

# 人體姿勢偵測系統與無監督辨識學習

## A Sensing System of Human Postures and Its Unsupervised Learning of Pattern Recognitions

黃信哲、陳健章、郭博昭、盧鴻興

Shen-Jhe Haung, Chien-Chang Chen, Terry B. J. Kuo, Henry Horng-Shing Lu

本文介紹一種穿戴式生理訊號偵測系統與相應的無監督學習分析技術。硬體設計方面採取三軸重力加速度感測器搭配神農無線藍芽傳輸模組。分析技術則採取量子力學中的密度泛函理論，使得數據中各特徵間的邊界以及數據群數能被同時決定。本技術針對長期實驗可用以偵測與分析人體姿體與各式時序生醫訊號的改變與關聯性。短期實驗可用以意外事故肇因分析以及警訊通知。除可節省大量人力資源與數據儲存空間的佔用，同時具備更高的可信度與客觀性，乃至於爾後的技術商業化。

The article proposes a wearable physiological signal sensing system associated with an unsupervised learning technique. The hardware mainly includes a three-axis accelerometer and a XenonBlue wireless transmission module. Then the framework of density functional theory of the quantum mechanics was employed to extract the cluster boundaries of datasets and their corresponding cluster numbers. The proposed system provides requiring detections and correlation analyses between the changing human postures and the time-dependent biomedical signals for the long-term experiments. The technique also can be used for real-time detections and analyses for accident circumstances and then dangerous alarms. In a nutshell, the system not only provides highly plausibility and objectivity but also reinforces the commercialization.

### 一、跨學科的生醫數據工程

#### 1. 從量子力學看資料科學

由於各類智慧型消費電子帶動了使用者對於個人生理特徵儲存與雲端分析的訴求，使得大數據 (big data) 資料科學這一學門即刻獲得各領域的科學家深入研究以及企業主們的青睞。此領域隨即於 2012 年由美國總統歐巴馬宣布成為美國國家重點科學發展項目之一<sup>(1)</sup>。因此，由於種種關於「大數據」分析技術的初期成功發展，在商業、經濟、

醫學及其他領域中的各種決策方法將依賴於資料數據的統計學習結果而論定，而非以往的傳統人為經驗或直覺。亦由於各種無可避免的人類活動所產生的大量資訊，此類大數據分析技術隨即於全球各領域旋起一股資料科學研究與商業活動的熱潮<sup>(2)</sup>，並且已在許多領域中有所發揮，例如天文學、大氣學、雲端分析<sup>(3)</sup>、基因組學與生物學<sup>(4-8)</sup>、通訊記錄與社群網路<sup>(6, 9-11)</sup>、通勤時間預測、個人醫療記錄、生醫圖像和影像分析<sup>(12-16)</sup>、大規模的電子商務<sup>(17-18)</sup>等。因此，各種資料探勘 (data mining)

的方法乃至於資料特徵的選定與擷取 (model selection and feature extraction)、資料結構的再造 (reconstruction)、資料分群或分類 (data clustering or classification)、模態辨識 (pattern recognition) 等重要的資料科學處理技術，便開始從單純的學術活動衍變為種種商業決策方面的應用。簡言之，身處於技術飛揚的大數據時代中，最主要的資料科學核心價值便在於如何使得隱寓於數據內部的種種極具價值的資料特徵，能以最直覺且最具效率的方法引薦而出以提供最適當的決策表現。

有趣的是，科學家們早已於一個世紀前的材料科學問題以及複雜物理系統中面臨到了與資料科學相同的情境。雖然當代的物理與化學理論以及相依的輔助計算技術能力與日俱增，但為了能夠處理材料或高分子化合物中數量龐大的粒子交互作用，目前的科學家們依然煞費苦心。舉一簡單實例，在一個物理系統中描述  $N$  顆粒子之間的交互作用時，物理學家或是量子化學家過往慣於使用  $N$  粒子的薛丁格波動方程式 ( $N$ -particle Schrödinger wave functions)。然而當粒子數量超過  $10^3$  之後，除了計算複雜度大幅增加之外，連同薛丁格波動方程式的合理性亦備受考驗<sup>(19)</sup>。為了克服如此困境，一種以系統電子機率密度函數為核心來取代多電子間的薛丁格波動方程式的理論架構便孕育而生。這項被稱作密度泛函理論 (density functional theory, DFT) 的物理架構，奠基在電子系統的巨觀處理概念上。這個精巧的 DFT 方法是將問題的核心投射於處理系統的 3 維電子機率密度函數方面，並以此取代傳統上的  $3N$  維薛丁格波動方程式，因此大幅降低了系統的計算複雜度並能獲得較佳的計算精度<sup>(20, 21)</sup>。於此便利之下，DFT 方法很快便深植於各科學領域，如量子化學、固態物理、材料科學，甚至是分子動力理論之中<sup>(22-28)</sup>。換言之，對於一個研究中的系統之物理架構以及其內在特徵，DFT 方法的理論架構實踐了以低維度電子機率密度函數 (probability density function, PDF) 為探子，來取代超高維度多粒子系統波函數的複雜計算<sup>(27-29)</sup>。總論上述，一旦系統內詳實的電子 PDF 被獲得，則理論上該系統中所有資訊皆得以被外界測量並分析。因此，在研究大規模尺寸的資料系統 (large-scale

data system) 方面，DFT 方法的數學框架在此處可展現出高度有利的適用性和兼容性。

## 2. 生醫工程內的資料工程

舉凡如心電圖、腦電圖、心搏與血壓等各項重要生理訊號，以及個人臉譜、指紋、視網膜、DNA 譜與血管神經拓樸等個人生物特徵，在長時間自動監測與資料庫蒐集的需求下，其龐大資訊的儲存技術以及不同資料結構之間的締合、群集、再構與分析，在在都突顯了大數據分析技術對於人類生活乃至於轉譯醫學領域的不可或缺。而無論科學研究的探索或是商業策略的執行，在非侵入式的前提下人類各項生物訊號與特徵，皆需由外部的傳感器與其相應的 CMOS 輔助電路系統、演算法來執行偵測或刺激的任務。因此，除了資料科學分析技術的提升外，其傳感器系統的動態物理行為與演算法之間的互相搭配亦逐漸成為現代轉譯醫學領域不可缺少的技術之一。

以偵測人體姿態改變為目的，本研究中所採用的傳感器設計為陽明大學腦科學轉譯研究室所研發之三軸重力加速度感測器 (gravity sensor/accelerometer)，如圖 1(a) 所示。該感測器長僅 4 公分、重約 7 克，且能分別針對三個不同方向的加速度分量變化進行感測與紀錄，每一秒鐘單軸可測得 50 個數據資料點。該技術配合神農無線藍芽傳輸技術 (bluetooth 4.0)，將數據藉由雲端服務平台傳輸到個人化智慧型電子設備，因此可使得偵測儀器變得非常精巧簡便與生活化。實驗方法是將加速度感測器以 XY 軸為平面並以正 Z 軸方向為軸垂直黏貼在人體胸口上，利用睡姿翻身或坐起的姿態改變造成三軸的重力加速度分量與瞬間加速度分量的變化，而產生不同偵測數據量，如圖 1(b) 所示。為使實驗目的與分析技術易於了解，本研究內容將專注於人體睡姿改變的偵測與機械學習分析方法之闡述。為與上述物理感測器完美融合，演算法方面採取了物理領域中 DFT 方法的數學框架。

醫學訊號的特徵分析對於精準預防醫學以及臨床診斷治療而言是相當重要且必須的輔助工具。對於動態生理訊號例如睡眠時期的腦波頻段與週期、心跳頻率、呼吸狀況的紀錄與分析在近年來出現許

