UNED

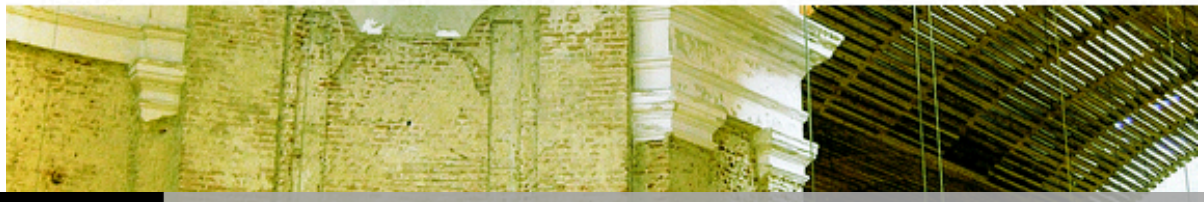

GRADO

INTRODUCCIÓN AL MANEJO DE DATOS MASIVOS CON HADOOP

PRÁCTICA DE LA ASIGNATURA SISTEMAS DE BASES DE DATOS

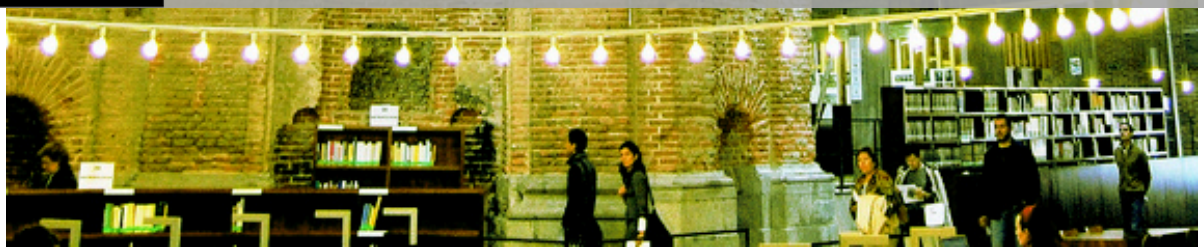

2015-2016

Versión 1.0

Dr. Agustín C. Caminero Herráez — Dr. Luis Grau Fernández

GRADO EN INGENIERÍA INFORMÁTICA

CONTENIDO

1 ¿Qué son los datos masivos o *Big Data*?

Los datos masivos, también conocidos como *Big Data*, son datos que cumplen entre otras las siguientes condiciones (conocidas como las 3 Vs):

- Tienen gran **volumen**. Estamos hablando de terabytes o petabytes de información, al menos.
- Tienen gran **velocidad**. Son datos que varían muy rápidamente, lo que hace que su tiempo de vida sea muy limitado. Esto impone severas restricciones temporales a su almacenamiento y procesamiento, ya que si no se utilizan las técnicas apropiadas, estos datos no se podrán aprovechar convenientemente.
- Tienen una gran **variedad**. No están limitados a texto, sino que incluyen cualquier tipo de dato, como por ejemplo vídeo, audio, imágenes.

Estas condiciones hacen que los sistemas de almacenamiento y procesamiento de datos tradicionales (como por ejemplo las bases de datos relacionales tradicionales) no sean los más indicados para trabajar con Big Data – esto se verá en mayor detalle más adelante en este documento. Por eso, se han desarrollado tecnologías que permiten el trabajo con datos de estas características, una de las más ampliamente utilizadas es Hadoop.

El Big Data se puede aprovechar en una gran cantidad de campos. Por ejemplo, en temas médicos (expedientes médicos, resultados de pruebas, ...), negocios (compras, ventas, transacciones entre empresas, movimientos de la Bolsa, *Business Intelligence*...), redes sociales (mensajes de Twitter, Facebook, ...), o servidores de Internet (logs que recogen los accesos que reciben los servidores, ...).

En esta práctica vamos a introducir la herramienta de Big Data conocida como Hadoop. Profundizaremos en su estructura y en sus componentes principales (el sistema de archivos HDFS y el modelo de programación MapReduce), presentaremos algunos ejemplos de funcionamiento, antes de proponer una serie de ejercicios de evaluación.

2 Introducción a Hadoop

2.1 ¿Qué es Hadoop?

Hadoop es un entorno software para el almacenamiento, procesamiento y análisis de datos masivos, también conocidos como *Big Data*. Entre sus características más importantes se encuentran las siguientes:

- Hadoop es **distribuido**:
    - Se ejecuta en un *cluster* de ordenadores, un conjunto de ordenadores conectados entre ellos mediante una red de interconexión que funcionan de forma coordinada (ver Figura 1).
    - El cluster permite que el usuario del sistema no tenga que preocuparse de realizar tareas tales como decidir en qué ordenador se ejecutan los trabajos, o de iniciar sesión en la máquina adecuada.
    - El cluster ofrece una imagen única de sistema (*Single System Image*, SSI) a sus usuarios, de forma que estos no tienen que ser conscientes de las infraestructuras subyacentes.

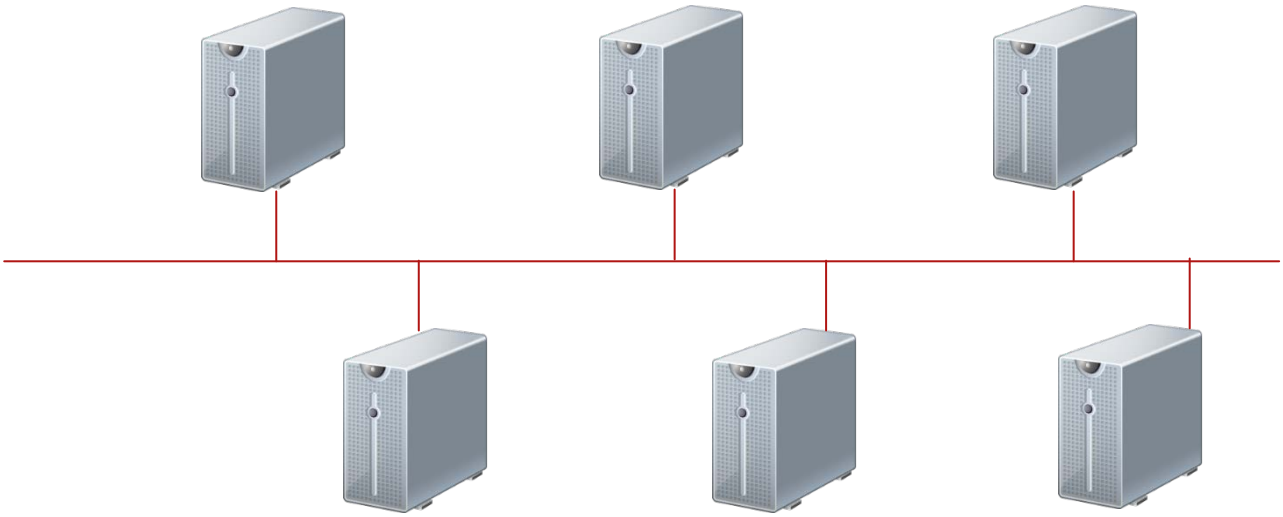

Figura 1. Cluster de ordenadores

- Hadoop es **escalable**:
    - Añadir nodos incrementa la capacidad de forma proporcional (ver Figura 2). Al contrario que otras tecnologías, que al incrementar el número de nodo implica un sobrecoste, en Hadoop el incremento de los nodos del cluster incrementa directamente la capacidad de procesamiento.

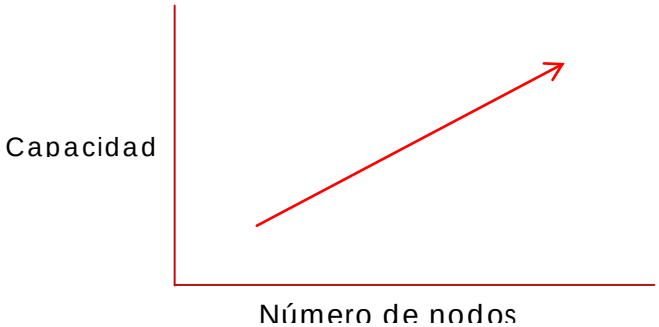

Figura 2. Escalabilidad de un sistema Hadoop

- Hadoop es **tolerante a fallos**:
    - Los fallos son normales en sistemas distribuidos. En grandes sistemas informáticos, como por ejemplo, Google, que están formados por cientos de miles de ordenadores, suceden fallos a diario.
    - El fallo de un nodo no afecta al sistema, que continúa funcionando. El sistema debe ser capaz de detectar el fallo y adaptarse a él con el fin de seguir proporcionando el servicio mientras el fallo se soluciona.
    - El maestro reasigna las tareas a otro nodo. De esta forma, el servicio sigue siendo proporcionado por las máquinas que siguen en funcionamiento.
    - No hay pérdida de datos gracias a la replicación. No solamente el servicio se debe seguir proporcionando, sino que la información almacenada debe seguir estando disponible sin pérdidas.
    - Cuando un nodo se recupera, vuelve al sistema automáticamente.

- Hadoop es **open-source**:
    - Su código fuente está disponible de forma abierta para que quien lo desee lo descargue, modifique, ...
    - Una gran cantidad de desarrollos software se publican de forma open-source (ver Figura 3), entre los más conocidos se encuentran el sistema operativo para smartphones Android, el navegador de Internet Mozilla Firefox, o el cliente de correo electrónico Mozilla Thunderbird.

