

# » 巨量資料分析與應用 (1)

楊立偉教授

台灣科技大學資管系

2013 Fall

# 楊立偉教授

## ◆ 專長領域為資料庫及語意分析技術、知識管理、數位行銷

現任	台科大資管系兼任助理教授 2008~
	台大工管系暨商研所兼任助理教授 2006~
	資訊及通信國家標準技術委員
	意藍資訊 董事總經理（創辦人）1999~ 國內規模最大的網路情報與社群口碑自動分析平台
	龍捲風科技 董事總經理 國內企業搜尋引擎市佔率最高；國際檢索競賽第一名
經歷	智威湯遜數位行銷首席顧問、尚藍互動行銷共同創辦人
	2009年獲選100 MVP最有價值經理人，擁有超過20項語意分析專利
	2012年榮獲國家雲端創新獎、數位時代「創業之星」首獎

# 課程內容

## ◆ 目標

- 了解巨量資料 ( big data ) 與相關趨勢
- 了解巨量資料分析及管理的理論與架構
- 了解相關技術，以及如何應用於企業營運
- 了解最新的相關發展議題巨量資料導論

## ◆ 對象

- IT 經理或系統網路部門主管
- 專案經理、系統架構師或系統網路管理人員
- 對於雲端運算之大量資料處理、分析、應用有興趣者

# 課程大綱

## ◆ 第一部份

- 巨量資料導論
- 巨量資料分析與管理架構
- 巨量資料分析技術

## ◆ 第二部份

- 應用案例與研討 – 企業個案 (1)
- 應用案例與研討 – 企業個案 (2)
- 應用案例與研討 – Open Data

# 參考資料

## ◆ 技術相關

- Data warehousing in the age of big data (2013) by Krish Krishnan.

## ◆ 管理相關

- Big Data : A Revolution that will transform how we live, work, and think (2013) by Viktor Mayer-Schonberger, Kenneth Cukier.

中譯本：《大數據》 · 天下文化 · 2013年5月

- 《雲端時代的殺手級應用：海量資料分析》 · 胡世忠 著 · 天下文化 · 2013年3月

# 巨量資料分析導論 (1)


---

# 資訊科技的發展趨勢 Trend of IT (1)

## ◆ Network 網路

- Internet and Web 網際網路
  - Internet
  - Internet of Things 物聯網
  - Cloud computing 雲端運算
- Mobile network 行動(無線)網路
  - 3G, 4G, LTE, WiFi, RFID, NFC, etc.
- e-Commerce 電子商務
- Social network 社交網路

# 雲端運算 與 物聯網 應用情境



Source : Internet of Things Also a Security Threat by Anthony Myers


# 資訊科技的發展趨勢 Trend of IT (2)

## ◆ Interface 人機界面

- **Multimedia 多媒體**
  - Image, Audio, Video, Virtual Reality, Augmented Reality, etc.
- **User interface 使用者界面**
  - Touch, Voice, Camera, Motion capturing, etc.
- **Wearable technology 穿戴式科技**
  - Biometric 生物辨識
  - Biosensor 生物感測

MIT's wearable device turns  
any surface into an interface

and more wearable devices  
coming.




# 資訊科技的發展趨勢 Trend of IT (3)

## ◆ Data

- Database
  - Data warehouse 資料倉儲
  - Data mining 資料探勘
- Business intelligence 商業智慧
- Big data


# Online in 60 Seconds






A Smarter Planet

By smarter, we mean the world  
is becoming:



**Big Data = Transactions + Interactions + Observations**



Source : IBM, Teradata.

# 巨量資料分析導論 (2)


---

# Trend of Big Data (1)


- ◆ Big Data 係指資料大量成長
- ◆ 根據IBM的研究，全世界90%的資料是在過去2年產生
- ◆ Google、Facebook 等，就是站在Big Data上的範例
- ◆ 巨大的數據源，將改變整個學術界，商界和政府
- ◆ 依賴資料庫工具處理
  - 包括 capture，storage，search，analytics 等

# Trend of Big Data (2)

## "big data" Job Trends



## "data scientist" Job Trends




資料分析人才  
需求大幅增加


# Trend of Big Data (3) 每天產生的資料

- ◆ 搭公車、搭捷運、刷悠遊卡
- ◆ 到便利商店買飲料
- ◆ 用手機上臉書、按個讚、打個卡
- ◆ 送個LINE、拍張照片上傳
- ◆ 上網瀏覽、刷卡購物、給個評價
- ◆ 過個馬路被數個鏡頭拍下...

