquer pendant la phase de Reduce.

**Rôle d'un *framework* MapReduce**

Prendre en charge la distribution, et gérer les reprises sur panne.

# Comptons les mots : la fonction de Map

Phase de Map : on extrait les termes, on les compte localement, on transmet au framework.

```
function mapTF($id, $contenu)
{
  // $id: identifiant du document
  // $contenu: contenu textuel du document

  // On boucle sur tous les termes du contenu
  foreach  ($t in $contenu) {
    // Comptons le nb d'occurrences de $t dans $contenu
    $count = nbOcc ($t, $contenu);
    // Emission du terme et de son nombre d'occurrences
    emit ($t, $count);
  }
}
```

NB : rien n'indique le contexte de distribution.

# Comptons les mots : la fonction de Reduce

Phase de Reduce : on reçoit, pour chaque terme, tous les compteurs, et on les additionne.

```
function reduceTF($t, $compteurs)
{
  // $t: un terme
  // $compteurs: les nombres d'occurrences, un pour chaque
  $total = 0;

  // Boucles sur les compteurs et calcul du total
  foreach ($c in $compteurs) {
   $total = $total + $c;
  }

  // Et on produit le total
  return $total;
}
```

Même remarque : rien n'indique le contexte de distribution.

# L'exécution par le *framework*

| URL | Document |
|---|---|
| $u_1$ | the jaguar is a new world mammal of the felidae family. |
| $u_2$ | for jaguar, atari was keen to use a 68k family device. |
| $u_3$ | mac os x jaguar is available at a price of us $199 for apple's new "family pack". |
| $u_4$ | one such ruling family to incorporate the jaguar into their name is jaguar paw. |
| $u_5$ | it is a big cat. |

# Déroulons le processus

| term | count |
|---|---|
| jaguar | 1 |
| mammal | 1 |
| family | 1 |
| jaguar | 1 |
| available | 1 |
| jaguar | 1 |
| family | 1 |
| family | 1 |
| jaguar | 2 |
| ... | |

Sortie du *map*
Entrée du *shuffle*

# Déroulons le processus

| term | count |
|---|---|
| jaguar | 1 |
| mammal | 1 |
| family | 1 |
| jaguar | 1 |
| available | 1 |
| jaguar | 1 |
| family | 1 |
| family | 1 |
| jaguar | 2 |
| ... | |

Sortie du *map*
Entrée du *shuffle*

| term | count |
|---|---|
| jaguar | 1,1,1,2 |
| mammal | 1 |
| family | 1,1,1 |
| available | 1 |
| ... | |

Sortie du *shuffle*
Entrée du *reduce*

# Déroulons le processus

| term | count |
|---|---|
| jaguar | 1 |
| mammal | 1 |
| family | 1 |
| jaguar | 1 |
| available | 1 |
| jaguar | 1 |
| family | 1 |
| family | 1 |
| jaguar | 2 |
| ... | |

Sortie du *map*
Entrée du *shuffle*

| term | count |
|---|---|
| jaguar | 1,1,1,2 |
| mammal | 1 |
| family | 1,1,1 |
| available | 1 |
| ... | |

Sortie du *shuffle*
Entrée du *reduce*

| term | count |
|---|---|
| jaguar | 5 |
| mammal | 1 |
| family | 3 |
| available | 1 |
| ... | |

