

大數據

「數位革命」之後，「資料革命」登場：
巨量資料掀起生活、工作和思考方式的全面革新

BIG DATA

A Revolution That Will Transform
How We Live, Work, and Think

by Viktor Mayer-Schönberger and Kenneth Cukier

麥爾荀伯格、庫基耶__著
林俊宏__譯

大數據

Big Data

A Revolution That Will Transform How We Live,
Work, and Think

原著 — 麥爾荀伯格、庫基耶

譯者 — 林俊宏

策劃群 — 林和 (總策劃)、牟中原、李國偉、周成功

科學叢書總監暨責任編輯 — 林榮崧

封面設計 — 張議文

內頁設計 — 江儀玲

出版者 — 天下遠見出版股份有限公司

創辦人 — 高希均、王力行

遠見·天下文化·事業群 董事長 — 高希均

事業群發行人／CEO — 王力行

出版事業部總編輯 — 許耀雲

版權部經理 — 張紫蘭

法律顧問 — 理律法律事務所陳長文律師

著作權顧問 — 魏啟翔律師

地址 — 台北市 104 松江路 93 巷 1 號 2 樓

讀者服務專線 — (02) 2662-0012 | 傳真 — (02) 2662-0007 ; 2662-0009

電子信箱 — cwpc@cwgv.com.tw

直接撥帳號 — 1326703-6 號 天下遠見出版股份有限公司

排版廠 — 極翔電腦排版有限公司

製版廠 — 東豪印刷事業有限公司

印刷廠 — 崇寶彩藝印刷股份有限公司

裝訂廠 — 源太裝訂實業有限公司

登記證 — 局版台業字第 2517 號

總經銷 — 大和書報圖書股份有限公司 電話／(02) 8990-2588

出版日期 — 2013 年 5 月 30 日第一版第 1 次印行

Copyright © 2013 by Viktor Mayer-Schönberger and Kenneth Cukier

Published by arrangement with Houghton Mifflin Harcourt Publishing Company

through Bardon-Chinese Media Agency

Complex Chinese translation copyright © 2013 by Commonwealth Publishing Co., Ltd.,

a member of Commonwealth Publishing Group

ALL RIGHTS RESERVED

ISBN 978-986-320-191-5 (精裝) (英文版 ISBN 978-0-544-00269-2)

定價 — 360 元

書號 — CS156

天下文化書坊 — www.bookzone.com.tw

大數據 / 麥爾荀伯格 (Viktor Mayer-Schönberger),
庫基耶 (Kenneth Cukier) 著; 林俊宏譯. — 第一
版.

-- 臺北市: 天下遠見, 2013.05

面; 公分. -- (科學文化; 156)

譯自: Big data: a revolution that will transform
how we live, work, and think

ISBN 978-986-320-191-5(精裝)

1. 資訊社會 2. 網路社會 3. 社會變遷

541.415

102008422

大數據

BIG DATA

A Revolution That Will Transform
How We Live, Work, and Think

- | | | |
|------------|------------------------------|-----|
| _01 | 現在
該讓巨量資料說話了 | 006 |
| _02 | 更多資料
「樣本＝母體」的時代來臨 | 030 |
| _03 | 雜亂
擁抱不精確，宏觀新世界 | 048 |
| _04 | 相關性
不再拘泥於因果關係 | 072 |
| _05 | 資料化
當一切成為資料，用途無窮無盡 | 104 |
| _06 | 價值
不在乎擁有，只在乎充分運用 | 138 |

