



Aproximación práctica a la ciencia de los datos y  
Big Data

Mahout práctico

José Manuel Benítez Sánchez

# Contenido

- Instalación de Mahout
- Ejemplos «in-memory»:
  - Ejemplo de clustering
  - Ejemplo de clasificación
- Ejemplos con MapReduce:
  - Ejemplo de clustering
  - Ejemplo de clasificación
- Clasificadores para «poker»

# Instalación

- Verificar las dependencias:
  - Maven
  - Java
- Conectarse a <http://apache.rediris.es/mahout> y descargar la última versión
- Instalarla en local
- Configurar las variables de entorno

# Acceso a la cuenta remota

- Acceder a la cuenta asignada en atlas.ugr.es
- Crear un directorio personal en HDFS
- Configurar variables de entorno:
  - JAVA\_HOME
  - MAHOUT\_HOME
  - HADOOP\_HOME

# Ejemplo de clustering

```
cd $MAHOUT_HOME
```

```
./examples/bin/cluster-reuters.sh
```

Comparar los resultados con distintos algoritmos y parámetros

# Clasificación: puntos con relleno

- Resolver el problema de detección de puntos con relleno
  
- Datos: `usr/share/doc/mahout-doc-0.7+16/examples/src/main/resources/`
  
- (Mantados de procesamiento en material sobre Mahout)
  - Preparación de datos
  - Construcción del clasificador
  - Evaluación del clasificador
  - Mejoras

# Construyendo el clasificador

```
mahout trainlogistic --input donut.csv --output  
./model --target color --categories 2 --  
predictors x y --types numeric --features 20 --  
passes 100 --rate 50
```

# Clasificación: 20 newsgroups

```
cd $MAHOUT_HOME
```

```
./examples/bin/classify-20newsgroups.sh
```

Evaluar el rendimiento de distintos algoritmos.

Después, realizar la ejecución de las distintas etapas, paso a paso



# Ejecución detallada

1. Crear directorio de trabajo
2. Decargar y desempaquetar datos
3. Convertir los datos en SequenceFiles
4. Preprocesar los datos para incluir frecuencias de términos
5. Dividir el conjunto de datos en: entrenamiento y prueba
6. Entrenar el clasificador
7. Evaluar el clasificador

# 1. Crear un directorio de trabajo

```
export WORK_DIR=/tmp/mahout-work-`${USER}`  
mkdir -p `${WORK_DIR}`
```

## 2. Descargar y desempaquetar datos

```
curl
http://people.csail.mit.edu/jrennie/20Newsgroups/20news-bydate.tar.gz -o ${WORK_DIR}/20news-bydate.tar.gz
```

```
mkdir -p ${WORK_DIR}/20news-bydate
```

```
cd ${WORK_DIR}/20news-bydate && tar xzf ../20news-bydate.tar.gz && cd .. && cd ..
```

```
mkdir ${WORK_DIR}/20news-all
```

```
cp -R ${WORK_DIR}/20news-bydate/*/*
${WORK_DIR}/20news-all
```

## 2.b Si se usa Hadoop

```
hadoop dfs -put ${WORK_DIR}/20news-all  
${WORK_DIR}/20news-all
```

### 3. Convertir los datos en SequenceFile

```
mahout seqdirectory
```

```
-i ${WORK_DIR}/20news-all
```

```
-o ${WORK_DIR}/20news-seq
```

```
-OW
```

## 4. Preprocesar los datos: frecuencias de términos

```
mahout seq2sparse
```

```
-i ${WORK_DIR}/20news-seq
```

```
-o ${WORK_DIR}/20news-vectors
```

```
-lnorm
```

```
-nv
```

```
-wt tfidf
```

## 5. Dividir el conjunto de datos

```
mahout split
```

```
-i ${WORK_DIR}/20news-vectors/tfidf-vectors  
--trainingOutput ${WORK_DIR}/20news-train-vectors  
--testOutput ${WORK_DIR}/20news-test-vectors  
--randomSelectionPct 40  
--overwrite --sequenceFiles -xm sequential
```

## 6. Entrenar el clasificador

```
mahout trainnb
```

```
-i ${WORK_DIR}/20news-train-vectors
```

```
-el
```

```
-o ${WORK_DIR}/model
```

```
-li ${WORK_DIR}/labelindex
```

```
-ow
```

```
-c
```



## 7. Evaluar el clasificador

```
mahout testnb
```

```
-i ${WORK_DIR}/20news-test-vectors
```

```
-m ${WORK_DIR}/model
```

```
-l ${WORK_DIR}/labelindex
```

```
-OW
```

```
-o ${WORK_DIR}/20news-testing
```

```
-C
```

# Clasificación: poker

Diseñar y crear un clasificador para el problema de “poker”.

Evaluar rendimiento y tiempos de respuesta con distintos algoritmos y parámetros.

Datos: `/home/curso/poker`