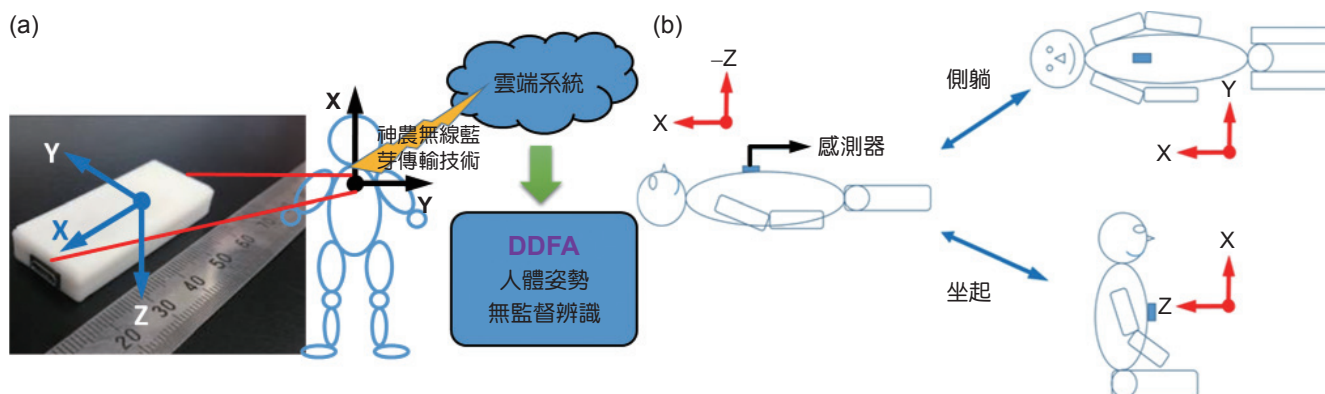


圖 1. 陽明大學腦科學轉譯研究室研發之三軸重力加速度感測器外觀 (最大尺寸僅 4 公分、重約 7 克)，以及實驗配置方法與實驗流程。

多前瞻性的實驗開發與研究報告<sup>(30-31)</sup>。但對於成眠後的姿態改變、翻身幅度與其頻率狀況的紀錄卻非常少見，原因在於該研究方法大多採攝影機直接進行整晚睡眠狀況攝影或利用大型壓力感測床紀錄睡姿，並由研究人員主觀進行觀察與睡眠品質分析。如此研究方法不僅容易造成巨大的分析資料量且耗費過多人力資源，同時必須仰賴極具專業的分析才能獲得有價值的研究結果與發展。因此，為提升篩測效率以及正確率以降低診斷工作量與風險，提出一種可輔助當代醫學訊號監測儀器的醫學訊號特徵辨識無監督學習方法是當務之急。

在醫學訊號特徵分析處理方面，當代主要的大數據分析方法大致可歸類在以統計計算為基底的機械學習 (machine learning) 方法與圖論網絡 (graph theory and network) 的互相結合：機率論與資料特徵或是拓樸結構的揉合<sup>(32-42)</sup>。因此大抵以網路分群 (network clustering) 或是決策樹 (decision tree) 為主要分析結果的呈現方法。然而對於初探此領域的醫師及轉譯科學家而言，如何正確的在以「具有充分的領域知識」的前提下使用符合該特殊資料結構的分群方法實如大海撈針。此外，以機械學習為基底的演算法在實用上往往也需要諸多先決條件，例如：必須事先準備用於建構模型的資料集 (training sets)<sup>(32)</sup> 或種子集 (seeding sets)<sup>(35, 43-45)</sup>、先驗的特殊幾何結構 (prior regular curve or shape)<sup>(32, 34-36, 39-42)</sup>，以及特定的資料長度<sup>(40)</sup> 等。一旦這些無法避免的先決條件最終成為資料分析時不可或缺的一部分，

則使用者的監督干預 (user-supervised interventions) 以及複雜的過濾／分類機制 (filtering/classifying mechanisms) 可能造成該演算法在不規則或意料之外的使用情況中更加的不穩定。有鑑於此，以輔助醫學診斷儀器為前提，本文提出了可適用於動態資料結構的大數據分析方法論：資料密度泛函演算法 (data density functional algorithm, DDFA)。

本演算法僅利用基本物理的能量轉換法則，將嵌入希爾伯特空間 (Hilbert space) 內的資料數據點視為「類物理粒子」分析，即可呈現適用於任何醫學資料結構的無參數－非監督式 (nonparametric and unsupervised) 的高維度數據分析方法。值得強調，本分群過程之中不需要額外的數值迭代，因此擁有快速且高效率之運算特性。以下將以本文提出的穿戴式生醫電子系統結合機械學習分析技術，說明本方法的理論架構以及臨床醫療器材輔助上的實質效能。

## 二、理論方法與實驗架構

### 1. DDFA 的理論基礎

DDFA 架構於量子力學的密度泛函理論之下，可將任意高維度的問題降為到只有若干個主要維度結構，因此大幅簡化了系統的計算複雜度以及提升了可靠度與效率。為了將此優勢運用在任何的資料結構上，資料的特徵與性質需預作處理。理論證明，僅要資料依存的空間可被映射到有向黎曼流形

(oriented Riemannian manifold) 內，則此資料結構是被允許在密度泛函理論的架構下被分析。而無法被映射的資料結構則需先映射到虛擬的 Hilbert 向量空間再映射至有向黎曼流形內。相關映射理論與技術業已建立完備<sup>(43, 44, 46)</sup>。

對於目前的醫學訊號特徵分析問題，可先行導入軟凝態物理中局域密度近似方法 (local density approximation, LDA)<sup>(47, 48)</sup> 的數學架構於 DDFA 方法中，即將訊號資料映射至  $D$  維的能量空間中：

$$t_s[I] = \frac{2\pi^2}{D+2} \cdot D^{(D+2)/D} \cdot I^{2/D} \quad (1)$$

以及

$$u[I] = \frac{1}{2} \int \frac{I(x')}{|x'' - x'|} d^D x' \quad (2)$$

其中以上兩式分別為資料的局域動能密度泛函  $t_s[I]$  與局域位能密度泛函  $u[I]$ 。 $x'$  與  $x''$  分別為資料點座標以及觀察點座標。可發現  $t_s[I]$  與  $u[I]$  皆與資料機率密度函數  $I(x')$  成正比，同時  $u[I]$  與兩點間距離 (即  $|x'' - x'|$ ) 成反比。且由方程式 (2) 可得， $u[I]$  的行為如同  $I(x')$  與  $1/|x'' - x'|$  之

折積 (convolution)。因此在機械學習領域上可推斷， $t_s[I]$  描述了資料單群相較其他群的顯著性 (significance)，而  $u[I]$  則與資料各群之間的相似性 (similarity) 密切相關。同時藉由考量此兩者之物理性質，可衍伸計算該資料系統的拉氏密度泛函 (Lagrangian density functional, LDF) 來尋找資料群的邊界以及用以度量資料中心度 (centrality) 的系統總能密度 (Hamiltonian density functional, HDF)。 $LDF$  與  $HDF$  的理論方程分別為：

$$LDF = \gamma^2 t_s[I](\gamma x') - \gamma u[I](\gamma x') \quad (3)$$

以及

$$HDF = \gamma^2 t_s[I](\gamma x') + \gamma u[I](\gamma x') \quad (4)$$

其中  $\gamma$  為系統自適應調節參數，完全由系統特徵自動決定：

$$\gamma = \frac{1}{2} \frac{\langle u[I](\gamma x') \rangle}{\langle t_s[I](\gamma x') \rangle} \quad (5)$$