_07 蘊涵	
資料價值鏈的三個環節	172

_08 風險	
巨量資料也有黑暗面	210

_09 管控	
打破巨量資料的黑盒子	238

_10 未來	
巨量資料只是工具，勿忘謙卑與人性	258

資料來源	276
------	-----

延伸閱讀	301
------	-----

謝辭	314
----	-----

大數據

「數位革命」之後，「資料革命」登場：
巨量資料掀起生活、工作和思考方式的全面革新

BIG DATA

A Revolution That Will Transform
How We Live, Work, and Think

by Viktor Mayer-Schönberger and Kenneth Cukier

林俊宏 譯

每十年，總是有極少數的書，能改變你看待一切的方式。

《大數據》正是這樣的書。

整個社會已經開始估算，巨量資料將帶來的變化。

這本書是一個非常重要的起點。

—— 萊斯格 (Lawrence Lessig)，哈佛法學院網路智慧財產權教授

《大數據》開闢了新境界，

告訴我們巨量資料如何從根本上，轉變我們對世界的基本理解……

這本書清楚說明了，企業如何釋放潛藏的價值，決策者如何因應新局，

以及每個人的認知模式需要如何改變。

—— 伊藤穰一 (Joi Ito)，麻省理工學院媒體實驗室主任

任何人如果想要保持領先地位，確定未來的商業發展趨勢，

都必須閱讀《大數據》。

—— 貝尼奧夫 (Marc Benioff)，salesforce.com 董事長兼執行長

《大數據》很樂觀而務實的看待巨量資料革命——

你只要伸頭看看周遭發生的大變化，就會明白這場革命已然開始了，

更大的變化即將衝擊而來。

—— 多克托羅 (Cory Doctorow)，boingboing.com

我們敢肯定的是，

《大數據》將是在討論這方面的未來時，一言九鼎的文本。

—— 富比士網站

有太多書籍在頌揚資訊社會的技術奇蹟，

但是唯有這本《大數據》對資訊的本質，進行了原創的分析。

—— 《柯克斯書評》(Kirkus Reviews)

這本書充滿了偉大的見解、駕馭資訊的新途徑，
並且對於未來趨勢，提供了很有說服力的願景，
這是任何使用巨量資料的人、或受到巨量資料影響的人，
都不可或缺的讀物。

—— 喬納斯 (Jeff Jonas)，IBM 首席科學家

這本出色耀眼的書，撥開了圍繞在巨量資料周邊的迷霧。
不論你從事的是商業、資訊科技、公共行政、教育、醫療，
或者你只是單純對未來趨勢感到好奇，都必須閱讀這本《大數據》。

—— 布朗 (John Seely Brown)，全錄帕羅奧圖研究中心主任

正如水是濕滑的，然而單個水分子卻不是；
巨量資料也能顯現個別資料無法揭露的訊息。
作者向我們展示了龐大、複雜、凌亂的資料，若是集合起來，
竟能用來預測購物行為、流感爆發……的一切模式，真是令人驚駭。

—— 薛奇 (Clay Shirky)，社會媒體理論家

作者讓「巨量資料」這個名詞的內涵變得非常清晰，
這個名詞的重要性已遠遠超過矽谷的其他流行語彙……
沒有哪一本書能夠提供這樣的可讀性和平衡報導，
告訴我們繼續迷戀數據和資料的諸多好處及缺點。

—— 《華爾街日報》

「巨量資料」是企業管理階層、技術官僚的流行語之一，
如果你想知道他們都在談論些什麼，那麼《大數據》正是為你而寫的。
這本書深入淺出、而且很有意思的切入這個大題目……

—— 《波士頓環球報》

大數據

BIG DATA

A Revolution That Will Transform
How We Live, Work, and Think

- | | | |
|------------|------------------------------|-----|
| _01 | 現在
該讓巨量資料說話了 | 006 |
| _02 | 更多資料
「樣本＝母體」的時代來臨 | 030 |
| _03 | 雜亂
擁抱不精確，宏觀新世界 | 048 |
| _04 | 相關性
不再拘泥於因果關係 | 072 |
| _05 | 資料化
當一切成為資料，用途無窮無盡 | 104 |
| _06 | 價值
不在乎擁有，只在乎充分運用 | 138 |

_07 蘊涵	
資料價值鏈的三個環節	172

_08 風險	
巨量資料也有黑暗面	210

_09 管控	
打破巨量資料的黑盒子	238

_10 未來	
巨量資料只是工具，勿忘謙卑與人性	258

資料來源	276
------	-----

延伸閱讀	301
------	-----

謝辭	314
----	-----

NOW



第 1 章

現在 該讓巨量資料說話了

2009年又冒出了一種新的流感病毒，稱為H1N1。這種新菌株結合了禽流感和豬流感病毒，迅速蔓延。短短幾星期內，全球的公共衛生機構都憂心忡忡，擔心即將爆發流感大流行。有些人發出警訊，認為這次爆發可能與1918年的西班牙流感不相上下，當時感染人數達到五億人，最後奪走數千萬人的性命。雪上加霜的是，面對流感可能爆發，卻還沒有能派上用場的疫苗，公共衛生當局唯一能努力的，就是減緩流感蔓延的速度。為了達到這項目的，必須先知道當前流行感染的範圍及程度。

在美國，疾病管制局（CDC）要求醫生一碰到新流感病例，就必須立刻通報。即使如此，通報的速度仍總是慢了病毒一步，大約是慢上一到兩星期。畢竟，民眾覺得身體不舒服之後，通常還是會過個幾天才就醫，而層層通報回到疾管局也需要時間，更別提疾管局要每星期才整理一次通報來的資料。但是面對迅速蔓延的疫情，拖個兩星期簡直就像是拖了一個世紀，會在最關鍵的時刻，讓公共衛生當局完全無法掌握真實情況。