Figura 3. Proyectos open-source

2.2 Necesidad de Hadoop

La creciente necesidad de datos hace que los sistemas distribuidos tradicionales no sean eficientes. El principal problema que presentan es el almacenamiento de los datos, ya que se suelen almacenar en una base de datos externa a los nodos de cómputo, tal como muestra la Figura 4.

De esta forma, cada vez que se inicia un procesamiento sobre los datos, los nodos de trabajo deben recuperar la información de la base de datos, lo cual supone un cuello de botella ya que todos los nodos implicados en esos cálculos deben recuperar los datos prácticamente al mismo tiempo y algunos nodos deberán esperar, lo cual retrasa el comienzo de los cálculos y afecta negativamente a la productividad del sistema informático.

En cambio, Hadoop proporciona una nueva gestión de los datos para eliminar ese cuello de botella, como se muestra en la Figura 5. En Hadoop, los datos se almacenan en los mismos ordenadores donde se realizarán los cálculos, de forma que se distribuyen entre ellos en el momento en que se almacenan en el sistema. Por tanto, cuando se inicia un procesamiento, los datos ya se encuentran en los nodos de trabajo, por lo que pueden empezar a trabajar sin demora. Debido a esto, la productividad del sistema informático mejora considerablemente.

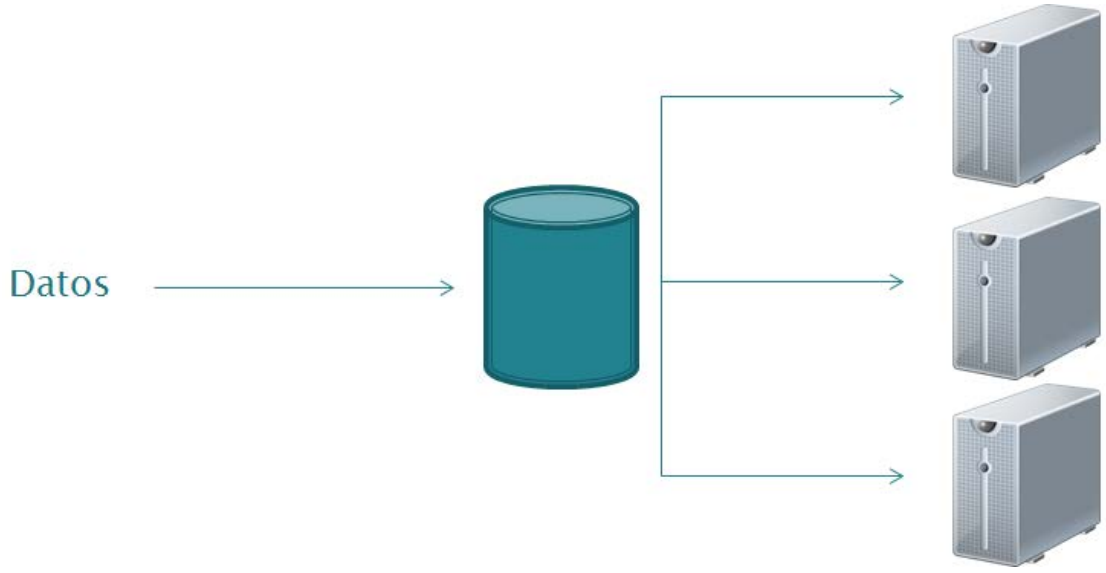

Figura 4. Arquitectura tradicional de un sistema distribuido

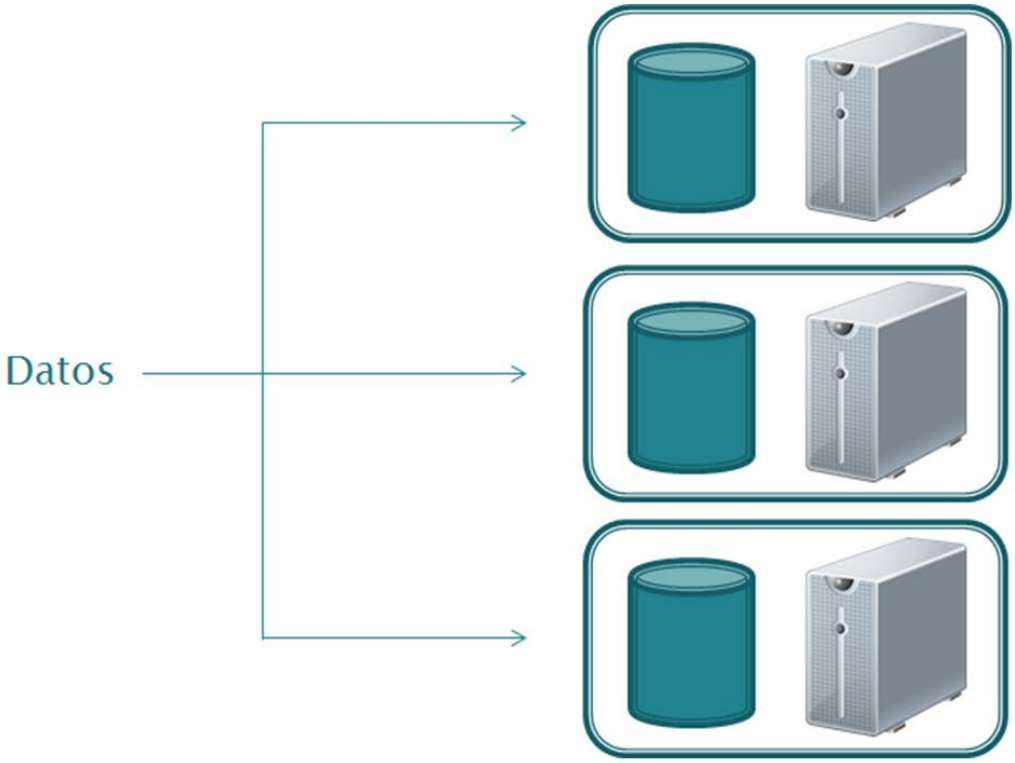

Figura 5. Arquitectura de Hadoop

Cuando los datos se almacenan en Hadoop, estos se dividen en bloques, que es la unidad en la cual se realizan los cálculos (procesos *map*). Un nodo maestro gestiona los cálculos para asegurar que se realizan correctamente. Este proceso se muestra gráficamente en la Figura 6.

De esta forma, se persigue que los nodos se comuniquen entre ellos lo menos posible. Como los datos se distribuyen cuando se almacenan, evitamos el cuello de botella que supone leer los datos de la base de datos. Además, los cálculos se llevan a los datos, no al revés, es decir, que los cálculos se ejecutan en los ordenadores que almacenan los datos sobre los que se deben realizar tales cálculos.

Finalmente, Hadoop replica los bloques en varios nodos por razones de prestaciones y de tolerancia a fallos.

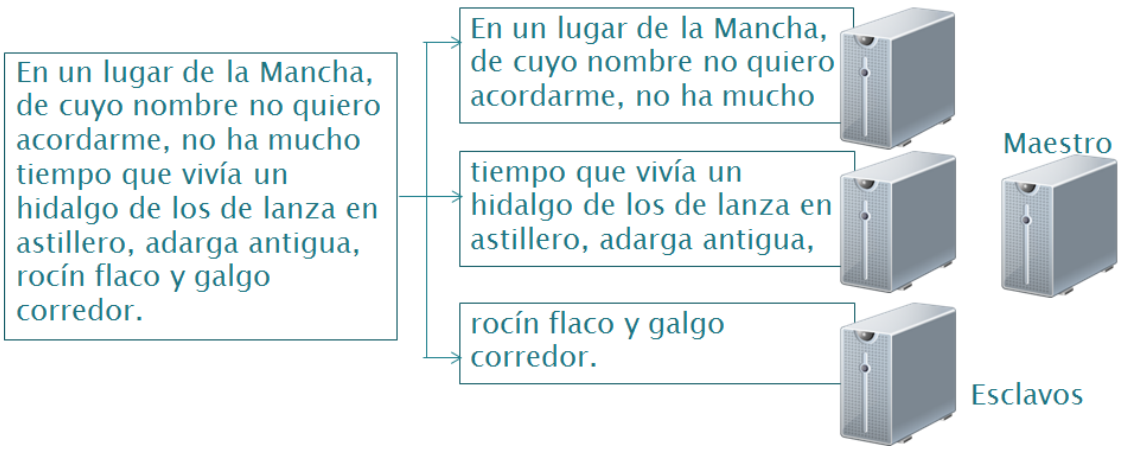

Figura 6. Datos divididos en bloques

3 Hadoop y su estructura

Hadoop forma parte de un ecosistema con múltiples componentes, algunos de los cuales se muestran en la Figura 7. Los componentes principales de Hadoop son el sistema de ficheros distribuido de Hadoop (*Hadoop Distributed File System, HDFS*) y el entorno de programación MapReduce. A continuación veremos brevemente las características principales de cada uno.