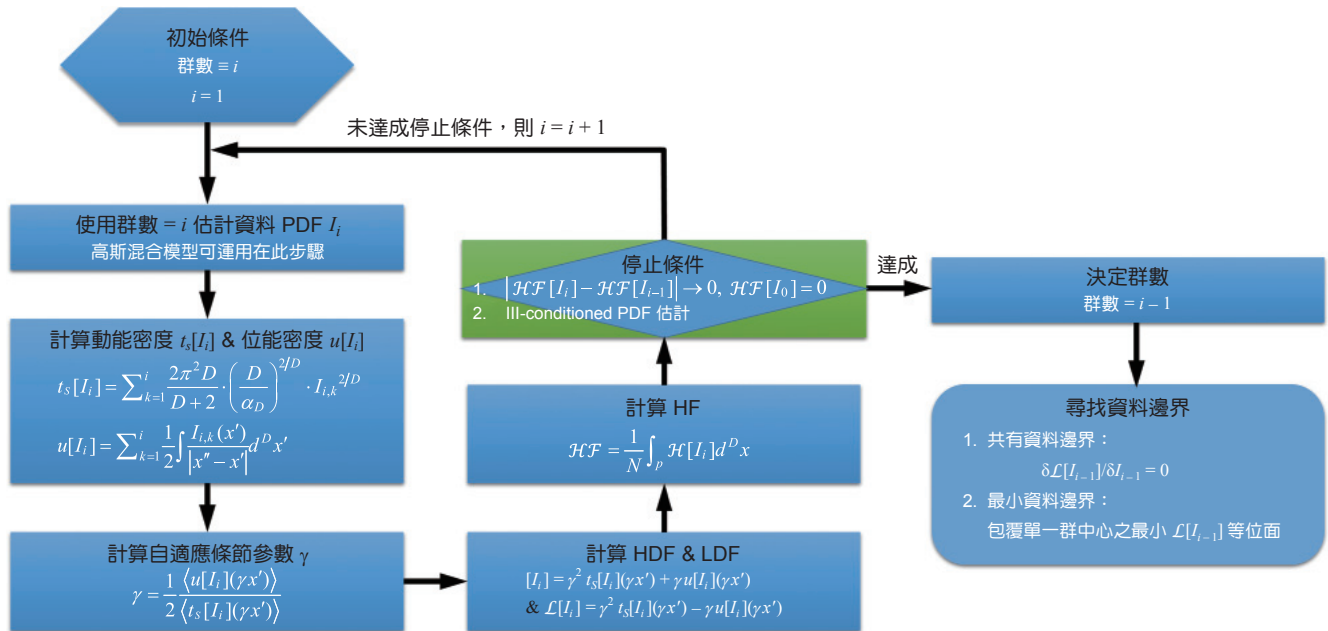


圖 2. DDFA 演算法程序，其中說明了空間散佈型資料結構群數與資料邊界的無監督搜尋演算法。值得強調本演算法不需要傳統的數值疊代或是嘗試錯誤方法。

式中的  $\langle u[I](\gamma x') \rangle$  以及  $\langle t_s[I](\gamma x') \rangle$  分別為系統的位能以及動能密度總和的平均值。相關的 DDFA 演算法步驟如圖 2 所示，其中展示了非監督搜尋數據群數與邊界的方法。值得強調，本演算法不需要傳統的數值疊代或是嘗試錯誤方法。圖 3 展示了二維任意混合資料分布的 DDFA 執行概念：(a) 與 (b) 分別為任意兩群不同強度混合的資料動能密度與位能密度的強度圖形，而 (c) 則為經由 DDFA 計算後得出的資料系統 LDF。由 (c) 可知資料 LDF 可提

供相當明顯的資料邊界 (如圖箭頭所示)，同時各資料群的峰型亦可獲得強烈的塑形。因此本方法可同時提供資料群的邊界與群數之重要特徵訊息。

## 2. 視覺化演算法：群邊界與群數測量

圖 4 為圖 3 實作之二維範例：模擬資料群 (共兩群如左上圖) 可在能量空間中表現出其對應的資料動能密度 (significance)、庫倫形式位能密度 (similarity)，以及該資料系統之總能密

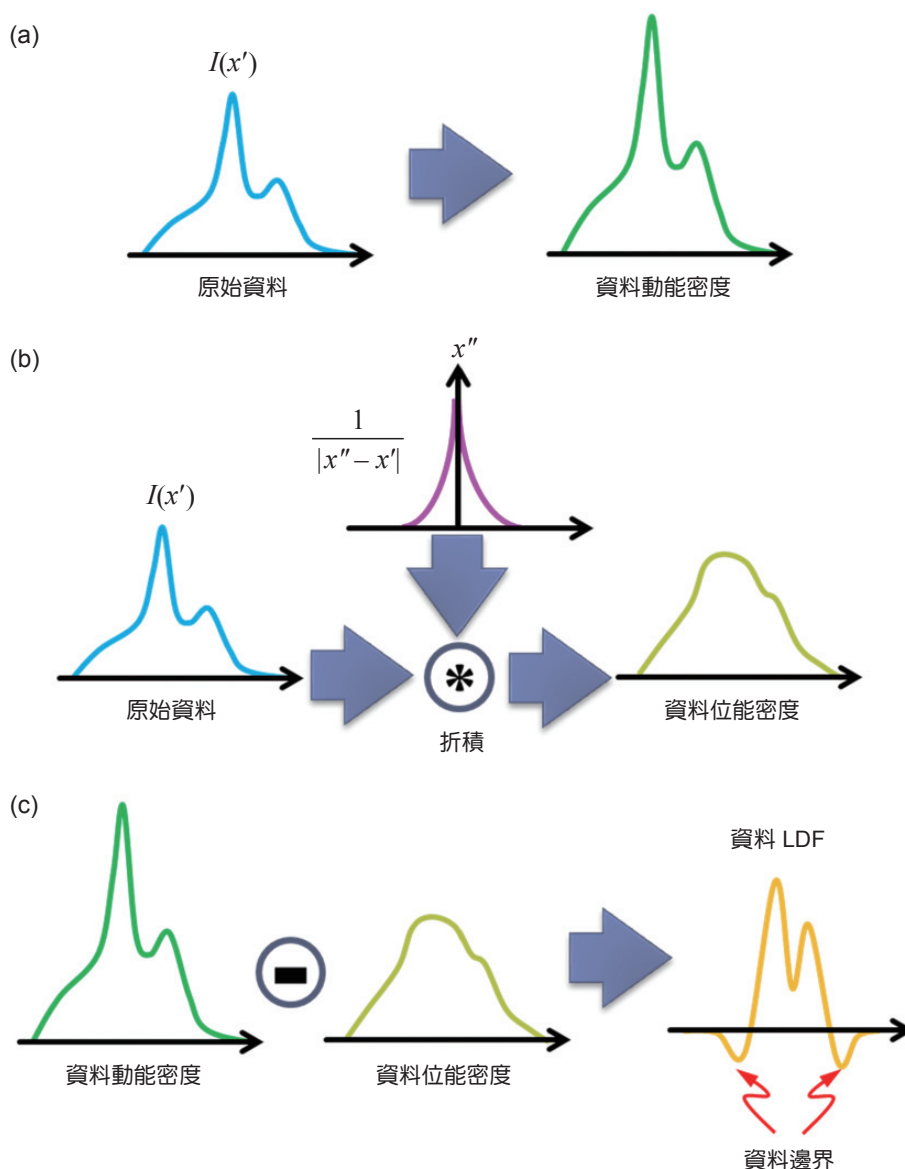


圖 3. 二維任意混合資料分布的 DDFA 執行成果。(a) 與 (b) 分別為任意兩群不同強度混合的資料動能密度與位能密度的強度圖形，而 (c) 則為經由 DDFA 計算後得出的資料系統 LDF。

度 (centrality)。該模擬資料群由高斯混合模型 (Gaussian mixture model, GMM) 技術給出，因此各群的資料 PDF 為已知。必須特別說明資料 LDF 的奇特性質：紅色虛線中所截取的 Lagrangian 作用量密度量測如其右下的插圖所示，可發現兩個作用量峰之間有個小突起。其定性的物理意義為該兩群資料 (如真實資料散佈圖所示) 若欲合併所必須先行克服的能量障礙，且該能障高度可藉由 Lagrangian 密度的形態拓樸圖做定量計算。在醫學訊號特徵分析的應用上，便可以使用訊號 LDF 的各個構件之間的能障高度作為各構件之間的數據邊界，以達成特徵辨識與分群的目的。

