DATUM ACADEMY

Hadoop, Spark & Map/Reduce

Benjamin Renaut
Mis à jour par Sergio Simonian

Plan

Module 1 :

- Big Data et le calcul distribué
- Le paradigme Map/Reduce
- Introduction à Hadoop

Module 2 :

- Programmation Hadoop

Module 3 :

- Spark
- Écosystème autour d'Hadoop

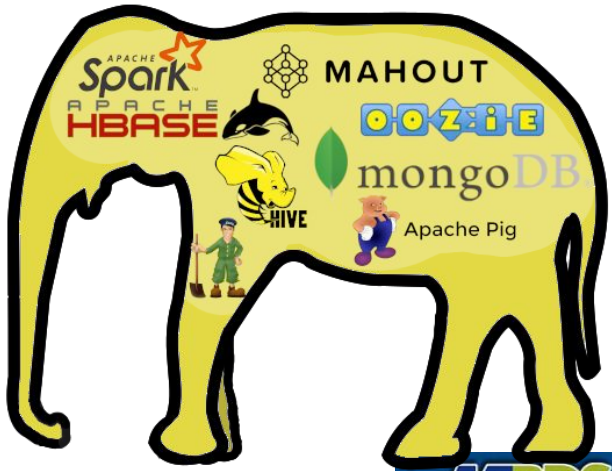

DATUM ACADEMY

Programmation Hadoop avancé

Propriétés de configuration, Compteurs,
Classe InputFormat, Classe OutputFormat, Interface Writable

Passage d'informations à un Mapper/Reducer

- Reprenons l'exemple de comptage des mots : nous voulons y ajouter une nouvelle fonctionnalité optionnelle - mettre les mots en majuscules.
- Dans ce cas une manière de procéder serait :
  - Créer 2 classes "Mapper" - une pour les lettres minuscules et une pour les majuscules.

Passage d'informations à un Mapper/Reducer

Solution : 2 classes "Mapper" - dans le main de la classe driver :

```
String[] ourArgs = new GenericOptionsParser(conf, args).getRemainingArgs();
Job job = Job.getInstance(conf, "WordCount v1.0");
// ...
if(ourArgs[0].equals("--uppercase"))
      job.setMapperClass(WordCountMapUpperCase.class);
else
      job.setMapperClass(WordCountMap.class);
// ...
FileInputFormat.addInputPath(job, new Path(ourArgs[1]));
FileOutputFormat.setOutputPath(job, new Path(ourArgs[2]));
```

Passage d'informations à un Mapper/Reducer

Solution : 2 classes "Mapper" :

- ➔ Pas idéal : la plupart du code du Mapper est répété.
- ➔ Très limité : que faire si le paramètre optionnel n'est pas booléen ?

Solution : "propriétés de configuration" :

- ➔ Les propriétés de configuration nous permettent de définir des valeurs dans la classe Driver et de les récupérer dans les classes Mapper/Reducer.
- ➔ Ainsi notre classe Mapper serait consciente si nous voulions mettre les mots en majuscule ou pas.

Passage d'informations à un Mapper/Reducer

➔ **Pour définir une valeur :**

```
conf.setInt("org.ebihar.hadoop.wordcount.uppercase", 1);
```

➔ Il y a de nombreux fonctions pour définir d'autres types de données :
- setLong, setFloat, etc. et set pour le type String.

➔ **Pour récupérer une valeur :** L'objet de configuration est récupéré avec l'objet **Context** dans les fonctions map/reduce.

```
Configuration conf = context.getConfiguration();
conf.getInt("org.ebihar.hadoop.wordcount.uppercase", 0)
```

➔ Il y a de nombreuses autres fonctions: getInt, getLong, etc. et get pour le type String.

➔ Le second argument spécifie **une valeur par défaut** si la propriété n'est pas trouvée.