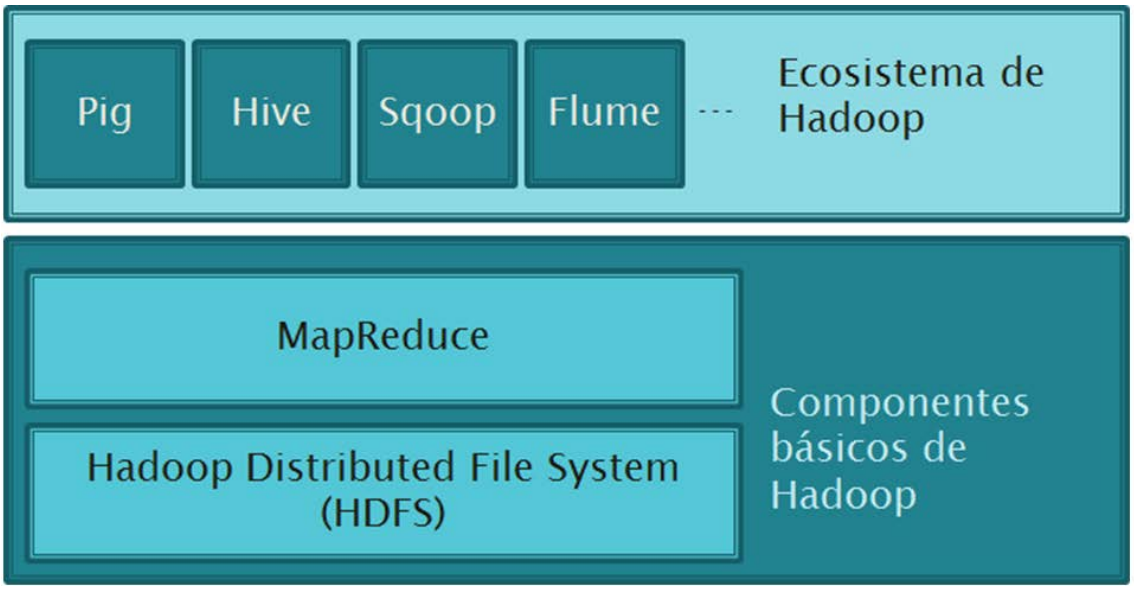

Figura 7. Ecosistema de Hadoop

3.1 Hadoop Distributed File System (HDFS)

HDFS es un sistema de archivos distribuido y tolerante a fallos. Funciona sobre el conjunto de los nodos de un cluster de Hadoop, balanceando la carga de archivos entre las máquinas del cluster, de forma equitativa. Gracias a su naturaleza distribuida, proporciona alta disponibilidad y altas prestaciones que le permiten ser capaz de manejar grandes ficheros.

Para insertar datos en HDFS existen una variedad de formas:

- Copiarlos manualmente utilizando un comando.
- Utilizando la herramienta Flume, que recoge datos de diversas fuentes y los inserta automáticamente.
- Utilizando la herramienta Sqoop, que transfiere datos entre HDFS y bases de datos relacionales.
- …

Ahora vamos a ver con detalle los procesos de escritura y lectura de datos en HDFS.

3.1.1Escrituras en HDFS

La forma en que HDFS gestiona las escrituras de archivos se explica a continuación:

1. Primero, el fichero de datos se divide en bloques de tamaño fijo, normalmente 64 o 128 MB. Esto se muestra en la Figura 8.
2. Tras esto, cada bloque se almacena en varios de los nodos del cluster. Esto se muestra en la Figura 9.

De esta forma, al estar cada bloque de datos replicado en varios nodos del cluster, en caso de fallo de alguno de los nodos, no se pierde información, y el sistema puede seguir funcionando correctamente (exceptuando el decremento de la capacidad del sistema consecuencia del fallo).

Para gestionar HDFS, tenemos un nodo especial en el cluster que se llama *NameNode.* Esta máquina almacena para cada fichero dónde se almacenan los bloques que lo forman.

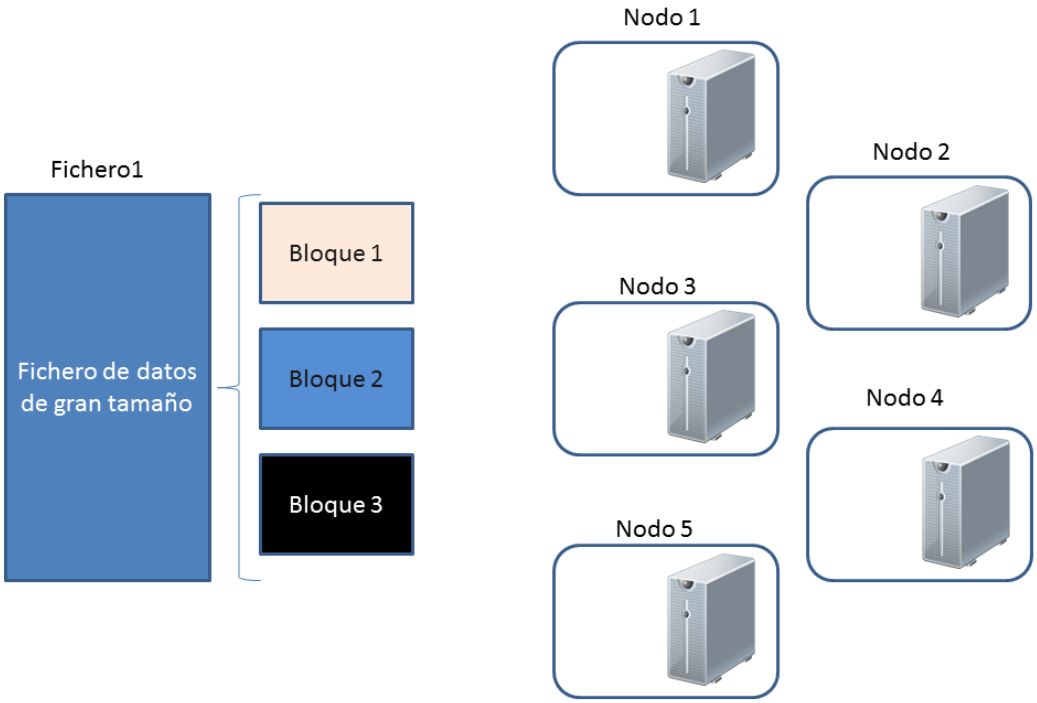

Figura 8. Escrituras en HDFS: Dividir el archivo en bloques

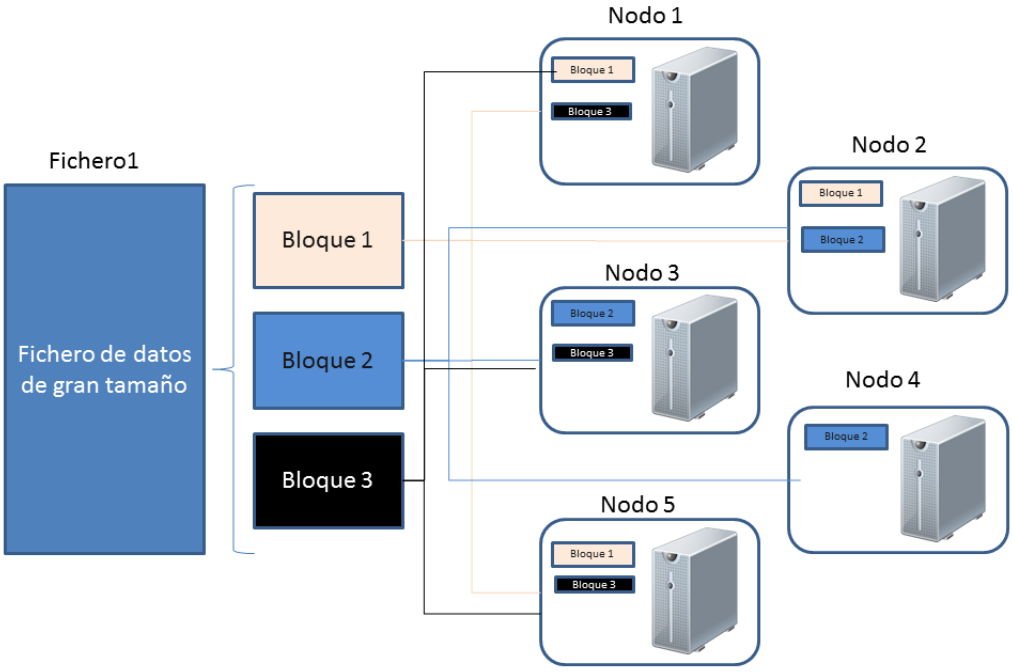

Figura 9. Escritura en HDFS: Almacenar cada bloque en múltiples nodos del cluster

3.1.2 Lecturas en HDFS

El proceso de lecturas de ficheros en HDFS es como sigue:

1. En primer lugar, el ordenador del cliente realiza la petición de lectura de un archivo al NameNode (esto se muestra en la Figura 10).
2. Entonces, el NameNode chequea en sus registros qué bloques pertenecen a dicho archivo así como dónde están almacenados tales bloques, y devuelve esta información al cliente (ver Figura 11)
3. Tras esto, el cliente solicita directamente a los nodos correspondientes que le envíen los bloques de dicho fichero (ver Figura 12). Finalmente, los nodos le envían al cliente los bloques correspondientes directamente, sin pasar por el NameNode.