圖 5 模擬圖 4 中兩群資料持續相互靠近下的數據群遷移狀況，其中使用了圖 2 所示的無監督搜尋演算法來測量系統中的群數。測量群數時使用了搜尋系統能量最穩定值作為該系統中最可能群數之表

徵，其系統能量方程式如下：

$$\mathcal{H}\mathcal{F} = \gamma^2 \langle tS[I] \rangle + \gamma \langle u[I] \rangle \quad (6)$$

各群之間間距使用標準差  $\sigma$  估計之，而各群之間距變化以及測量獲得的  $\mathcal{H}\mathcal{F}$  曲線分別如圖 5(a) 所繪。由圖可知，無論群間距離如何縮減， $\mathcal{H}\mathcal{F}$  曲線轉折後的穩定位置皆表徵該數據群數為 2 群 (如紅色點狀箭頭所標示)。圖 5(b) 則描繪了各群變動時的 LDF 型態，其中的黑色標記為使用 GMM 方法所估計之群中心。如圖 3 中所提出的 LDF 辨識特徵，當兩群資料間距約為  $1\sigma$  時，群外依然有兩處殘留邊界 (如圖 5(b) 紅色箭頭)。意指當此兩群數據因不斷接近而混合前，該處曾有兩群資料具有獨立的數據邊界。由殘留的數據邊界數量可知該混合群中原有兩群獨立的數據集。

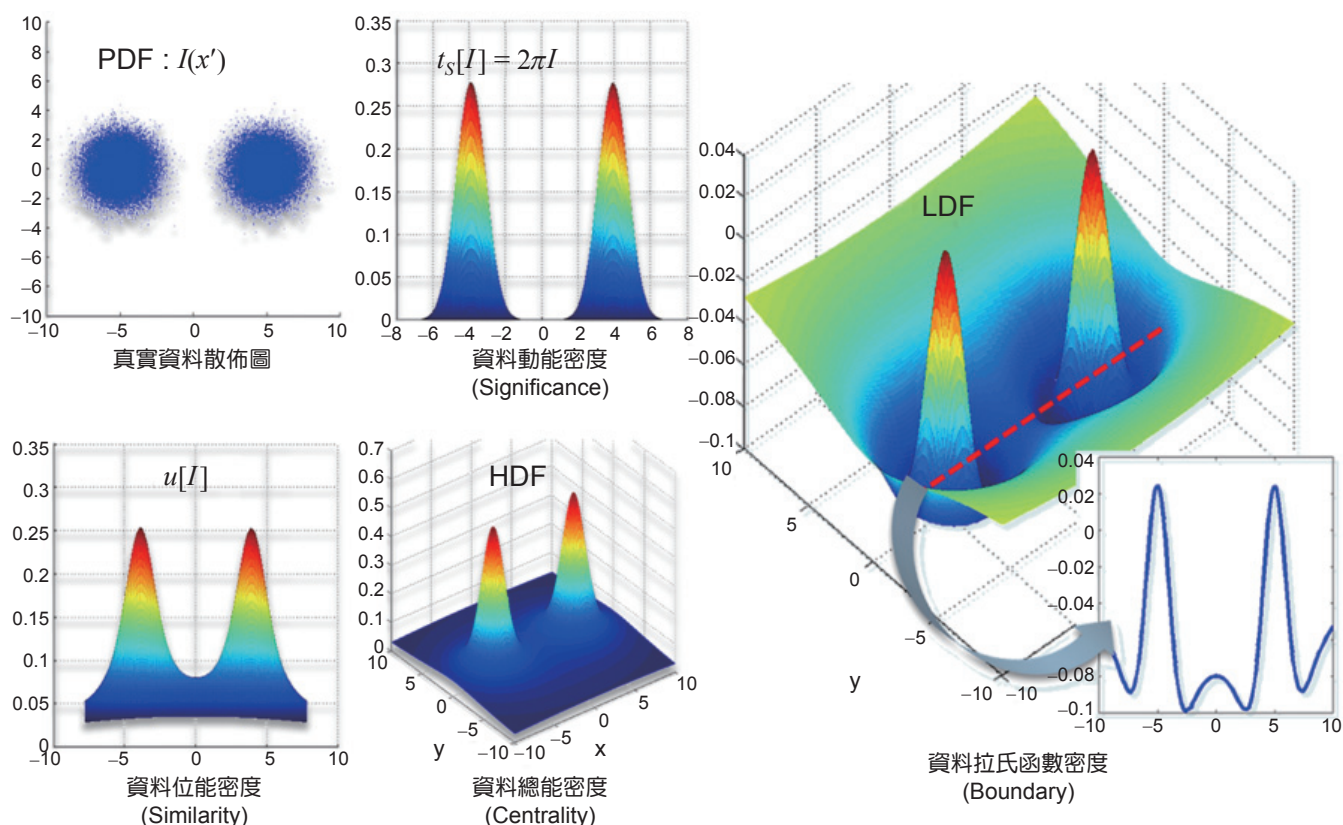


圖 4. 二維資料結構的能量結構型態拓樸。LDF 圖中的紅色虛線所截取的投射範圍如其下的插圖所示，可發現該兩個作用量峰之間有個小突起。其定性的物理意義為兩群資料 (如真實資料散佈圖所示) 若欲合併所必須先行克服的能障，且該能障高度可藉由 LDF 的形態拓樸圖做定量計算。

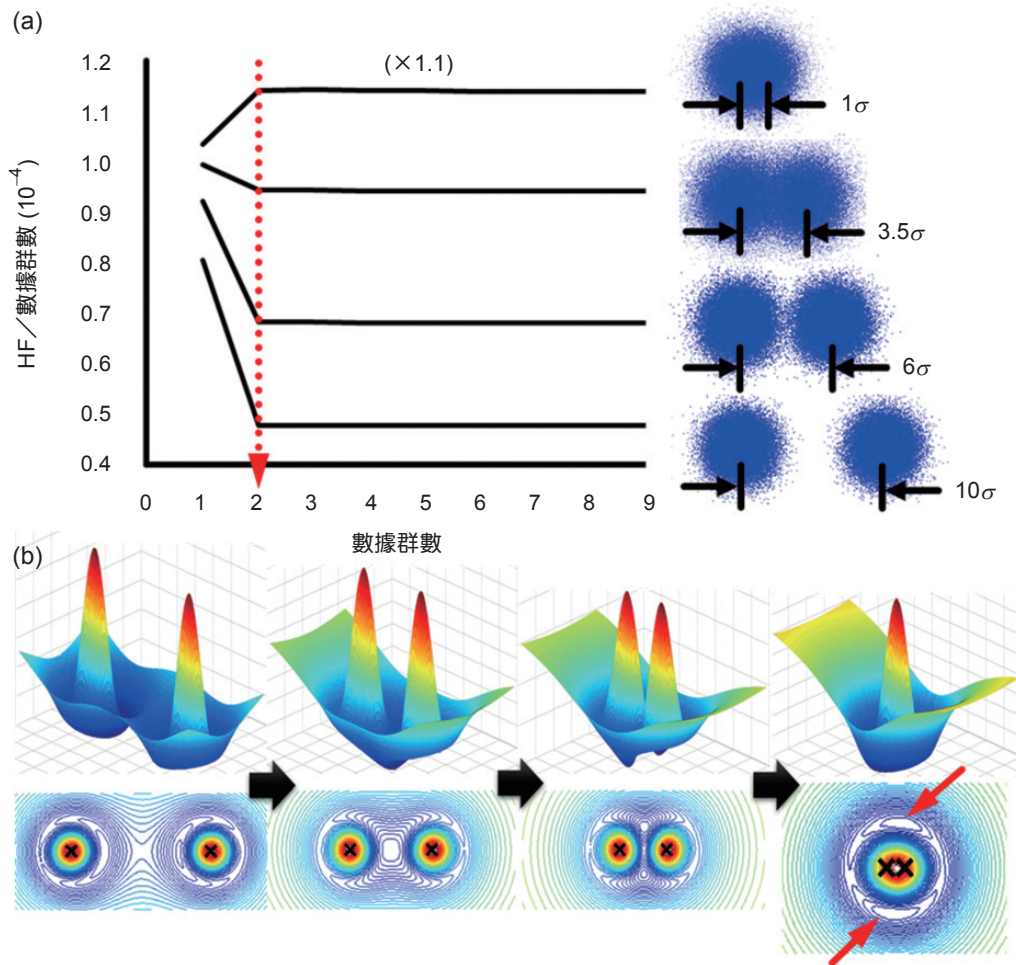


圖 5. 圖 (a) 描繪當兩群資料由間距  $10\sigma$  相互靠近至  $1\sigma$  時的資料散佈圖形以及各階段下所測量的數據群數。由圖可知所提出的非監督演算法可以能量穩定的概念來測量最可能的數據群數，其量測的最佳數據群數為 2 群，如紅色點狀箭頭所標註。圖 (b) 則為各階段的 LDF 型態圖，圖中的黑色標記為 GMM 方法所估計之群中心位置，紅色箭頭則標明殘留的資料邊界。由殘留的資料數量可知該混合群中原有兩群數據集。