Passage d'informations à un Mapper/Reducer

Solution : propriétés de configuration - dans le main de la classe driver :

```
String[] ourArgs = new GenericOptionsParser(conf, args).getRemainingArgs();
Job job = Job.getInstance(conf, "WordCount v1.0");
// ...
int uppercase = 0;
if(ourArgs[0].equals("--uppercase"))
      uppercase = 1;
conf.setInt("org.embds.hadoop.wordcount.uppercase", uppercase);
// ...
FileInputFormat.addInputPath(job, new Path(ourArgs[1]));
FileOutputFormat.setOutputPath(job, new Path(ourArgs[2]));
```

Passage d'informations à un Mapper/Reducer

Solution : propriétés de configuration - dans la classe Mapper :

```
protected void map(Object offset, Text value, Context context)
throws IOException, InterruptedException {
        StringTokenizer tok;
        Configuration conf = context.getConfiguration();
        int uppercase = conf.getInt("org.embds.hadoop.wordcount.uppercase", 0);
        if(uppercase != 0)
                tok = new StringTokenizer(value.toString().toUpperCase(), " ");
        else
                tok = new StringTokenizer(value.toString(), " ");
        while(tok.hasMoreTokens()) {
                Text word = new Text(tok.nextToken());
                context.write(word, new IntWritable(1));
        }
}
```

Compteurs Hadoop

- Reprenons l'exemple du parcours de graph.
- Notre **condition d'arrêt était**: l'état couleur de tous les nœuds est **NOIRE**.
- Une façon d'implémenter cette condition serait :
  - Après chaque exécution - Effectuer une recherche dans l'ensemble des données de sortie pour les nœuds qui ne sont pas de couleur noire.

Compteurs Hadoop

Exemple:

```
private static Boolean conditionDArret(Configuration conf, String output_path) {
   FileSystem fs = FileSystem.get(conf);
   FileStatus[] list = fs.globStatus(new Path(output_path));
   for(int i = 0; i < list.length; ++i) {
      BufferedReader br = new BufferedReader(new
InputStreamReader(fs.open(list[i].getPath())));
      String line = br.readLine();
      while(line != null) {
         if(!line.contains("NOIR")) {
            br.close();
            return(false);
         }
         line=br.readLine();
      }
      br.close();
   }
   return(true);
}
```

Compteurs Hadoop

Cette solution est problématique :

- ➔ Le graphe pourrait contenir des millions de nœuds.
- ➔ Notre programme lit la sortie 2 fois. (Dans **reduce** et **conditionDArret**)

Une meilleure solution serait :

- ➔ Vérifier la condition d'arrêt pendant l'exécution de **reduce**.
- ➔ Transmettre cette information au Driver.
  Pour cela les compteurs Hadoop nous seront utiles.

Compteurs Hadoop

Un compteur Hadoop :

- Contient une valeur numérique : de type Long.
- Ne peut être qu'incrémenté.
- Dans Mapper/Reducer : peut être lu et incrémenté.
- Dans Driver : peut être lu.

Cas d'utilisation :

- Communication entre Driver et les Mappers/Reducers.
- Collecter des statistiques sur un Job en cours.
- Détection des problèmes (Par exemple : compter le nombre d’erreurs)

Compteurs Hadoop

- Pour créer un compteur, déclarez une énumération. (par exemple dans le Driver) :

```
public enum GRAPH_COUNTERS {
      NB_NODES_UNFINISHED // Amount of non-black nodes after one execution cycle
};
```

- Le compteur peut ensuite être récupéré soit à partir de l'objet Job (dans le Driver) ou Contexte (dans Mapper/Reducer):

```
Counters cn = job.getCounters();
Counter cnt = cn.findCounter(GRAPH_COUNTERS.NB_NODES_UNFINISHED);
```

```
Counter cnt = context.getCounter(GRAPH_COUNTERS.NB_NODES_UNFINISHED);
```

Compteurs Hadoop

- Pour **lire** la valeur d'un compteur (Dans Driver/Mapper/Reducer) :

```
Counter cnt;
// …
Long value = cnt.getValue();
```

- Pour l'**incrémenter** (uniquement dans Mapper/Reducer) :

```
Counter cnt;
// …
cnt.increment(1);
```

- Note: Peut également être incrémenté de plus de 1.

