



進階課程

Hadoop + RDBMS

© TemplatesWise.com

Hadoop 0.20 + MySQL 5.5

王耀聰 陳威宇

Jazz@nchc.org.tw

wuae@nchc.org.tw



財團法人國家實驗研究院

國家高速網路與計算中心
NATIONAL CENTER FOR HIGH-PERFORMANCE COMPUTING



Hadoop 與 JDBC

- JDBC：用於執行SQL的Java API，目的在於無論機器改變、或資料庫改變，程式碼都可以不用改變
 - ◆ 支援 MySQL, PostgreSQL, Oracle, SQL...
 - ◆ 非預設就有，需額外針對資料庫形式下載對應的Jar 檔
- Hadoop 0.19 開始設計能與JDBC溝通的API
 - ◆ *org.apache.hadoop.mapred.lib.db (0.19)*
 - ◆ *org.apache.hadoop.mapreduce.lib.db (0.20~0.21)*

DBConfiguration

- DBConfiguration.configureDB(參數)
 - ◆ 參數 :

job	driverClass	dbUrl	userName	passwd
Hadoop 定義的 job	JDBC driver	資料庫url	帳號	密碼
job	com.mysql.jdbc.Driver	jdbc:mysql://localhost/mydb	root	rootpasswd

DBInputFormat

- 從DB端讀取資料
 - ◆ **DBRecordReader** : 從table中讀取bytes記錄
 - ◆ **DBInputSplit** : 描述輸入bytes的範圍
- **setInput()** : 設定初始輸入資料

DBWritable

- **DBWritable** : 定義key-value 格式
 - ◆ public void write(PreparedStatement statement) throws SQLException;
 - ◆ public void readFields(ResultSet resultSet) throws SQLException;

DBOutputFormat

- 對DB端寫入資料
- DBOutputFormat.setOutput() 設置輸出資訊

Conclusions

- Hadoop 可以支援 RDBMS 與 NoSQL
- NoSQL 的 HBase 結構上與 Hadoop 設計相近，又是針對存取大資料量，彼此互相支援
- 透過 Java 的 JDBC ， Hadoop 也可以對 MySQL 等資料庫作存取動作