Résultat final

# La grande vision

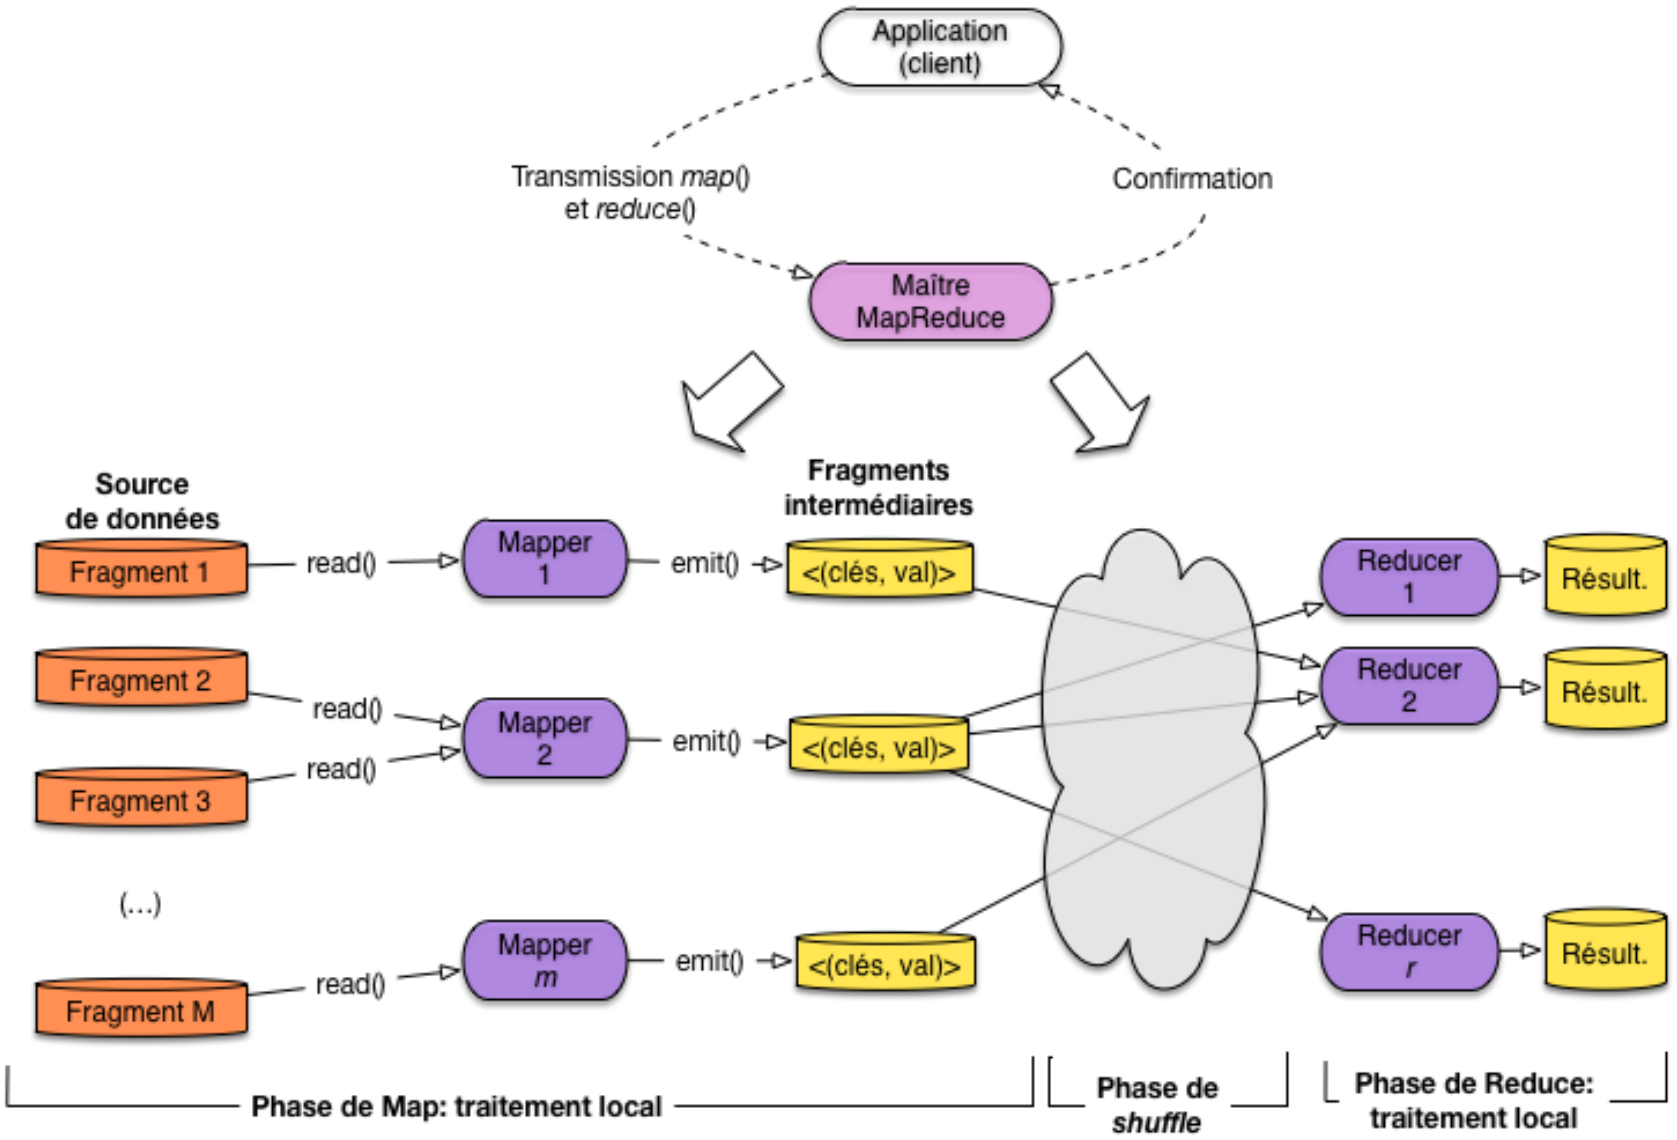

# Quelques calculs

Supposons une collection avec 1 million de documents ; chaque document contient 100 termes en moyenne, et sa taille est (en moyenne) de 1 KO.

Le partitionnement découpe en fragments de 64 MO : chaque fragment contient 64 000 documents. Il y a à peu près $M = \lceil 1{,}000{,}000/64{,}000 \rceil \approx 16{,}000$ fragments.

Si j'ai 16 machines, chacune traitera 1 000 fragments par 1 000 tâches.

Chaque tâche (Mapper) produit 6 400 000 paires (terme, compteur)

Si j'ai 10 machines pour la phase de Reduce : chaque Reducer $R_i$ reçoit 640 000 paires de chaque Mapper, pour tous les termes $t$ tels que $hash(t) = i$ $(1 \leq i \leq 10)$

# Un tout petit exemple

Quatre documents qui parlent de loups, de moutons, de bergerie.