巨量資料初試啼聲

說巧不巧，就在H1N1躍上新聞頭條的幾星期前，網路巨擘谷歌（Google）旗下的幾位工程師，在著名的《自然》科學期刊發表了一篇重要的論文，當時並未引起一般人的注意，只在衛生當局和電腦科學圈裡引起討論。該篇論文解釋了谷歌能如何「預測」美國在冬天即將爆發流感，甚至還能精準定位到是哪些州。谷歌

的祕訣，就是看看民眾在網路上搜尋些什麼。由於谷歌每天會接收到超過三十億筆的搜尋，而且會把它們全部儲存起來，那就會有大量的資料得以運用。

谷歌先挑出美國人最常使用的前五千萬個搜尋字眼，再與美國疾病管制局在2003年到2008年之間的流感傳播資料，加以比對。谷歌的想法，是想靠著民眾在網路上搜尋什麼關鍵詞，找出那些感染了流感的人。雖然也曾有人就網路搜尋字眼做過類似的努力，但是從來沒人能像谷歌一樣掌握巨量資料（big data，直譯為大數據），並具備強大的處理能力和在統計上的專業技能。

雖然谷歌已經猜到，民眾的搜尋字眼可能與流感有關聯，像是「止咳退燒」，但有沒有因果關係並不是真正的重點，他們設計的系統也不是從這個角度出發。谷歌這套系統真正做的，是要針對搜尋字眼的搜尋頻率，找出和流感傳播的時間、地區，有沒有統計上的相關性（correlation）。他們總共用上了高達四億五千萬種不同的數學模型，測試各種搜尋字眼，再與疾管局在2007年與2008年的實際流感病例加以比較。他們可挖到寶了！這套軟體找出了一組共四十五個搜尋字眼，放進數學模型之後，預測結果會與官方公布的全美真實資料十分符合，有強烈的相關性。於是，他們就像疾管局一樣能夠掌握流感疫情，但可不是一、兩星期之後的事，而是幾近即時同步的掌握！

因此，在2009年發生H1N1危機的時候，比起政府手中的資料（以及無可避免的通報延遲），谷歌系統能提供更多、更即時的資訊。公衛當局有了這種寶貴的資訊，控制疫情如虎添翼。

最驚人的是，谷歌的這套方法並不需要去採集檢體、也不用登門造訪各家醫院診所，而只是好好利用了巨量資料，也就是用全新的方式來使用資訊，以取得實用且價值非凡的見解、商機或服務。有了谷歌這套系統，下次爆發流感的時候，全球就有了更佳的工具能夠加以預測，並防止疫情蔓延。

巨量資料功能強大，可以讓許多領域改頭換面，公共衛生領域不過是其中之一，而商業領域也正在經歷這個過程。例如買飛機票就是一個很好的例子。

2003年，伊茲奧尼（Oren Etzioni）打算從西雅圖飛往洛杉磯參加弟弟的婚禮。早在幾個月前，他就已經上網買了機票，一心認為愈早預訂，票價就愈划算。但是在航程中，他出於好奇，問了坐在隔壁的乘客票價以及購票時間，結果那個人明明是最近才買的，票價卻是便宜得多。一氣之下，伊茲奧尼一個又一個的問下去，發現大部分人的票價都比他的更便宜。

對於大多數人來說，等到收回托盤、豎直椅背、準備下機的時候，這種覺得被敲竹槓的火氣，也差不多消了。但伊茲奧尼身為美國頂尖的資訊科學家，可沒這麼好打發。在他看來，整個世界就是由一連串關於巨量資料的問題構成的，而這正是他拿手的領域。追溯到1986年，伊茲奧尼可是哈佛大學第一位主修資訊科學的畢業生，之後進入華盛頓大學任教；而且早在巨量資料這個詞出現之前，他就已經開了數家處理巨量資料的公司。例如，他曾協助打造了最早期的網路搜尋引擎之一、於1994年推出的MetaCrawler，不久便由當時的網路巨擘InfoSpace公司買下。另

外，他也共同創立了史上第一個大型比價購物網站Netbot，後來出售給Excite公司。至於他的另一間公司ClearForest，則是處理如何從文件中取得語義資訊，後來由路透社收購。

客機著陸之後，伊茲奧尼已經下定決心，要讓人能夠知道自己在網上看到的票價，究竟是撿到便宜還是被人坑了。如果把飛機機位看成商品，同一航班的座位基本上也沒什麼不同，但票價卻是天差地別。這裡有許多因素，只有航空公司自己才曉得。