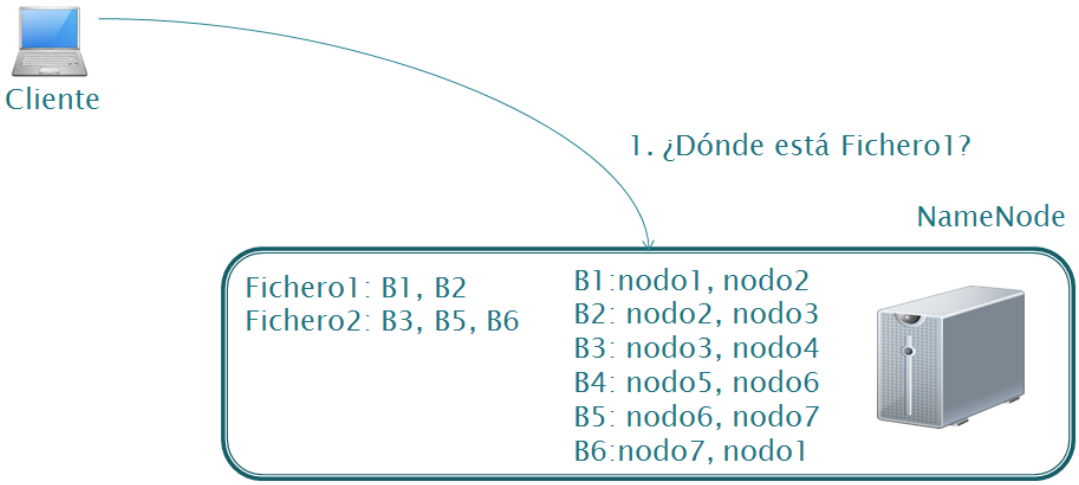

Figura 10. Lectura de HDFS: Petición del cliente

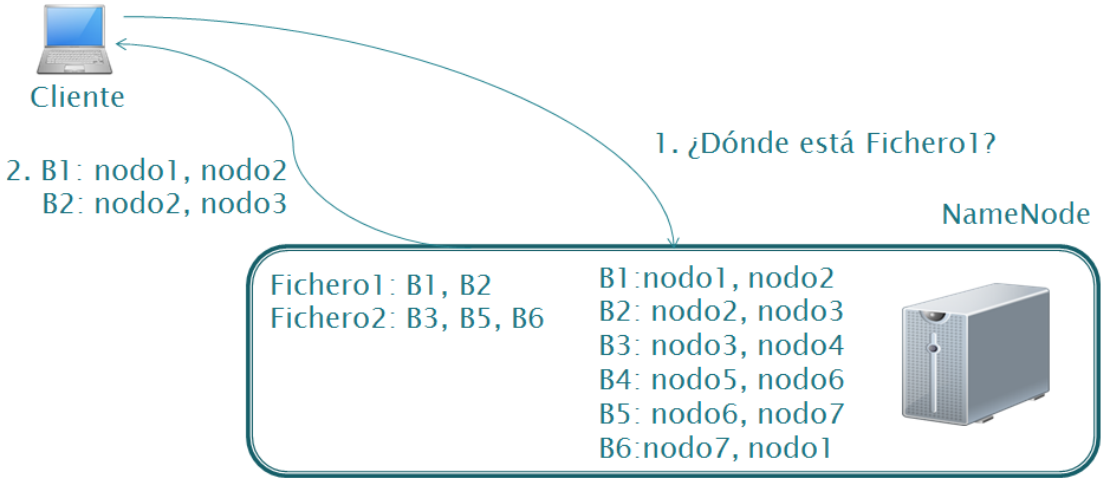

Figura 11. Lectura de HDFS: Respuesta del NameNode

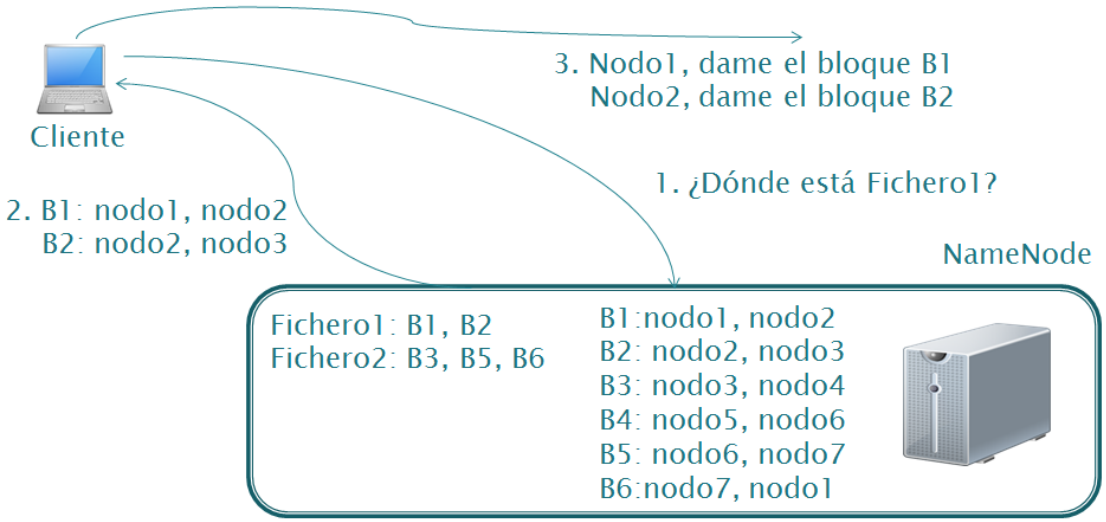

Figura 12. Lectura HDFS: Petición a los nodos

3.2 MapReduce

MapReduce es un modelo de programación paralela distribuida enfocado a grandes conjuntos de datos procesados en un cluster. Automatiza la paralelización de las ejecuciones así como la distribución de las tareas entre los nodos.

MapReduce consta de varias fases:

- *Map*:
  - Opera en un único bloque de un fichero HDFS.
  - Se ejecuta siempre que sea posible en el nodo que almacena dicho bloque, lo que minimiza el tráfico sobre la red.
- *Shuffle & sort* (barajar y ordenar):
  - Ordena y consolida los datos intermedios de todos los maps.
  - Sucede cuando todas las tareas map han acabado y antes de que comiencen las tareas *reduce*.
- *Reduce*:
  - Opera sobre los resultados intermedios ordenados y barajados (la salida de las tareas map).
  - Produce los resultados finales.

Para entender mejor Mapreduce, vamos a ver un ejemplo típico consistente en un contador de palabras. Partimos de un fichero de texto y deseamos obtener un conteo de las palabras que lo forman, y esto se realiza a través de las funciones Map y Reduce, como se muestra en la Figura 13.

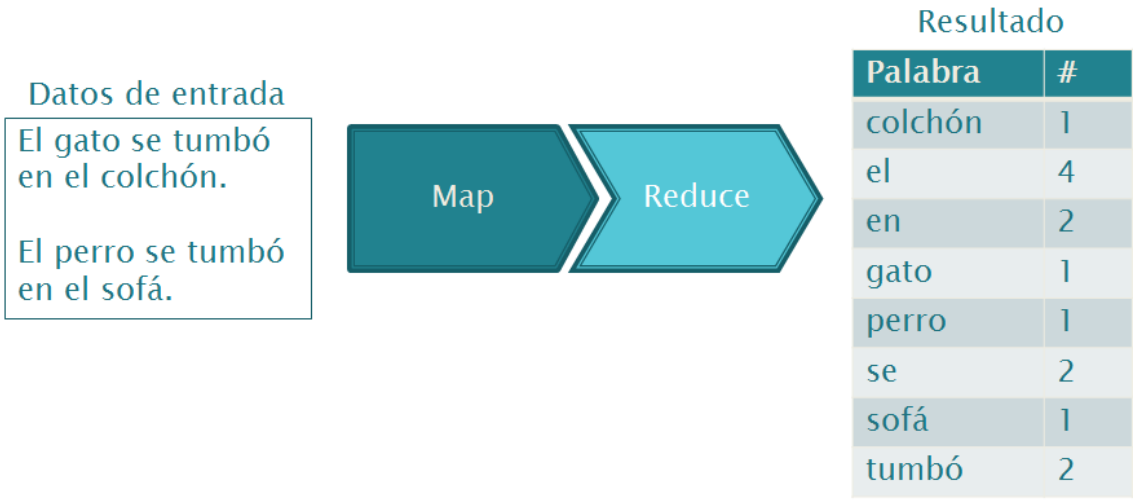

Palabra	#
colchón	1
el	4
en	2
gato	1
perro	1
se	2
sofá	1
tumbó	2

Figura 13. Ejemplo de MapReduce

Los pasos que sigue Hadoop para realizar esta tarea son los que siguen:

1. En primer lugar, se ejecutan procesos *map* sobre cada bloque que forma dicho fichero. Estos procesos se ejecutan en la medida de lo posible en los ordenadores que almacenan dichos bloques de forma que se minimice la información que se transfiere a través de la red de interconexión. Como resultado de esta fase, se obtiene un listado de pares <clave, valor>, que en este caso tiene como clave cada palabra, y como valor 1. Esto se muestra en la Figura 14.