Compteurs Hadoop

→ Notre fonction de condition d'arrêt dans Driver devient :

```
private static Boolean conditionDArret(Job previous_job) {
        Counters cn = previous_job.getCounters();
        Counter cnt = cn.findCounter(GRAPH_COUNTERS.NB_NODES_UNFINISHED);
        // Si le compteur n'a jamais été incrémenté : nous n'avons pas rencontré
        // un nœud qui n'était pas de couleur noire dans les Reducers
        // de l'exécution du Job spécifié.
        return(cnt.getValue() == 0);
}
```

Compteurs Hadoop

- Et à la fin de notre Reducer, ajoutons quelque chose comme :

```
if(!new_node_color.equals("NOIR"))
        context.getCounter(Graph.GRAPH_COUNTERS.NB_NODES_UNFINISHED).increment(1);
```

- Ainsi le Reducer communique la condition d'arrêt au Driver et nous évitons la relecture de la sortie.

Compteurs Hadoop

Hadoop possède également des compteurs internes; la plupart d'entre eux se trouvent dans TaskCounter et JobCounter (package org.apache.hadoop.mapreduce).

Quelques exemples :

- **TOTAL_LAUNCHED_MAPS** : Le nombre de tâches MAP qui ont été lancées. Inclut les tâches qui ont été lancées de manière spéculative.
- **TOTAL_LAUNCHED_REDUCES** : Le nombre de tâches REDUCE qui ont été lancées. Inclut les tâches qui ont été lancées de manière spéculative.
- **NUM_FAILED_MAPS** : Le nombre de tâches MAP qui ont échoué.
- **NUM_FAILED_REDUCES** : Le nombre de tâches REDUCE qui ont échoué.
- **REDUCE_INPUT_GROUPS** : Le nombre de groupes clef-valeur distincts envoyés aux Reducers.

Classe InputFormat

- Jusqu'à présent : l'entrée était toujours un fichier texte sur HDFS, divisé par ligne.
- Produit des couples clef/valeur : la clef passée au Mapper est **le numéro de ligne**, la valeur est la **ligne elle-même**.
- Comportement par défaut d'Hadoop - **peut être modifié**.
- La lecture, la division et l'interprétation des données d'entrée sont gérées par une classe appelée **InputFormat**.

Classe InputFormat

La classe **InputFormat** influence :

- ➔ La **récupération** des données sources : HDFS, bases de données, etc.
- ➔ La **division** des données d'entrée par la classe **InputSplit**.
- ➔ La **lecture** des données d'entrée par la classe **RecordReader**.
- ➔ Les **types** de couples clef/valeur passées au **Mapper** (à partir des données d'entrée lues).

Classe InputFormat

- Hadoop fournit plusieurs classes **InputFormat**.
- Pour utiliser une classe **InputFormat** différente au lieu de celle par défaut :

```
job.setInputFormatClass(class);
```

- La classe utilisé par **défaut** est :

```
job.setInputFormatClass(TextInputFormat.class);
```

- Le comportement peut souvent être influencé (par l'objet de configuration ou des méthodes statiques).

Classe InputFormat - Exemples

KeyValueTextInputFormat :

- Découpe le ou les fichiers d'entrée par ligne.
- S'attend à trouver des couples (clef; valeur) au sein de chacune des lignes.
- Le séparateur par défaut pour la clé et la valeur est le caractère de tabulation.
- Exemple :

```
1	2,5|GRIS|0
2	3|BLANC|-1
```

- Le caractère utilisé pour la séparation peut être modifié ainsi :

```
conf.set("mapreduce.input.keyvaluelinerecordreader.key.value.separator", ";")
```

Classe InputFormat - Exemples

FixedLengthInputFormat :

- Découpe le ou les fichiers d'entrée selon une taille fixe indiquée.
- La **clef** est le numéro du fragment, la **valeur** est le fragment lui-même.
- Particulièrement adapté pour des données binaires où une série de « blocs » de taille égale se suivent.
- Exemple : lire le code RNA par codon (trois caractères).

```
GCUACGGAGCUUCGGAGCUAGGCUACGGAGCUUCGGAGCUAG
```

- La taille du bloc peut être réglée par les paramètres suivants :

```
conf.setInt(FixedLengthInputFormat.FIXED_RECORD_LENGTH, 3);
```

```
FixedLengthInputFormat.setRecordLength(conf, 3);
```