# Big Data 巨量資料分析的應用緣起



# Big Data 的主要來源



Source : IBM 2012全球CEO調查報告

<https://www-07.ibm.com/tw/blueview/2012oct/8.html>

# Big Data 的應用方式




## ◆ 運用資料與演算，達成智慧決策



Source : IBM 2012全球CEO調查報告  
<https://www-07.ibm.com/tw/blueview/2012oct/8.html>

# Big Data 的特性

- ◆ 數量大、產生速度快、多樣性、可能存在誤差資料

Volume	Velocity	Variety	Veracity
 <b>Data at rest</b> Terabytes to exabytes of existing data to process	 <b>Data in motion</b> Streaming data, milliseconds to seconds to respond	 <b>Data in many forms</b> Structured, unstructured, text and multimedia	 <b>Data in doubt</b> Uncertainty due to data inconsistency and incompleteness, ambiguities, latency, deception and model approximations


# Big Data 對企業的整體資訊供應鍊



Source : IBM 2012全球CEO調查報告

<https://www-07.ibm.com/tw/blueview/2012oct/8.html>

# Data Processing Cycle




Source : Data warehousing in the age of big data by Krish Krishnan. Morgan Kaufmann, 2013

# 巨量資料分析技術 (1)


---

# Big Data Processing Flow



Source : Data warehousing in the age of big data by Krish Krishnan. Morgan Kaufmann, 2013

# Big Data Processing Platform




Source : Data warehousing in the age of big data by Krish Krishnan. Morgan Kaufmann, 2013

# Big Data 新架構的基本需求

- ◆ Extreme parallel processing 儘量平行化處理
- ◆ Minimal database usage 降低資料庫用量
- ◆ Distributed file-based storage 分散式檔案儲存
- ◆ Linearly scalable infrastructure 可線性擴充的架構
- ◆ Programmable APIs 提供開發界面
- ◆ High-speed replication 可高速複製
- ◆ High availability 高可用性
- ◆ Localized processing of data and storage of results
- ◆ Fault tolerance 容錯性

# 相關技術架構 – 以Hadoop為例

## ◆ Hadoop 核心元件




Source : Data warehousing in the age of big data by Krish Krishnan. Morgan Kaufmann, 2013

# (1) HDFS 架構

## ◆ Hadoop Distributed File System


- Provide high throughput access to application data.
- Redundancy, Scalability, Fault tolerance, Cross-platform

- 一般硬體即可, 可適用大檔(GB to PB), 適用快速連續讀取




## (2) Hadoop 的平行處理方式

### ◆ Job executions in Hadoop




# (3) MapReduce 的架構

- ◆ a programming model : divide, conquer, merge




## ◆ MapReduce implementation




# (4) 結合SQL與MapReduce的架構

- ◆ 結合MapReduce處理大規模結構與非結構資料，和廣為熟悉的SQL後結果處理能力
- ◆ 參考 : Apache Pig



# (5) HBase 的架構

- ◆ non-relational (key-value), column-oriented, multidimensional, distributed database




# (6) HBase 的儲存方式

- ◆ 新增為主, 支援多版本, 可自定schema, 有層狀結構

Row key	TS	Column “recipe:”	
“www.foodie.com”	t10	“recipe: foodie.com”	“FOODIE”
“www.foodtv.com”	t9	“recipe: foodtv.com”	“FOODTV.COM”
	t8	“recipe: foodtv.com/ spicy/curry”	“FOODTV.COM”


# (7) Hive的架構

- ◆ 以Hadoop為基礎的資料倉儲方案
  - extend SQL interface




# (7) Hive 的處理流程

- 可在整合入企業商業智慧 (business intelligence) 架構



# 相關技術架構 – 以NoSQL為例

## ◆ Not only SQL 關聯式資料庫以外的選擇



## » 問題討論