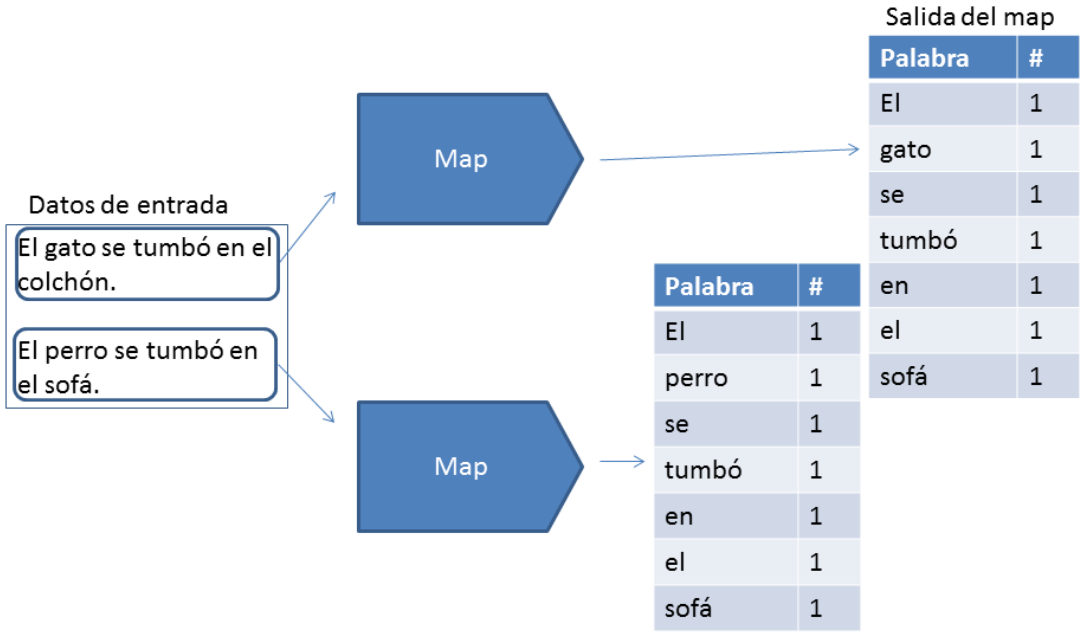

Palabra	#
El	1
perro	1
se	1
tumbó	1
en	1
el	1
sofá	1

Palabra	#
El	1
gato	1
se	1
tumbó	1
en	1
el	1
sofá	1

Figura 14. Ejemplo de Mapreduce: Map

2. Tras finalizar los *map*, la salida de todos los *map* se combina dentro de la fase de *shuffle and sort*, de forma que las parejas <clave,valor> que tengan la misma clave se agrupan (es decir, las que tengan la misma palabra), de la forma en que lo muestra la Figura 15.

3. Finalmente, la fase *reduce* toma la salida de la fase anterior y agrega los valores que tengan la misma clave, dando como resultado el sumatorio de ocurrencias de cada palabra (ver Figura 16).

Hadoop se encarga de automatizar la diseminación de las tareas a través de los nodos, la gestión de los fallos, ... de forma que el usuario solamente se tiene que concentrar en implementar las funciones *map* y *reduce*. Además, con el fin de evitar realizar transferencias de información a través de la red, que crearían latencias, Hadoop trata de ejecutar las tareas *map* en los nodos del cluster que almacenan los bloques sobre los que opera dicha función *map*.

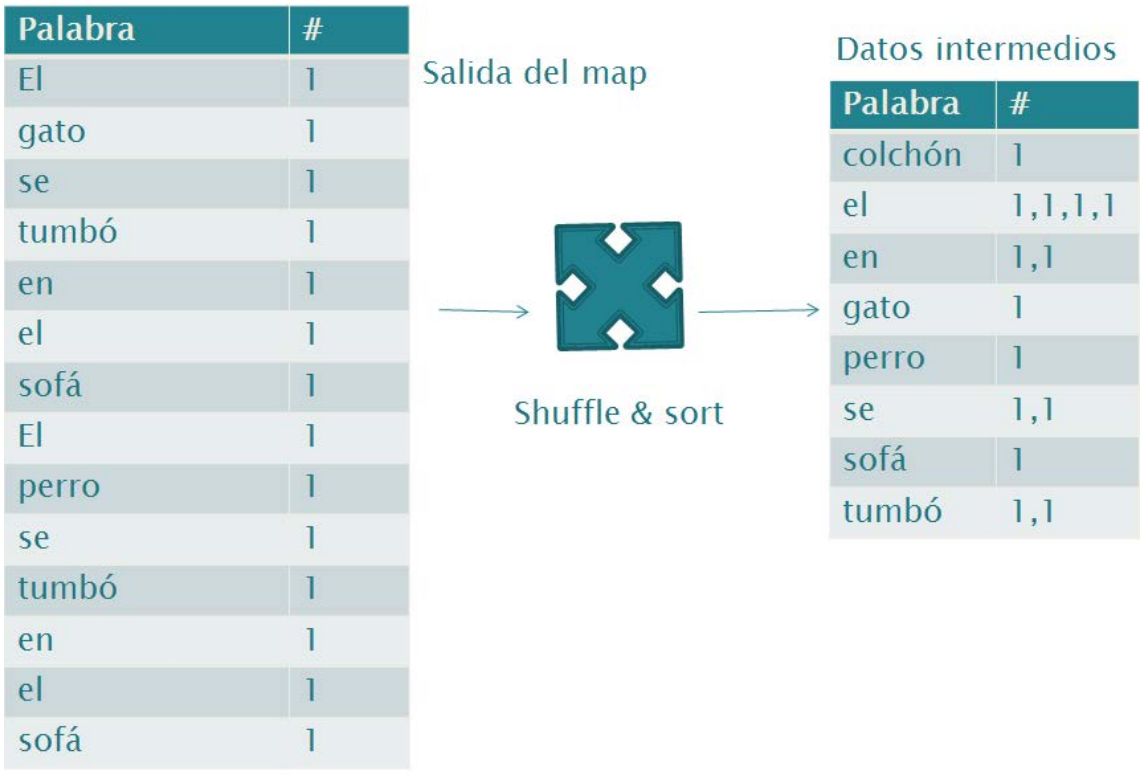

Figura 15. Ejemplo de Mapreduce: Shuffle & sort

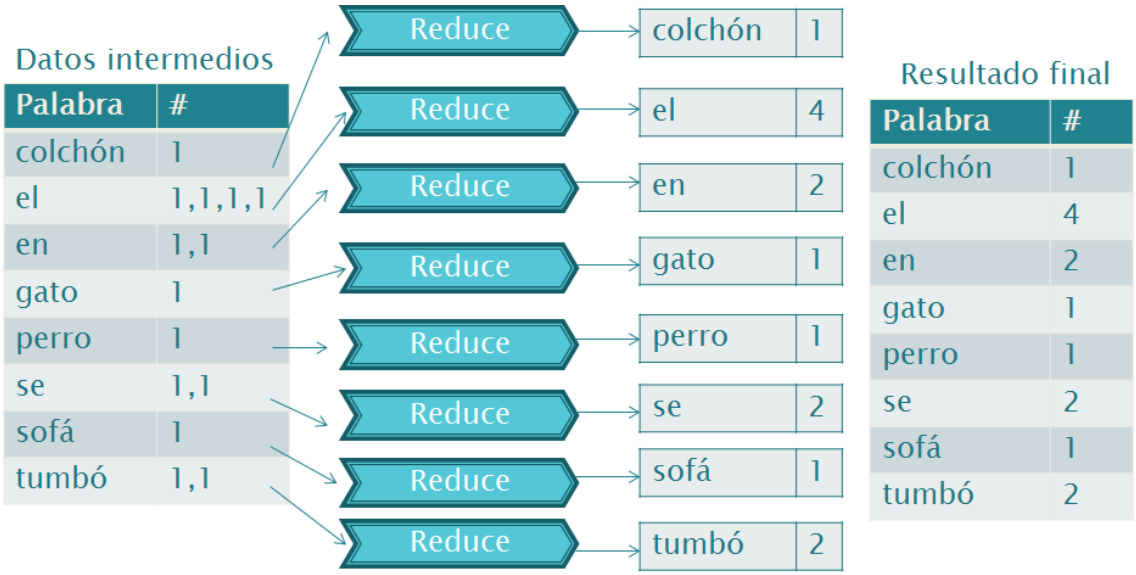

Figura 16. Ejemplo de Mapreduce: Reduce

3.3 Ecosistema de Hadoop

Hadoop es un proyecto vivo con una gran variedad de herramientas que incrementan su funcionalidad y facilidad de uso.

- **Hive**: Interacción con Hadoop utilizando un lenguaje de consultas similar a SQL.
- **Pig**: Interacción con Hadoop utilizando un lenguaje de script.
- **Sqoop**: Comunicación de Hadoop con bases de datos relacionales.
- **Flume**: Herramienta para mover grandes cantidades de datos.
- **HUE**: Interfaz gráfico para Hadoop.
- ...

3.4 Distribuciones

Existen una variedad de distribuciones de Hadoop, proporcionadas por diversas empresas, que extienden su funcionalidad y le proporcionan soporte.

- Cloudera, Hortonworks, MapR

Una de las más importantes es **Cloudera**, que será la que utilicemos en este curso.

Entre las ventajas de Cloudera se encuentran ...

- Proporciona asistentes que facilitan la instalación.

- Es una de las distribuciones más utilizadas.
- Hay gran cantidad de materiales, tutoriales, libros... que se basan en ella.

4 Ejemplo de trabajo con Hadoop

En este ejemplo, trabajaremos con la distribución Cloudera, que ha sido seleccionada por las ventajas arriba mencionadas. Además, se puede descargar de su web una máquina virtual donde podremos practicar y aprender los conceptos de Hadoop.