Classe InputFormat - Exemples

NLineInputFormat :

- Découpe le ou les fichiers d'entrée par groupes de N lignes.
- La clef est le numéro du bloc de N lignes.
- La valeur est le contenu des lignes.
- Exemple : lire par groupes de deux lignes.

```
Il s'agit d'une
phrase de deux lignes
Et voici
une autre
```

- Le nombre N des lignes peut être réglée par les paramètres suivants :

```
conf.setInt("mapreduce.input.lineinputformat.linespermap", 2);
```

```
NLineInputFormat.setNumLinesPerSplit(job, 2);
```

Classe InputFormat - Exemples

Sequence Files :

- ➔ Format de Apache destiné à stocker des couples clé-valeur.
- ➔ Supporte le **format binaire**.
- ➔ Supporte la **compression**.
- ➔ Plus efficace ; évite les problèmes de surcharge avec de nombreux petits fichiers.
- ➔ Souvent utilisé avec Hadoop et les frameworks big data en général.

Classe InputFormat - Exemples

SequenceFileInputFormat :

- Lit les fichiers de type “Sequence File”.
- Les clés et les valeurs sont extraites du fichier de séquence; leurs types de données varient en fonction du fichier.
- Souvent utilisé en production, bien que le format textuel soit également courant.
- Les fichiers de séquence sont couramment créés avec les programmes Hadoop; souvent par le biais d'une opération map uniquement : pas de shuffle, pas de reduce, les tuples produit par map sont écrits directement en sortie. Peut être accompli avec :

```
job.setNumReduceTasks(0);
```

Classe InputFormat

- De nombreuses autres classes **InputFormat** sont disponibles.
- Ils ne sont pas tous basés sur des fichiers HDFS; par exemple : **MongoInputFormat** avec le **connecteur MongoDB**.
- Pour des cas d'utilisation particuliers, il est possible de créer son propre InputFormat.

Créer son propre InputFormat

Pour créer **son propre InputFormat** :

- ➔ La nouvelle classe doit hériter d'un InputFormat existant : **FileInputFormat**, **DBInputFormat**, **CompositeInputFormat** …
- ➔ Créer une classe héritant de **RecordReader**.
- ➔ (Ré)Implémenter les méthodes pertinentes dans les deux.

Créer son propre InputFormat - Exemple

Exemple :

- Un InputFormat pour lire les données de notre exemple "amis communs" comme couples clef/valeur appropriés dès le départ.
- Pour rappel, les données d'entrée sont :

```
A => B, C, D
B => A, C, D, E
C => A, B, D, E
D => A, B, C, E
E => B, C, D
```

Créer son propre InputFormat - Exemple

Objets Hadoop principaux pour travailler avec des données d'entrée provenant de fichiers :

- ➔ **InputSplit** est un bloc qui contient des données; il est renvoyé par la méthode getSplits() de l'InputFormat. Pour le format FileInputFormat, par défaut: InputSplit ~= un block sur HDFS.
- ➔ **RecordReader** lit InputSplit ; génère des tuples à partir de lui.
- ➔ **InputFormat** encapsule et crée les deux.

Créer son propre InputFormat - Exemple

→ Notre propre classe **InputFormat** pour l'exemple “amis communs” :

```
public class FriendsInputFormat extends FileInputFormat<Text, Text> {
   public RecordReader<Text, Text> createRecordReader(InputSplit split, TaskAttemptContext
context)
   throws IOException, InterruptedException {
      return new FriendsRecordReader();
   }
}
```

Créer son propre InputFormat - Exemple

→ Notre propre classe **RecordReader** pour l'exemple “amis communs” : (1/3)

```
public class FriendsRecordReader extends RecordReader<Text, Text> {
   private LineRecordReader lineRecordReader = null;
   private Text key = null;
   private Text value = null;

   public void initialize(InputSplit split, TaskAttemptContext context)
   throws IOException, InterruptedException {
      close();
      lineRecordReader = new LineRecordReader();
      lineRecordReader.initialize(split, context);
   }
```