簡言之，本文中演算法建立的進行步驟為：  
 (1) 將資料結構的特徵空間投射至有向黎曼流形中 (或等效之 Hilbert space)。一般而言，由目前造影技術所呈現之醫學影像以及各類型的生理訊號，皆可直接投射至 Hilbert space 之中。  
 (2) 使用方程式(1)–(6) 計算醫學訊號特徵的各種能量狀態，演算法步驟如圖 2 所示。  
 (3) 計算系統的總能密度 HF 可獲得訊號特徵組成的數量，以及計算系統的拉氏密度 LDF 可獲得各特徵組成之間的邊界。值得強

調，相較於傳統方法本演算法擁有以下優勢：  
 (1) 無須使用傳統的迭代計算方法；  
 (2) 解析方程式構造簡單，如方程式 (1)–(6)，程式編碼簡易；  
 (3) 可將任意高維度資料結構降成 2 維或 3 維的可視覺化圖像；  
 (4) 可與任何當代的機械學習或是影像分析技術搭配使用。因此本方法除了計算速度將優於傳統技術之外，更被賦予高效率、高精確率以及可與其他技術混成的彈性。

### 三、人體姿勢的無監督模態識別

初步實驗中使用單顆三軸加速度感測器進行平躺和側翻之間動作改變的測試，其中圖 6 為紀錄之各軸運動量數據與時間關係。實驗方法為受試者平躺至測試台上，以四十秒 (另一組為二十秒) 為週期側翻再躺回原位。由圖 6 可知：X 軸方向上變化相較於其它兩軸較為微弱，主因在於該軸與實驗對象中心軸同向所致，也就是 X 軸的方向 (頭頂方向) 隨著人體平躺與側翻兩種姿態的動作改變，並沒有太大的加速度分量改變。同時，雖側轉圖形於實驗中為已知參數 ((a)、(b)、(c) 圖為向右翻，(d)、(e)、(f) 圖為向左翻)，但為檢驗所提出無監督姿勢辨別方法之成效，故此列參數將交由演算法自行判定，而不列入已知輸入參數。

傳統上，處理訊號時研究者專注力將會聚焦於提取訊號特徵的方法、提取訊號特徵的種類，以及如何消弭訊號雜訊。而對於動態生理訊號而言，其一般最受研究者注目的訊號特徵在於訊號的節律 (rhythm)、強度 (intensity)、再現頻率 (frequency) 或週期 (period)，以及由實驗元件或架構產生的其他特徵。以圖 6 之生理訊號為例，在 y 方向與 z 方向

的訊號強度高於 x 方向的訊號特徵，此可說明在該兩方向所受的外力較為強烈。此外亦可發現人體翻身姿態產生的節律特徵以加速度訊號呈現時，其訊號結構為一方波，其再現周期為 40 秒與 20 秒。而該方波在升與降的轉折處，會出現過衝現象 (overshooting)。而該現象發生主因在於元件收到過強或過快的外力作用，使得其中感測電訊號突然到達飽和或異常快速升高。此時處理這種特徵的方法便各有巧思。如以傅立葉分析 (Fourier analysis) 為基底的方法，對於如此的非穩態 (non-stationary) 訊號的抵抗力較弱。因此，該種特徵便需要以前處理 (pre-processing) 的方式來避免或消除。而本文提出的方法可利用分群方法將其歸類在某特定群中，因此可以直接避免時間訊號處理時面臨的窘境。

為了使用 DDFA 對時序資料做分群，各個加速度軸上之偵測數據將依據各個主資訊軸映射到相應之二維物理空間中，如圖 7 所示。如圖 7(a)，可發現在第一主資訊軸 (即 x 軸) 以及第二主資訊軸 (即 y 軸) 構成的資料點的集合圖形中，資料點擁有固定的分布範圍。而圖 7(b) 由第一主資訊軸以及第三主資訊軸 (即 z 軸) 構成的資料點集合圖形裡可發現相同資料集中情形。但在圖 7(c) 卻發現由




圖 6. 三軸加速度感測器之時序訊號關係圖：人體側轉時的 (a) x 軸方向特徵，明顯可看出強度弱於其它兩軸；(b) 與 (c) 分別為 y 軸與 z 軸之加速度變化特徵，明顯成消長關係；(d)–(f) 另一側側轉時的訊號變化。實驗中雖人體側轉方向為已知：左邊三幅圖為平躺與向右翻，右邊三幅圖為平躺與向左翻。但為檢驗無監督演算法之可行性，其側轉方向於演算過程中假設未知，並依賴於機械學習方法對於資料的分析做判定。






圖 7. 對照圖 6(a)–(c) 的三軸時序加速度訊號於各二維主資訊軸映射關係圖。

第二主資訊軸以及第三主資訊軸構成的資料呈現出大範圍的散佈行為，且該行為為接近數值反比之特性。因此可推論第一主資訊軸對於該時序睡姿改變數據的影響較其他兩軸為弱，此推論亦可由圖 6(a) 中獲得支持。所以在資料分群的依據上，由第一主資訊軸為參考軸 (因干擾最少) 來觀測其他兩軸上的資料分佈狀態較易達成資料分群的需求。

為研究如何以感測器與演算法合作，來有效判斷與分辨人體兩種姿態不同時的數據差異，在進行剔除掉異常值 (outlier) 的前置處理以及使用 HF 計算群數之後，我們首先使用 GMM 進行初始分群工作以及尋找資料質心位置。圖 8(a)–(c) 為使用 GMM 方法在各二維主資訊軸下的分群結果。觀察可得由第一主資訊軸為基底的分析方法，最能提供最佳的分群結果，如圖 8(a) 所示。而圖 8(b) 在 GMM 分群方法下的分群結果，由於該資料在第三主資訊軸上分佈得過於分散，因此不被採用做進一步的 DDFA 能量分群。而圖 8(c) 的資料雖達成分群結果，但兩群資料之間仍有太多未分群資料點存在，因此可能容易造成判斷誤差。下一階段我們將

使用 GMM 所獲得的資料密度函數做為 DDFA 的輸入函數，並利用資料動能與資料位能估計出拉氏泛函在二維空間中的分布情形，如圖 8(d)–(e) 所示。其中以與圖 8(a) 對應的 (d) 圖，最能反映出適當的分群結果。因此將以圖 8(d) 為範本，尋找包圍資料群的最低封閉等能量線，如圖中紅色箭頭所示。由於該圖表明 LDF 的能量形態，因此箭頭表明獨立包圍單一資料群之最低封閉等能量線，亦具有代表該群資料的最外可能邊界的物理意義。圖 8(d) 的 DDFA 分群結果，主要可以區分為上下兩群和未被分群的其餘資料點。同時發現在任意一群的中心位置上有兩個成對總共四個的凹槽。這些凹槽表示在該兩大群裡，各別都還有可被 DDFA 進行細分的子群。由複驗實驗紀錄發現，是由於黏貼於胸口的高靈敏度感測器紀錄了呼吸時胸腔的起伏而造成的小型資料群。由此可知 DDFA 可從大群集裡經由邊界的凹槽再進行細緻化分群。