Además, utilizaremos un conjunto de datos del sitio web Yelp Challenge. Yelp es una web donde los usuarios formulan opiniones para una gran variedad de negocios, por ejemplo, restaurantes, gimnasios, dentistas, ... Si un usuario está buscando un determinado negocio (por ejemplo, un gimnasio en Madrid), puede acudir a Yelp para recabar opiniones y elegir basándose en ellas. Yelp permite la descarga de algunos de sus datos dentro del programa Yelp Challenge.

4.1 Preparando el entorno de trabajo

Como hemos comentado antes, vamos a utilizar la máquina virtual oficial de Cloudera para este trabajo. Esta máquina virtual la descargaremos del siguiente enlace:

https://www.cloudera.com/content/cloudera/en/downloads/quickstart_vms/cdh-5-4-x.html

En dicho enlace (que nos lleva a la página que se muestra en la Figura 17), seleccionaremos la máquina virtual de la versión 5.4.2 para la tecnología VirtualBox. Se trata de un fichero comprimido llamado *cloudera-quickstart-vm-5.4.2-0-virtualbox.zip*.

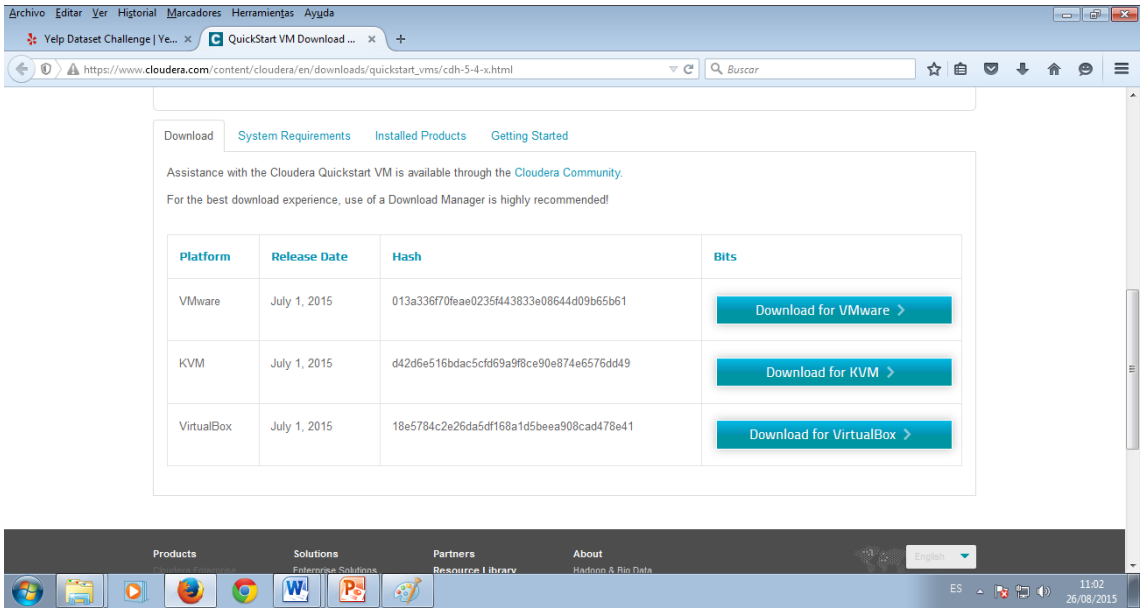

Figura 17: Descarga de la máquina virtual de Cloudera

Para utilizar esta máquina virtual, deberemos tener el software VirtualBox descargado e instalado en nuestro ordenador. Dicho software se encuentra disponible desde el siguiente enlace:

https://www.virtualbox.org/

Una vez tengamos VirtualBox instalado y la máquina virtual descargada y descomprimida en nuestro ordenador, deberemos importar la máquina virtual en nuestra instalación de VirtualBox. Para ello, ejecuta el programa VirtualBox, y en su ventana principal, haz click en "File", seguido de "Import appliance". Seguidamente aparecerá una ventana donde tendrás que navegar hasta la carpeta donde hayas descomprimido la máquina virtual, y seleccionar el fichero con extensión *.ovf*, llamado"cloudera-quickstart-vm-5.4.2-0-virtualbox.ovf". Una vez hayas importado correctamente la máquina virtual, ésta aparecerá a la izquierda en la ventana principal de VirtualBox, tal y como muestra la Figura 18.

Para arrancar la máquina virtual, selecciónala y clica el botón "Start" que aparece en la parte de arriba de la ventana de VirtualBox. Una nueva ventana aparecerá, que será la del escritorio de la máquina virtual. Dependiendo de la potencia del ordenador donde se está ejecutando, este proceso puede tardar unos minutos. Una vez la máquina virtual esté funcionando, aparecerá una ventana del navegador de Internet de la máquina virtual, que se abre de forma automática al arrancar la máquina virtual, similar a la que muestra la Figura 19[1].

[1] Se recomienda no actualizar el software de la máquina virtual cuando lo pida.

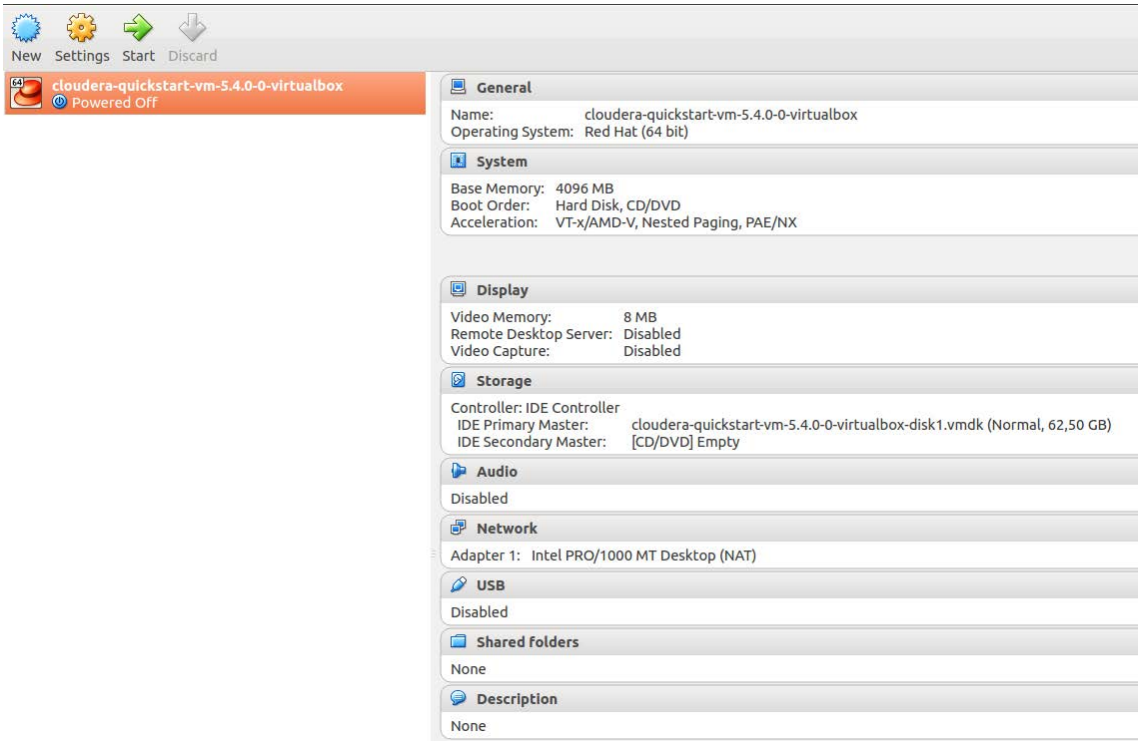

Figura 18. Ventana de VirtualBox

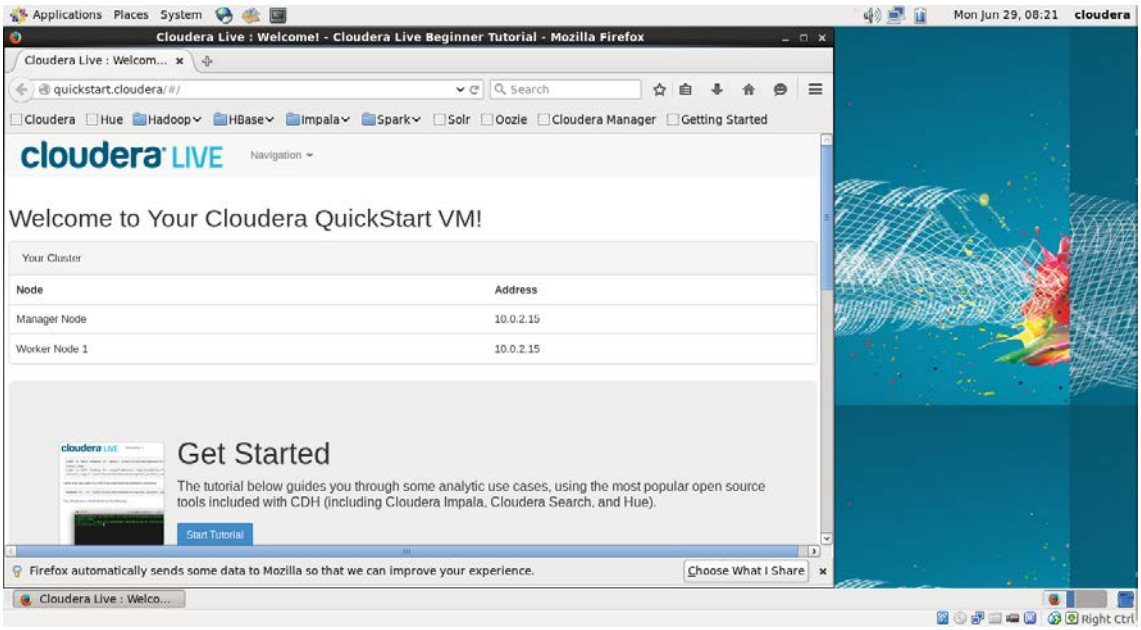

Figura 19. Máquina virtual iniciada

4.2 Preparando los datos

Como hemos comentado anteriormente, vamos a utilizar datos de Yelp, que se pueden descargar del siguiente enlace:

http://www.yelp.com/dataset_challenge/

Desde este enlace (que nos lleva a la página que se muestra en la Figura 20), clicando en el enlace "Get the data", y tras rellenar un formulario con nuestros datos, nos descargaremos un fichero comprimido que contiene, entre otros los siguientes ficheros:

- *yelp_academic_dataset_business.json* → fichero que contiene información de negocios.
- *yelp_academic_dataset_review.json* → fichero que contiene información de opiniones.