Créer son propre InputFormat - Exemple

→ Notre propre classe **RecordReader** pour l'exemple “amis communs” : (2/3)

```
public boolean nextKeyValue() throws IOException, InterruptedException {
   if(!lineRecordReader.nextKeyValue()) {
      key = null;
      value = null;
      return false;
   }
   Text line = lineRecordReader.getCurrentValue();
   String str = line.toString();
   String[] arr = str.split("=>");
   key = new Text(arr[0].trim());
   value = new Text(arr[1].trim());
   return true;
}
public Text getCurrentKey() throws IOException, InterruptedException {
   return key;
}
```

Créer son propre InputFormat - Exemple

→ Notre propre classe **RecordReader** pour l'exemple “amis communs” : (3/3)

```
    public Text getCurrentValue() throws IOException, InterruptedException {
        return value;
    }
    public float getProgress() throws IOException, InterruptedException {
        return lineRecordReader.getProgress();
    }
    public void close() throws IOException {
        if(lineRecordReader != null) {
            lineRecordReader.close();
            lineRecordReader = null;
        }
        value = null;
    }
}
```

Créer son propre InputFormat - Exemple

Remarques :

- ➔ Nous avons accès à la configuration par le biais du contexte ; nous pouvons permettre à l'utilisateur final d'ajuster le comportement de notre **InputFormat** en utilisant des variables de configuration.
- ➔ Nous utilisons **LineRecordReader** : le **RecordReader** du **InputFormat** par défaut - **TextInputFormat**.
- ➔ C'est l'une des approches les plus courantes ; elle nous permet de lire facilement par ligne. Alternativement : il faut mettre en œuvre la lecture de l'**InputSplit** manuellement, par exemple avec l'**API HDFS**.

Créer son propre InputFormat - Exemple

→ Un exemple d'initialisation pour la gestion manuelle d'**InputSplit** :

```
public void initialize(InputSplit isplit, TaskAttemptContext ctx) throws IOException {
        FileSplit split = (FileSplit) isplit;
        Configuration conf = context.getConfiguration();
        start = split.getStart();
        end = start + split.getLength();
        Path file = split.getPath();
        FileSystem fs = file.getFileSystem(job);
        fileIn = fs.open(file);
        fileIn.seek(start);
}
```

Créer son propre InputFormat - Exemple

→ Dans la même classe, pour lire une ligne et une clef/valeur, nous ferions par exemple :

```
public boolean nextKeyValue() throws IOException {
   // ...
   Text line = new Text();
   size = fileIn.readLine(line, MAX_LENGTH);
   String[] arr = line.toString().split("=>");
   key = new Text(arr[0].trim());
   value = new Text(arr[1].trim());
   // ...
}
```

Créer son propre InputFormat - Exemple

Et concernant les **(input) splits** :

- ➔ Le comportement peut être modifié en surchargeant **getSplits()** dans **InputFormat**.
- ➔ Renvoie une liste d'objets **InputSplit**.
- ➔ Rarement nécessaire pour les formats d'entrée de fichiers (le comportement par défaut convient généralement).

Classe OutputFormat

- Équivalent de la classe InputFormat, mais pour les données de sortie.
- Comportement par défaut : un tuple de sortie par ligne, clef puis tabulation puis valeur.
- Peut être modifié de la même manière que le format d'entrée :

```
job.setOutputFormatClass(class);
```

- Par exemple (classe de format de sortie par défaut) :

```
job.setOutputFormatClass(TextOutputFormat.class);
```

Classe OutputFormat

Il existe une multitude de classes standard **OutputFormat** fournis par Hadoop :

- ➔ **SequenceFileOutputFormat** : écrit des fichiers de séquences.
- ➔ **MultipleOutputFormat** : écrit les couples clef/valeur de sortie dans différents emplacements sur HDFS en fonction des clés ou des valeurs des tuples.
- ➔ Il y en a d'autres, leur comportement peut également être modifié par le biais des paramètres de configuration.