圖 9(a) 與 (c) 展示了圖 6 中各主資訊軸 (principal axis, PA) 的 DDFA 分群結果，同時圖 9(b) 與 (d) 顯示了該資料重新映射回了時間序列軸裡的

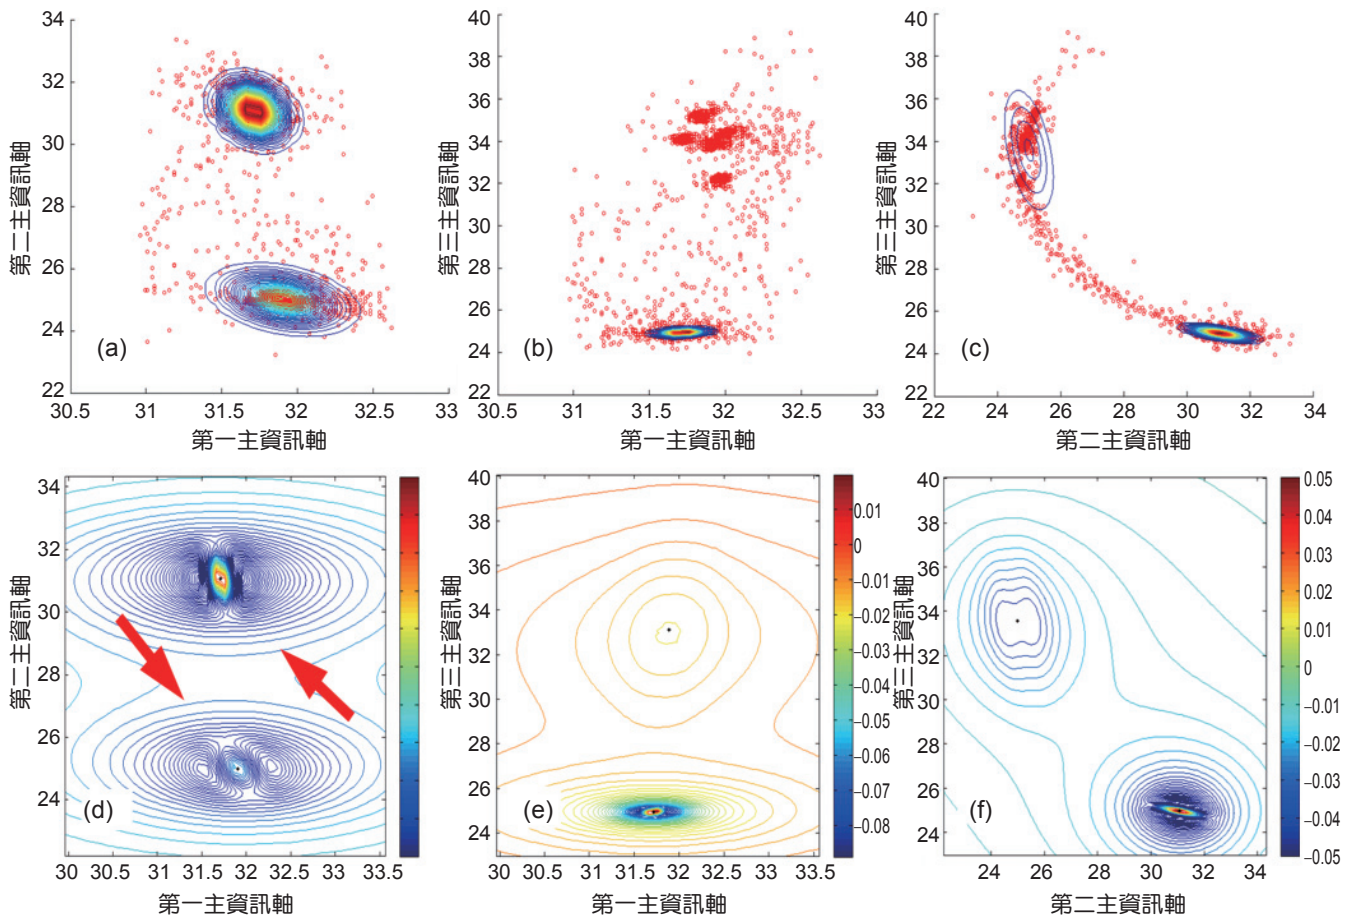


圖 8. 針對圖 7 的 GMM 與 DDFA 締合分群結果：(a)–(c) 為使用 GMM 方法下在各二維主資訊軸下的分群結果。可看出該方法可以擷取出資料點的質心位置。(d)–(f) 則為締合方法獲得之各二維主資訊軸下的能量分群結果。可發現 DDFA 除可將資料點質心位置擷取出來，還可利用最低封閉等能量線 (如紅色箭頭所指) 將資料點的範圍清楚定義。

結果。Lying 表示平躺時的資料群組，TL (turn left) 與 TR (turn right) 分別代表側躺時的資料群組，而 Transit 代表兩者間轉換時期的過渡區。可以發現平躺時 (Lying 群集) 資料比較密集，是因為平躺時人體姿態處於較為穩定的狀態，而在側躺時 (TL/TR 群集) 資料相對較為分散，是因為轉身進入側躺狀態時，為了要平衡穩定身體狀態使身體自發造成的些微晃動。造成這兩者的差異是受人體身理結構影響，此結果可由實驗數據支持。圖 9(b) 與 (d) 為還原回時間域的譜圖。可發現每個主資訊軸之間都擁有明確的對應關係，且過渡區大部分都符合預期地發生在兩種動作的轉換區域中。

本研究分析了人體的姿態轉換辨識。由空間域

分群結果可得第二主資訊軸比第三主資訊軸有較佳的資料點集中趨勢，故擁有較佳的分群結果，如圖 9(a) 與 (c) 所示。而該 DDFA 分群結果在時序訊號中將無法直接從原始的圖 6 獲得。同時搭配圖 6 時序訊號可知，翻身姿態以及週期長短不會影響 DDFA 資料分群結果。因此可以承受人體姿態有大幅度的調整或改變，可論為本技術的獨特優勢所在。最後，由圖 1 之感測器物理元件架構可知：感測人體向右旋轉時，可得 y-z 軸資料反比分佈；向左旋轉時，可得 y-z 軸資料正比分佈。故演算法可自動判定圖 9(a) 與 (c) 應分別為左側翻與右側翻之姿態分佈圖形。圖 10 為人體翻轉一週後數據投射物理空間的結果，並可以藉此特性估計出人體翻轉