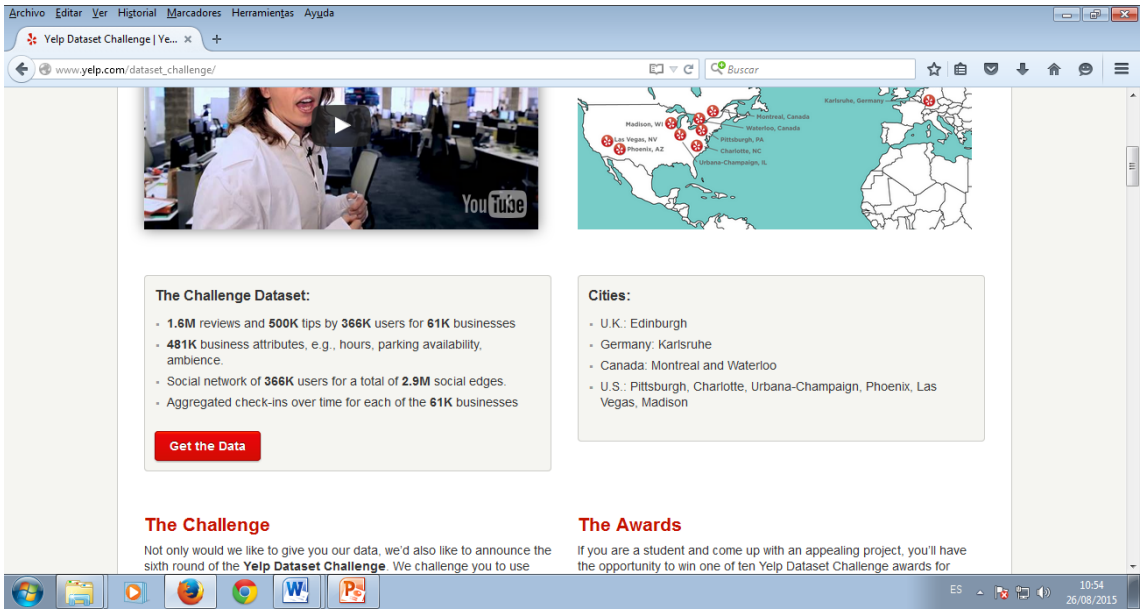

Figura 20: Yelp challenge: Get the data

Los datos de los negocios que tenemos son los siguientes:

- "city", "review_count", "name", "neighborhoods", "type", "business_id", "full_address", "hours", "state", "longitude", "stars", "latitude", "attributes", "open", "categories".

  - Los datos más importantes con los que trabajaremos en este ejemplo son:
    - review_count: contador de opiniones.
    - Latitude, altitude: coordenadas geográficas.

- Business_id: un identificador para el negocio.
- Categories: el tipo de negocio (ej. Restaurante, ...).

También tenemos datos de opiniones:

1. "funny", "useful", "cool", "user_id", "review_id", "text", "business_id", "stars", "date", "type"
    - Los datos más importantes con los que trabajaremos en este ejemplo son:
        - Text: el texto de la opinión, que refleja la descripción que el usuario de Yelp ha realizado sobre ese negocio.
        - Cool: un número entero que cuanto más alto, mejor es la valoración de este negocio.

Los datos de Yelp Challenge son datos en formato JSON, es decir, que tienen una estructura como la que sigue, en la que para cada campo tenemos su nombre seguido de su valor:

- Ejemplo de negocios:
    - **{"business_id"**: "vcNAWiLM4dR7D2nwwJ7nCA", **"full_address"**: "4840 E Indian School Rd\nSte 101\nPhoenix, AZ 85018", **"categories"**: ["Doctors", "Health & Medical"], **"city"**: "Phoenix", "review_count": 9, **"name"**: "Eric Goldberg, MD", **"longitude"**: -111.98375799999999, **"stars"**: 3.5, **"latitude"**: 33.499313000000001}
- Ejemplo de opiniones:
    - {**"votes"**: {**"funny"**: 0, **"useful"**: 2, **"cool"**: 1}, **"user_id"**: "Xqd0DzHaiyRqVH3WRG7hzg", **"stars"**: 5, **"date"**: "2007-05-17", **"text"**: "dr. goldberg offers everything i look for in a general practitioner", **"type"**: "review", **"business_id"**: "vcNAWiLM4dR7D2nwwJ7nCA"}

4.3 Trabajando con Hive

En este apartado vamos a trabajar con Hive, la herramienta del ecosistema de Hadoop que proporciona un interfaz con una sintaxis similar al lenguaje de consultas de bases de datos relacionales SQL. Utilizaremos también el interfaz de línea de comandos de Hadoop, así como su interfaz gráfico HUE, que nos proporcionará una forma intuitiva para cargar ficheros en el cluster, redactar y ejecutar programas así como ver los resultados.

Utilizaremos estas herramientas para procesar datos de Yelp. Para ello, seguiremos los siguientes pasos.

1. En primer lugar, antes de nada deberemos preprocesar los datos de Yelp. La estructura en formato JSON de estos datos no es idónea para el trabajo con Hive, debido a la existencia de campos anidados (el campo "votes" contiene los subcampos "funny", "useful" y "cool") así como la presencia de saltos de línea dentro de algunos campos de texto en las estructuras JSON tanto en el fichero de opiniones como el de negocios.

   Para solucionar estos problemas, ejecutaremos el script llamado convert2.py que se ha proporcionado. Esto se realiza desde un terminal, tecleando la siguiente orden:

   ```
   ./convert2.py
   ```

   Tras esto, tendremos los nuevos ficheros siguientes:
   - yelp_academic_dataset_business_*clean2*.json
   - yelp_academic_dataset_review_*clean2*.json

2. Ahora iniciaremos HUE, para lo cual deberemos ejecutar el navegador de Internet. En la página de inicio del navegador de Internet del entorno virtual (ver Figura 19), haz click en el botón que dice "Launch Hue UI". Para conectarte a HUE deberás utilizar los siguientes datos de acceso:

   Usuario: cloudera

   Clave: cloudera

3. Ahora cargaremos los dos ficheros generados en el paso 1 en nuestro cluster de Hadoop. Este punto se realiza desde la opción "File Browser" situada arriba a la derecha en el interfaz de HUE.

4. Seguidamente, crearemos tablas partiendo de estos ficheros, una llamada "business" y otra llamada "reviews". Este paso se realiza desde "Data Browsers" → "Metastore tables". Debemos prestar atención a que las columnas de las tablas tengan los nombres correctos, dichos nombres son los que se mencionan en el apartado 4.2 de este documento. Para nombrar las columnas, clica en "Bulk edit column names" y pega los nombres de las columnas correspondientes a la tabla que estás creando.

5. Una vez las tablas estén creadas con los datos correctos, crea una consulta utilizando el editor de Hive (esto se encuentra en "Query editors"-> "Hive") con el siguiente contenido:

```
SELECT name, review_count
FROM business
ORDER BY review_count DESC
LIMIT 25
```

Esta consulta devuelve el nombre y el contador de opiniones de los 25 negocios que mayor número de opiniones tengan. Para ejecutar esta consulta clicaremos en "Execute".

6. Tras ejecutarla, si vamos a la opción "Chart" podremos ver sus resultados graficados de varias formas diferentes.

7. Ahora ejecutaremos otra consulta algo más compleja que nos devolverá, entre otra información, la localización geográfica de los 25 restaurantes con mejores valoraciones. La consulta a ejecutar es la siguiente:

```
SELECT r.business_id, name, SUM(cool) AS coolness, longitude,
latitude
FROM review r JOIN business b
ON (r.business_id = b.business_id)
WHERE categories LIKE '%Restaurants%'
GROUP BY r.business_id, name, longitude, latitude
ORDER BY coolness DESC LIMIT 25
```

Tras clicar en "Execute", veremos sus resultados. En este caso, si vamos a la opción "Chart", y dentro de ella, "Map", podremos visualizar los resultados en forma de mapa. Para ello, deberemos indicar qué campos resultado de la consulta se deben utilizar para realizar la visualización en el mapa, es decir, la longitud y latitud geográficas. Esto es, en el desplegable "Latitude" seleccionamos "Latitude" y en el desplegable "Longitude" seleccionamos "Longitude". El resultado de esta consulta se muestra en Figura 22.