Classe OutputFormat

- Par exemple, pour ajuster le séparateur dans la classe **TextOutputFormat** par défaut (pour utiliser le point-virgule au lieu de la tabulation) :

```
conf.set("mapreduce.output.textoutputformat.separator",
";");
```

- Comme pour l'**InputFormat**, pour des besoins plus complexes, nous pouvons créer notre propre **OutputFormat**.
- Approche très similaire : il suffit de créer les classes **OutputFormat** et **RecordWriter**.

Créer son propre OutputFormat

L'**OutputFormat** doit principalement :

- → Ouvrir un fichier de sortie sur HDFS pour les résultats d'une opération Reduce.
- → Instancier et retourner un objet RecordWriter.

Le **RecordWriter** écrit des couples clef/valeur dans le fichier de sortie.

Créer son propre OutputFormat - Exemple

Exemple :

→ Nous voulons maintenant créer notre **propre OutputFormat** pour notre exemple "amis communs".

→ Nous voulons que les données finales soient écrites comme suit :

A-B => C, D
A-C => B, D
A-D => B, C
B-C => A, D, E
B-D => A, C, E
...

Créer son propre OutputFormat - Exemple

→ Notre classe **OutputFormat** :

```
public class FriendsOutputFormat extends FileOutputFormat<Text, Text> {
   public RecordWriter<Text, Text> getRecordWriter(TaskAttemptContext context)
   throws IOException, InterruptedException {
      Path path = getDefaultWorkFile(context, "");
      FileSystem fs = path.getFileSystem(context.getConfiguration());
      FSDataOutputStream fileOut = fs.create(path, context);
      return(new FriendsRecordWriter(fileOut));
   }
}
```

Créer son propre OutputFormat - Exemple

→ Notre classe **RecordWriter** :

```
public class FriendsRecordWriter extends RecordWriter<Text, Text> {
	private DataOutputStream out;

	public FriendsRecordWriter(DataOutputStream stream) {
		out = stream;
	}
	public void write(Text k, Text val) throws IOException, InterruptedException {
		out.writeBytes(k.toString() + " => " + val.toString() + "\n");
	}
	public void close(TaskAttemptContext ctx) throws IOException,
	InterruptedException {
		out.close();
	}
}
```

Créer son propre OutputFormat - Exemple

→ Nous pouvons aussi, bien sûr, **modifier le nom du fichier de sortie** :

```
public class FriendsOutputFormat extends FileOutputFormat<Text, Text> {
   public RecordWriter<Text, Text> getRecordWriter(TaskAttemptContext context)
   throws IOException, InterruptedException {
      Path path = FileOutputFormat.getOutputPath(context);
      Path fullPath = new Path(
            path, FileOutputFormat.getUniqueFile(context, "RESULTS", ".txt")
      );
      FileSystem fs = path.getFileSystem(context.getConfiguration());
      FSDataOutputStream fileOut = fs.create(fullPath, context);
      return(new FriendsRecordWriter(fileOut));
   }
}
```

Créer son propre OutputFormat - Exemple

- Avant notre changement de nom, le répertoire de sortie sur HDFS ressemblait à ceci :

```
/out/_SUCCESS
/out/part-r-00000
/out/part-r-00001
/out/part-r-00002
...
```

- Après :

```
/out/_SUCCESS
/out/RESULTS-r-00000.txt
/out/RESULTS-r-00001.txt
/out/RESULTS-r-00002.txt
...
```

Les types Writable

- Jusqu'ici, on a utilisé des types « simples » pour les clefs et valeurs dans les exemples : Text ou encore IntWritable.
- Hadoop permet également de définir ses **propres types Writable**, pour la **clef** et la **valeur**.
- Si nous souhaitons utiliser nos propres types comme entrée initiale ou comme sortie finale du programme, il est nécessaire d'implémenter un **InputFormat** ou, respectivement, un **OutputFormat** dédié.

Les types Writable

Deux options :

- ➔ Si notre type serait utilisé **uniquement comme valeur** des tuples => implémenter l'interface **Writable**.
- ➔ Si notre type serait utilisé comme **clef et valeur** des tuples => implémenter l'interface **WritableComparable**.

Dans les deux cas, la sérialisation et la désérialisation doivent être gérées par la classe spécifique.