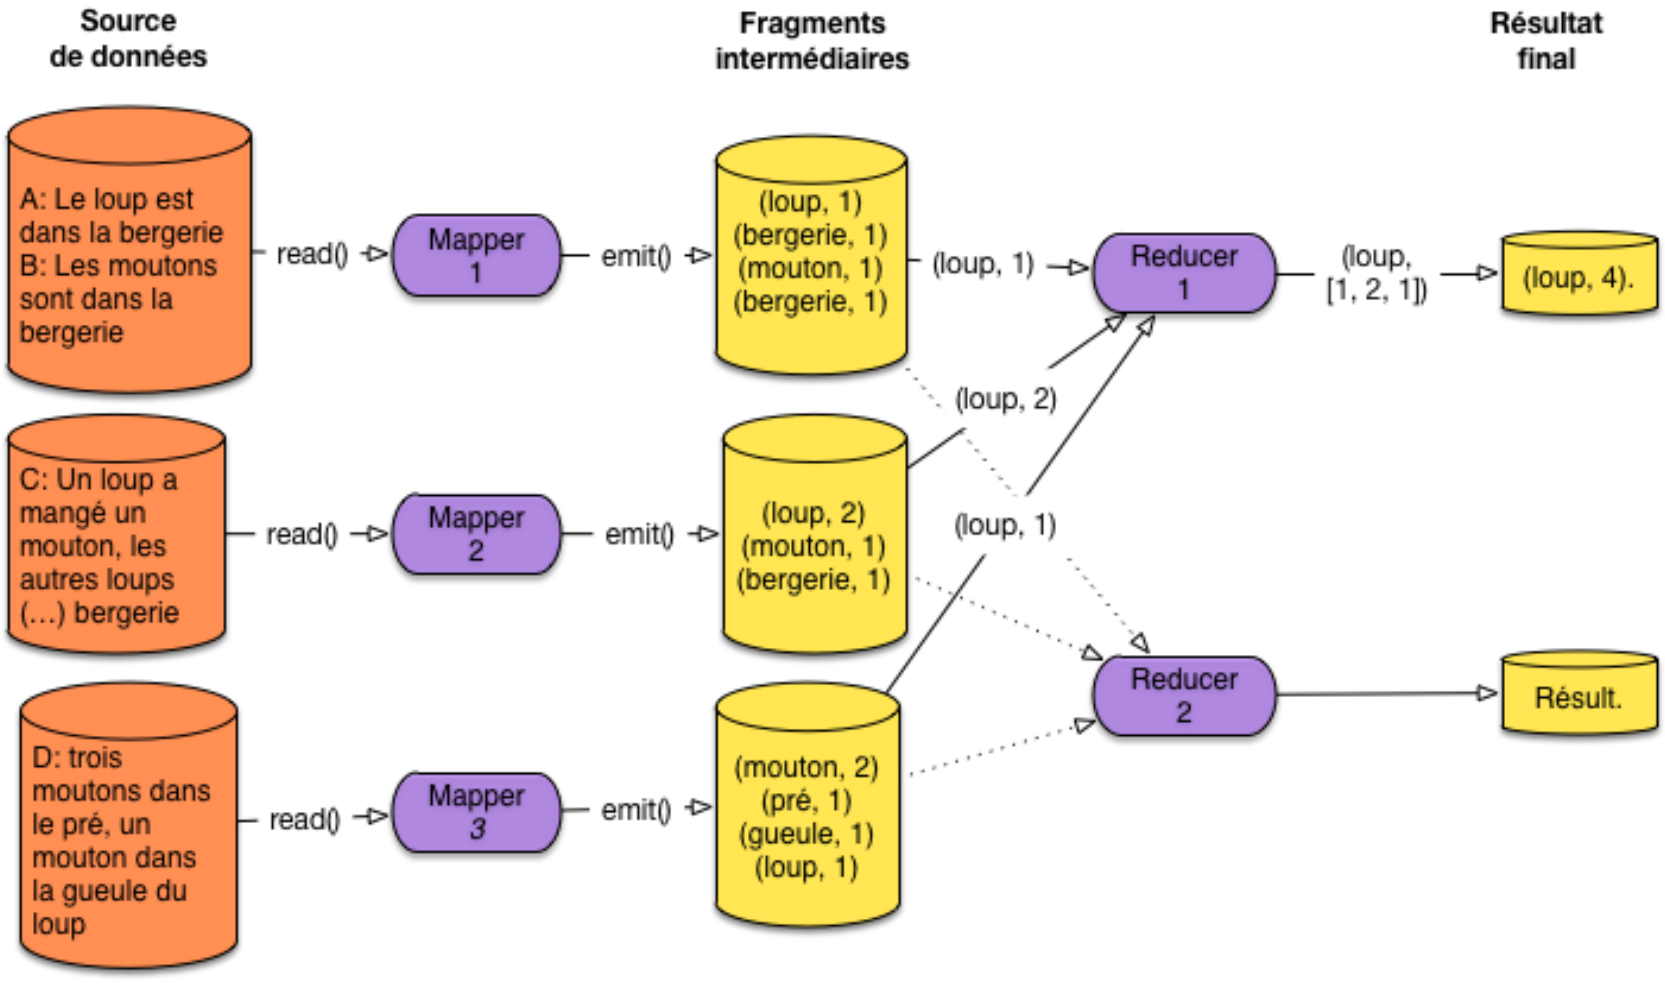

# Gestion des pannes

Un traitement MapReduce peut durer des jours, sur des centaines de machines : la probabilité de panne est très grande.

Ré-exécuter le traitement complètement en cas de panne ⇒ on est à peu près sûr de ne jamais terminer.

Dans Hadoop, le Maître (*JobTracker*) surveille l'ensemble du processus (tâches de Map, tâches de Reduce).

1. Panne d'un Reducer : on peut reprendre à partir du résultat des Mappers, **stocké sur disque**.
2. Panne d'un Mapper : on recommence la tâche sur le même fragment (**ou sur un réplica**)
3. Si le Maître tombe en panne : on recommence tout, mais la probablité est très faible.

**Essentiel**

Tout repose sur une **sérialisation** (écriture sur disque) aux différentes étapes. **Robuste mais très lent**.