伊茲奧尼認為，這種系統並不需要真的去解出票價背後千絲萬縷的糾纏因素，只要能預測出未來票價是漲是跌就夠了。這其實不困難，只要先取得特定航線售出的所有票價資訊，再與出發前的天數做比較即可。

如果平均票價呈現下跌趨勢，買票這件事當然就可慢慢來。如果平均價格呈現上漲趨勢，系統則會建議馬上以目前顯示的價格購票。換句話說，當初伊茲奧尼是在一萬公尺高空中，逐一詢問其他乘客的票價，而現在這個系統就是個加強版。雖然說這絕對還是一個資訊工程的龐大問題，但與過去相同，這對他而言仍然能夠迎刃而解。於是，他動工了。

伊茲奧尼花了四十一天，從某個旅遊網站取得超過一萬兩千筆票價資料，做為樣本，並建立一個預測模型，讓模擬的乘客都省下了大筆鈔票。這個模型並不懂「為何如此」(why)，只知道「正是如此」(what)。換言之，模型完全不知道各種影響票價的因素，像是未售出的機位數、淡旺季、或是星期幾的機票較便宜之類；模型所做的預測，都是基於手中確實的資訊，也就是從其他

航班所蒐集到的相關資料。

伊茲奧尼思思念念的，就是「要買還是不買」的問題——像極了莎翁名劇《哈姆雷特》的經典獨白：「生存還是毀滅，這是一個值得考慮的問題。」正因如此，伊茲奧尼把這個研究計畫命名為「哈姆雷特」。

原本的小小研究計畫，後來發展成投入大量資金的創業計畫「Farecast」，藉著預測機票票價可能上漲或是下跌，Farecast就能讓消費者知道是否該立刻點選「購買」鍵。在過去，消費者從來不可能得知這些資訊。Farecast堅持一切應該透明，所以甚至還會對自己的預測加上可信度評分，提供給使用者參考。

預測系統要有效，就必須擁有大量的數據資料。為了提升效能，伊茲奧尼從航空業的一個航班預訂資料庫下手。資料庫存有全年美國商業航空公司各航班、各座位的資料，能做為系統預測的基礎。現在，Farecast手中大約有近兩千億筆票價紀錄，用以做出預測。如此一來，消費者就能省下大筆的金錢。

伊茲奧尼有一頭黃褐色的頭髮，露齒微笑、一臉天真，看起來實在不像是會讓航空業損失數百萬美元潛在收入的人。但事實上，他的目標還不止於此。

到了2008年，伊茲奧尼打算將這套辦法再應用到其他商品，像是飯店客房、音樂會門票、二手車，只要是產品差異性小、價格變化大、而且有大量數據資料的商品，都能適用。但他還沒來得及讓計畫成真，微軟就已經找上門，用大約一億一千萬美元買下Farecast，結合到Bing搜尋引擎之中。到了2012年，該系統平均

有75%的預測準確率，讓每位旅客省下五十美元。

Farecast正是一個巨量資料公司的縮影，也是世界未來的走向。如果是五年或十年前，伊茲奧尼絕不可能建立起這種公司。他說：「這本來是不可能的任務，」所需要的計算能力和儲存容量都還太過昂貴。然而，讓計畫成真的原因當中，雖然科技進展是關鍵因素，但還有一個更微小、卻更重要的因素，就是關於該如何使用資料的思維，已經有所改變。

過去認為資料是靜態、靜止的，一旦完成原本蒐集的目的（例如飛機已降落、或在谷歌網頁完成了一次搜尋），便不再有用處。但是現在，資料是新的商業生產原料、重要的經濟資源投入，可以創造出新形式的經濟價值。如果心態和思維正確，就能巧妙重複運用資料，不斷帶來創新和不同的服務。只要夠謙卑、有意願、也有工具可傾聽，資料就能讓種種祕密躍然眼前。

讓巨量資料說話

不論是每個人口袋裡的手機、背著到處走的電腦、又或是辦公室所使用的伺服器系統，都是資訊社會明顯而豐碩的果實。但相較之下，「資訊」本身就不那麼引人注意。自從電腦在半世紀前進入主流社會以來，累積的資料已經到了一定程度，開始帶來全新而特殊的改變。現在，世界上不僅是資訊量前所未見，資訊成長的速度更是一日千里。規模的改變已經開始導致狀態的改變；換句話說，就是從量變引發了質變。譬如天文學、基因組學之類