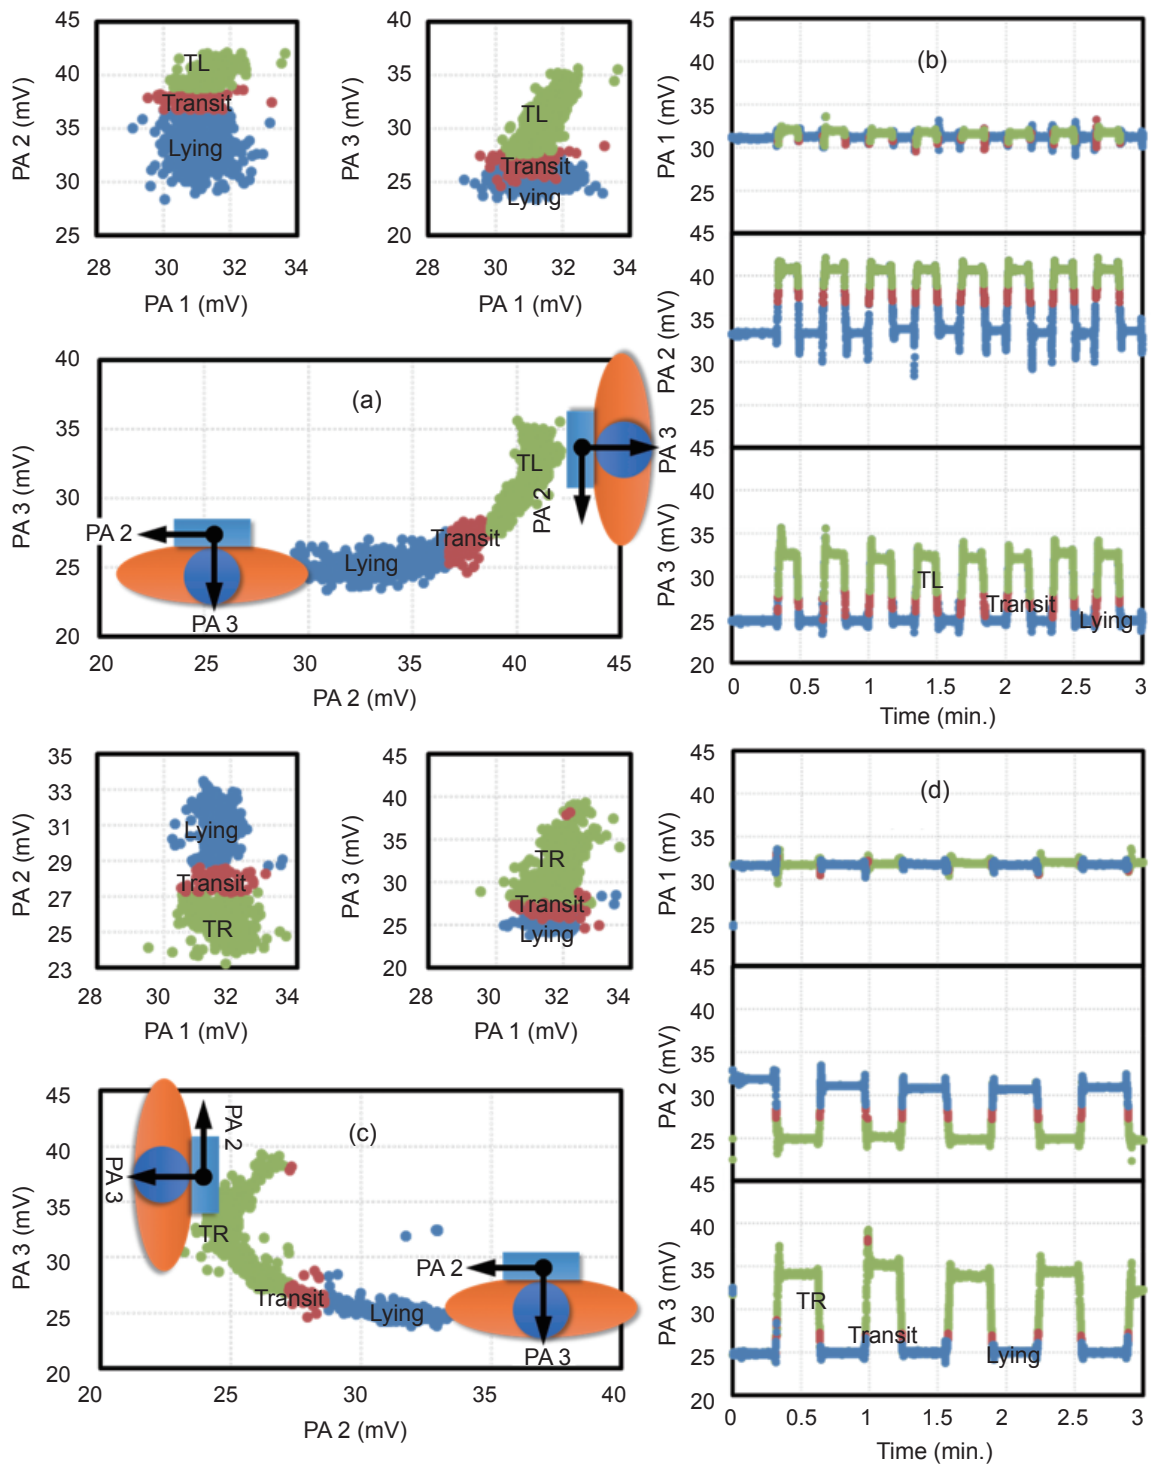


圖 9. (a) 與 (c) 圖為藉由 DDFFA 所搜尋獲得的各資料邊界分群結果映射至各二維主資訊軸的關係圖。其中 Lying 表示由側躺轉為正躺的資料群，TR/TL 代表由正躺轉為側躺的資料群，而 Transit 代表兩者之間的過度區。(b) 與 (d) 圖為還原之後的分群時序訊號序列。由該兩圖 Lying 的數據且搭配圖 1 之感測器物理元件架構可驗證：圖 6 中的左三圖為右側翻數據如本圖 (c) 與 (d) 所示，以及右三圖為左側翻數據如本圖 (a) 與 (b)。

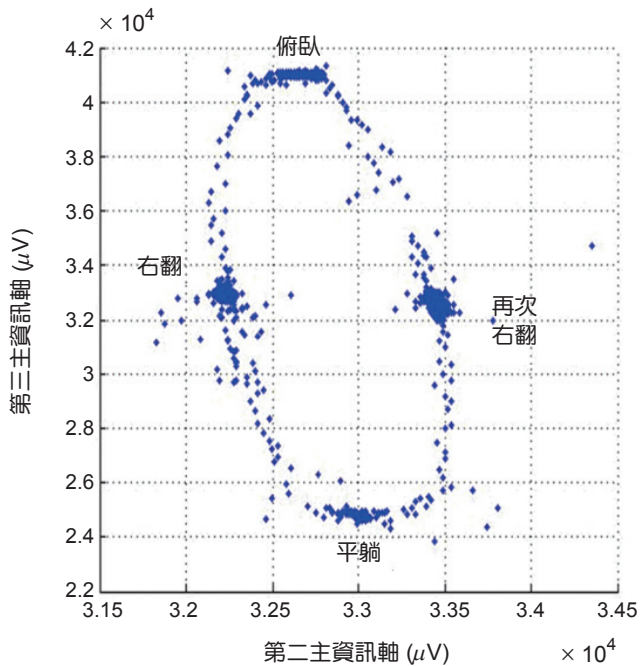


圖 10. 人體翻轉一周後數據投射物理空間結果，可以藉此特性直接計算出所翻轉之角度。由圖可知，從平躺、右翻、俯臥到再次右翻(即相當於左翻)，個別狀態之間的轉動角度皆約略為 90 度。約略左傾的圖形偏移，可推論是由於身體翻轉姿勢習慣造成。

角度；由該圖可知當嬰幼兒翻轉超過 270 度時(由平躺變為俯臥)，本方法可依據其行為對使用者或監督者提出警訊。另外，若為行動不便之患者，當其翻轉角度超出床側容許之範圍時，本方法亦能偵測其行為並警告看護者。

#### 四、結論及未來展望

綜合以上，本文之目的在於藉由專業的生理特徵取樣技術獲得重要資訊後，利用 DDFA 分析重點需求：自動化的人體姿態特徵辨識。此技術本身除了在科學研究上得以給出一個以基礎科學為基礎的普適型且無參數—非監督式大數據演算理論之外，在工程方面亦供給電腦輔助系統設計方面的便利。由上而下的概念更容易滿足研究成果導入商品化或技術轉移等重點需求。

本技術與專業穿戴式生醫電子系統結合，而提出了相應的機械學習分析技術。其中，所提出的新穎機械學習分析技術揉合了物理與統計的各種優勢：藉由搜尋最低封閉等能量線以及能量穩定值，可分別獲得資料群之間的最適當邊界以及數據群數。而且可將時序資訊映射在低維度空間中，使得本方法可適用於分析長時間或暫態的時序生醫資訊。值得強調：每組時序訊號映射到相對應的二維主資訊空間之後，都可擁有各自的資料密度函數關係。因此也各自擁有獨立的群平均值以及共變異數矩陣。所以在長時間的分析上相關參與研究人員可針對該群平均數以及共變異數矩陣獲得各群之間以及各群內部的數值意義，例如群聚的大小與形態等，如此資訊將非常適合作為個人客製化形式的資料庫。而時序上的分群則適合用於短暫時間中的模態辨識，而可應用在如警訊通知方面。