Con el fin de aclarar los conceptos de Hadoop así como para presentar varios ejemplos de funcionamiento, tanto utilizando el interfaz gráfico HUE como con la línea de comandos, hemos preparado una serie de vídeos que se encuentran accesibles desde el curso virtual.

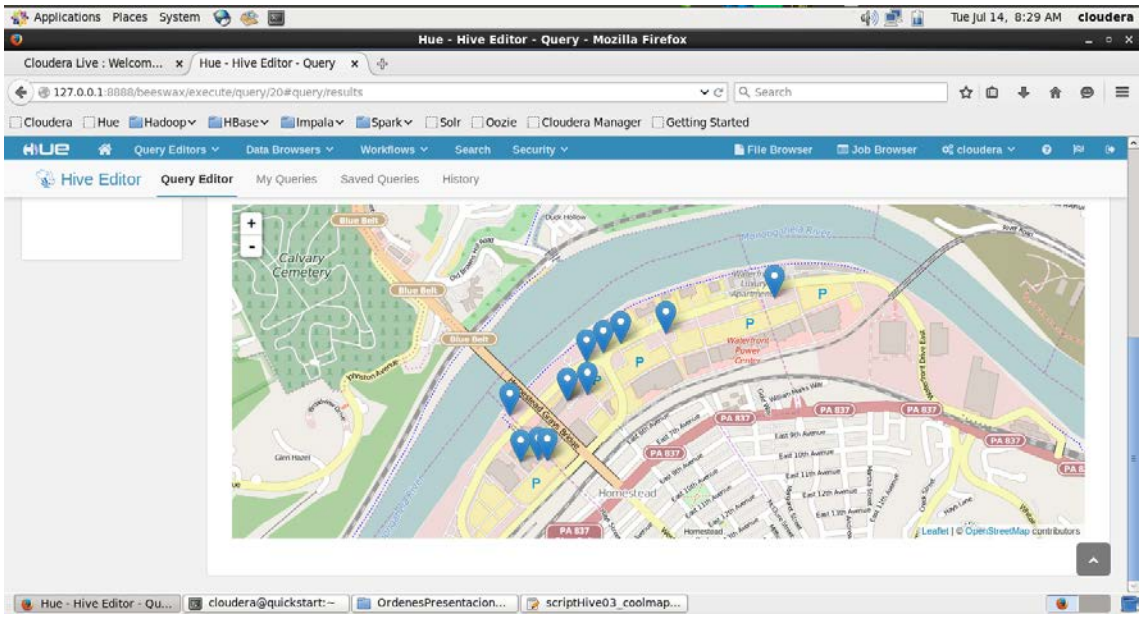

Figura 21. Visualización en el mapa del resultado de una consulta Hive

5 Ejercicio de evaluación

En este ejercicio vamos a trabajar con varios ficheros de datos de Yelp y vamos a realizar una serie de consultas sobre ellos utilizando la herramienta Hive de Hadoop. En el enlace http://www.yelp.com/dataset_challenge/ se puede encontrar una breve explicación de los campos de cada registro JSON de los datos de Yelp.

Para realizar estas consultas, así como para subir datos a Hadoop, crear tablas, ... se puede utilizar tanto la línea de comandos de Hadoop como el interfaz gráfico HUE (en los vídeos accesibles desde el curo virtual se muestra el funcionamiento tanto del interfaz gráfico como de la línea de comandos). Sin embargo, se valorará positivamente que se utilicen ambas formas de trabajo con Hadoop para cada una de las tareas a realizar (por ejemplo, se pueden subir al cluster algunos ficheros mediante línea de comandos y otros mediante HUE, se pueden crear algunas tablas mediando comandos y otras mediante HUE, ...). Esto debe detallarse en la memoria.

Recuerda que tal vez sea necesario preprocesar estos datos de Yelp antes de utilizarlos en Hadoop. En el caso de que sea necesario, esto se debe detallar convenientemente en la memoria.

Las consultas a realizar son las siguientes:

1. Los usuarios de Yelp pueden tener amigos, y esto se encuentra representado en la estructura JSON que representa a cada uno. Además,

para cada usuario se almacena la media de estrellas que ha otorgado en sus opiniones. Teniendo en cuenta estas consideraciones, realiza una consulta que devuelva los 10 usuarios cuyo grupo de amigos sume más media de estrellas.

2. Realiza una consulta que devuelva los 3 usuarios que más estrellas han dado a los 20 negocios con mejores valoraciones (estas valoraciones se refieren al campo "Cool").

3. Yelp almacena estadísticas sobre los clientes que han utilizado cada negocio acumulados por horas y días de la semana (por ejemplo, los domingos de 9 a 10 han utilizado este negocio 10 personas). Esto se almacena en la estructura JSON llamada *checkin.* Teniendo esto en cuenta, realiza una consulta que devuelva los dentistas ortodontistas (en inglés, "Orthodontists") que hayan recibido más clientes los lunes a cualquier hora.

4. Entre los datos que Yelp almacena se encuentran las "*tips*", que son indicaciones sobre un determinado negocio. Un ejemplo de indicación puede ser lo siguiente: "Este restaurante es difícil de encontrar ya que la zona no está bien cartografiada. Tu GPS se va a hacer un lío. Para encontrarlo ve a la estación de tren y luego sigue todo recto hasta que veas un edificio rojo, está justo enfrente". Teniendo esto en cuenta, realiza una consulta que devuelva los 5 negocios que más indicaciones necesiten que contengan la palabra "GPS".

6 Detalles de la evaluación

Una vez realizadas las consultas explicadas en la sección anterior, la forma de evaluar el trabajo se hará en base a lo siguiente:

- Una memoria explicativa en la que se detalle el trabajo realizado.
  - Se deberá incluir tanto el documento en formato pdf como las fuentes del documento en el formato que el estudiante haya utilizado (doc, docx, odt, ...).
  - La memoria debe contener al menos un apartado que detalle el proceso de cargar los datos en Hadoop (ej. preprocesamiento que haya podido ser necesario, comandos de Hadoop para cargar los ficheros o crear tablas si se ha hecho mediante comandos, ...) y otro apartado que contenga las consultas realizadas con sus respectivas explicaciones, junto con capturas de pantalla de sus resultados. Además, la memoria debe contener todo lo que el estudiante considere necesario para

evaluar su trabajo (ej. explicaciones, scripts, consultas, capturas de pantalla, ...), de forma que la memoria sea autocontenida para facilitar su evaluación.
    - No es necesario explicar en la memoria el proceso de instalación de la máquina virtual.
    - Se valorará positivamente el hecho de utilizar tanto el interfaz de línea de comandos como el interfaz gráfico para realizar los desarrollos de este trabajo. Por ejemplo, se pueden crear algunas tablas con el interfaz gráfico y otras con comandos, subir algunos archivos a Hadoop con comandos y también con el interfaz gráfico.
    - La memoria puede opcionalmente contener un apartado final donde se explique la opinión del estudiante sobre esta práctica, así como puntos fuertes y/o débiles de la práctica.
    - La memoria completa no debe tener una extensión superior a 10 páginas con tamaño de letra 11, e interlineado y márgenes razonables a elección del estudiante.

- Documentos de texto sin formato que contengan los scripts y las consultas que se hayan realizado, listos para ser ejecutados en la máquina virtual. Los desarrollos realizados deberán funcionar correctamente en la máquina virtual de Cloudera que se indica en este enunciado.

Este material se deberá incluir en un fichero comprimido y enviado a través del curso virtual dentro de los plazos establecidos para su entrega. El nombre de dicho fichero comprimido deberá tener la siguiente estructura: *CentroAsociado-ApellidosNombre.zip*, donde *CentroAsociado*, *Apellidos* y *Nombre* deben sustituirse por los valores correspondientes para cada estudiante. Un nombre correcto es, por ejemplo, el siguiente: Cuenca-GarciaMartinezTeresa.zip

Solamente habrá un intento para entregar la práctica y se valorarán negativamente los defectos de forma al realizar la entrega. En estos casos, se considerará la práctica como no entregada, y no será posible volver a entregarla. Se recomienda no dejar la entrega para última hora, ya que pueden haber imprevistos (por ejemplo, fallos técnicos, ...) que impidan su entrega en los plazos establecidos.

Esta práctica tiene un valor de 1.5 puntos en la nota final de la asignatura, y solamente se corregirá en el cuatrimestre en el que se imparte la asignatura.

7 Notas y referencias de interés

7.1 Notas de interés

Con el fin de aclarar el funcionamiento de Hadoop, así como para introducir algunos ejemplos más de uso de Hadoop tanto mediante línea de comandos como mediante el interfaz gráfico, hemos preparado una serie de vídeos explicativos. Dichos vídeos se encuentran accesibles desde el curso virtual.

7.2 Referencias de interés

- Página de la Wikipedia sobre Big Data. Disponible en https://es.wikipedia.org/wiki/Big_data
- Página web de Apache Hadoop. Disponible en: https://hadoop.apache.org/
- Página web de Apache Hive. Disponible en: https://hive.apache.org/
- Página web de HUE. Disponible en: http://gethue.com/
- Programming Hive. Data Warehouse and Query Language for Hadoop Autores: Edward Capriolo, Dean Wampler, Jason Rutherglen. Editorial O'Reilly Media.
- Algunos tutoriales de Hadoop. Disponibles en: https://github.com/romainr/hadoop-tutorials-examples