Les types Writable - Exemple

Exemple :

- ➔ On souhaite créer un type **Writable** pour stocker nos valeurs dans l'exemple « amis en commun ».
- ➔ La classe s'appellera « FriendsListWritable » et stockera la liste des amis liés à un utilisateur du réseau.

Les types Writable - Exemple

→ Exemple d'un type Writable spécifique (1/2) :

```
public class FriendsListWritable implements Writable {
   public ArrayList<String> friends;

   public void write(DataOutput out) throws IOException {
      Text line = new Text(get_serialized());
      line.write(out);
   }
   public FriendsListWritable(String datatxt) {
      unserialize(datatxt);
   }
   public void unserialize(String datatxt) {
      String[] data = datatxt.split(",");
      friends = new ArrayList<String>(Arrays.asList(data));
   }
```

Les types Writable - Exemple

➔ Exemple d'un type Writable spécifique (2/2) :

```
    public FriendsListWritable() { }

    public String get_serialized() {
        String line = String.join(",", friends);
        return(line);
    }
    public void readFields(DataInput in) throws IOException {
        Text line = new Text();
        line.readFields(in);
        unserialize(line.toString());
    }
}
```

Les types Writable - Exemple

→ Pour utiliser notre type comme valeur de sortie, spécifions le **dans le Driver** :

```
job.setInputFormatClass(FriendsInputFormat.class);
job.setOutputFormatClass(FriendsOutputFormat.class);
job.setOutputValueClass(FriendsListWritable.class);
```

→ Et **dans le Mapper / Reducer** :

```
public class FriendsMap extends Mapper<Text, FriendsListWritable, Text, FriendsListWritable>
```

```
public class FriendsReduce extends Reducer<Text, FriendsListWritable, Text,
FriendsListWritable>
```

Les types Writable - Exemple

→ Notre **InputFormat** doit également être mis à jour :

```
public class FriendsInputFormat extends FileInputFormat<Text, FriendsListWritable> {
```

→ Le **RecordReader** aussi :

```
public boolean nextKeyValue() throws IOException, InterruptedException {
        // ...
        String[] arr = str.split("=>");
        key = new Text(arr[0].trim());
        value = new FriendsListWritable(arr[1].trim()));
        // ...
}
```

Les types Writable - Exemple

- Pour utiliser le nouveau type Writable comme **clef** également, implémentez **WritableComparable**.
- Deux méthodes supplémentaires à implémenter :
  - **compareTo()** :
    similaire à la fonction de comparaison habituelle de Java ; compare deux instances.
  - **hashCode()** :
    doit renvoyer une valeur dont la similitude est garantie pour deux objets identiques - même à travers des JVM et différentes exécutions.

Les types Writable - Example

- Le code de hachage est utilisé pendant l'étape **shuffle**, pour produire les partitions qui sont passées à l'étape **reduce**.
- Deux hashcodes identiques permettent au **shuffle** de regrouper des objets identiques (clefs identiques).
- Les objets Java disposent d'une fonction hashcode() ; cependant, d'après la doc Java :
  Cet hashcode n'a pas besoin de rester cohérent d'une exécution d'une application à une autre exécution de la même application.

Les types Writable - Example

- Comme nous exécutons notre programme sur plusieurs machines, la fonction hashcode() sera appelée sur des objets identiques mais sur des machines différentes.
- Par conséquent, bien qu'elles soient égales, les clefs ne seront peut-être pas regroupées.
- **Solution** : générer nous-mêmes un hashcode, qui soit **basé sur les données de l'objet**. De plus, le hashcode doit être **distribué uniformément**.
- Les types **Writable** Hadoop standard (Text, etc.) offrent déjà une telle fonction de hashcode.

Les types Writable - Example

→ Pour revenir à notre exemple, nous pourrions faire :

```
public class FriendsListWritable implements
WritableComparable<FriendsListWritable> {
// ...
```

→ Et :

```
    public int hashCode() {
        return(new Text(get_serialized()).hashCode());
    }
    public int compareTo(FriendsListWritable o) {
        int mysize = friends.size();
        int theirsize = o.friends.size();
        return (mysize < theirsize ? -1 : (mysize == theirsize ? 0 : 1));
    }
// ...
```