本技術針對長期實驗可用以建立個人資料數據庫：除了準確偵測與分析個別人體姿態，亦藉由資料庫更新使得各種姿態頻率的判定更加精確。在這種長期的生理訊號的分析下可以找出各種人體可能發生的病灶，例如脊椎側彎等。短期實驗可用以意外事故肇因分析以及提前的警訊通知，如老人摔倒、幼兒翻身等。除可節省大量人力、物力資源與數據資料的佔用，同時具備更高的可信度與客觀性，乃至於爾後技術的商業化。藉由以上分群後的分析結果可以明顯的發現，在姿態的改變上可以藉由數據分析做明確的分群，若再配合其他的醫療輔助器材即可進行全面的人體資訊分析。

#### 參考文獻

1. D. Laney, *META group*, **949**, (2001).
2. L. D. W. Thomas and A. Leiponen, *IEEE Eng. Manag.*, **44**, 74 (2016).
3. E. E. Schadt, M. D. Linderman, J. Sorenson, L. Lee and G. P. Nolan, *Nature Reviews Genetics*, **12**, 224 (2011).
4. A. Jacobs, *Communications of the ACM*, **52**, 36 (2009).
5. J. Rozas, J. C. Sánchez-DelBarrio, X. Messeguer, and Ricardo Rozas, *Bioinformatics*, **19**, 2496 (2003).
6. M. Girvan and M. E. J. Newman, *PNAS*, **99**, 7821 (2002).
7. S. Hampel, P. Chung, C. E. McKellar, D. Hall, L. L. Looger, and J. H. Simpson, *Nature Methods*, **8**, 253 (2011).
8. O. Kobiler, Y. Lipman, K. Therkelsen, I. Daubechies, and L. W.

Enquist, *Nature Communications*, **1**, 1 (2010).

9. M. E. J. Newman and M. Girvan, *Phys. Rev. E*, **69**, 026113 (2004).

10. A. Clauset, M. E. J. Newman, and C. Moore, *Phys. Rev. E*, **70**, 066111 (2004).

11. O. Sporns, *Ann. NY Acad. Sci.*, **1224**, 109 (2011).

12. E. T. Bullmore and D. S. Bassett, *Annu. Rev. Clin. Psychol.*, **7**, 113 (2011).

13. J. W. Lichtman, J. Livet, and J. R. Sanes, *Nat. Rev. Neurosci.*, **9**, 417 (2008).

14. N. Tzourio-Mazoyer, B. Landeau, D. Papathanassiou, F. Crivello, O. Etard, N. Delcroix, B. Mazoyer, and M. Joliot, *NeuroImage*, **15**, 273 (2002).

15. R. A. Poldrack, *Soc. Cogn. Affect. Neurosci.*, **2**, 67 (2007).

16. Z. Kalal, K. Mikolajczyk, and J. Matas, *IEEE Trans. Pattern Anal. Mach. Intell.*, **34**, 1409 (2012).

17. A. McAfee and E. Brynjolfsson, *Harvard Business Review*, 1 (2012).

18. H. Chen, R. H. L. Chiang, and V. C. Storey, *MIS Quarterly*, **36**, 1165 (2012).

19. W. Kohn, *Rev. Mod. Phys.*, **71**, 1253 (1999).

20. P. Hohenberg and W. Kohn, *Phys. Rev.*, **136**, B864 (1964).

21. W. Kohn and L. J. Sham, *Phys. Rev.*, **140**, A1133 (1965).

22. S. Grimme, J. Antony, T. Schwabe, and C. Mück-Lichtenfeld, *Org. Biomol. Chem.*, **5**, 741 (2007).

23. K. E. Riley, M. Pitoňák, P. Jurečka, and P. Hobza, *Chem. Rev.*, **110**, 5023 (2010).

24. F. Neese, *Coord. Chem. Rev.*, **253**, 526 (2009).

25. K. Lee, É. D. Murray, L. Kong, B. I. Lundqvist, and D. C. Langreth, *Phys. Rev. B*, **82**, 081101 (2010).

26. C. J. Cramer and D. G. Truhlar, *Phys. Chem. Chem. Phys.*, **11**, 10757 (2009).

27. F. M. Bickelhaupt and E. J. Baerends, *Reviews in Computational Chemistry*, Vol. 15, Hoboken, NJ, USA: John Wiley & Sons, Inc., (2007).

28. J. Wu, *AIChE Journal*, **52**, 1169 (2006).

29. M. S. Daw and M. I. Baskes, *Phys. Rev. Lett.*, **50**, 1285 (1983).

30. H.J. Tsai, T. B. J. Kuo, G. S. Lee, and C. C. H. Yang, *Psychophysiology*, **52**, 388 (2015).

31. T. B. J. Kuo, C. H. Hong, I.T. Hsieh, G. S. Lee, and C. C. H. Yang, *Sleep Medicine*, **15**, 986 (2014).

32. E. Bas, D. Erdogmus, R. W. Draft, and J. W. Lichtman, *J. Vis. Commun. Image R.*, **23**, 1260 (2012).

33. E. Bas and D. Erdogmus, *ISBI*, 1297 (2010).

34. Z. Vasilkoski and A. Stepanyants, *J. Neurosci. Meth.*, **178**, 197 (2009).

35. Y. Wang, A. Narayanaswamy, C.-L. Tsai, and B. Roysam, *Neuroinform.*, **9**, 193 (2011).

36. E. Türetken, F. Benmansour, B. Andres, H. Pfister, and P. Fua, *IEEE CVPR*, 1822 (2013).

37. R. Gala, J. Chapeton, J. Jitesh, C. Bhavsar, and A. Stepanyants, *FNANA*, **8**, 1 (2014).

38. P. Chothani, V. Mehta, and A. Stepanyants, *Neuroinform.*, **9**, 263 (2011).

39. E. Türetken, G. González, C. Blum, and P. Fua, *Neuroinform.*, **9**, 279 (2011).

40. Y. Zhang, K. Chen, M. Baron, M. A. Teylan, Y. Kim, Z. Song, P. Greengard, and S. T. C. Wong, *NeuroImage*, **50**, 1472 (2010).

41. H. Peng, F. Long and G. Myers, *Bioinformatics*, **27**, i239 (2011).

42. A. Rodriguez, D. B. Ehlenberger, P. R. Hof, and S. L. Wearne, *J. Neurosci. Meth.*, **184**, 169 (2009).

43. Y. Hsu and H. H.-S. Lu, *International Journal of Computer Information Systems and Control Engineering*, **7**, 891 (2013).

44. H.-C. Shao, W.-Y. Cheng, Y.-C. Chen, and W.-L. Hwang, *ICIP*, 2025 (2012).

45. T.-Y. Wu, H.-H. Juan, H. H.-S. Lu, and A.-S. Chiang, *ACM ISABEL*, (2011).

46. L. Lu, H. Jiang, and W. H. Wong, *Journal of the American Statistical Association, Theory and Methods*, **108**, 1402 (2013).

47. P. Hohenberg and W. Kohn, *Phys. Rev.*, **136**, B864 (1964).

48. W. Kohn and L. J. Sham, *Phys. Rev.*, **140**, A1133 (1965).



黃信哲先生現為中央大學生醫科學與工程學系跨領域轉譯博士班學生。  
Shen-Jhe Haung is currently a Ph.D. student in the Department of Biomedical Sciences and Engineering at National Central University.



陳健章先生為國立交通大學電子工程博士，現為國立中央大學生醫科學與工程學系助理教授。  
Chien-Chang Chen received his Ph.D in electronics engineering from National Chiao Tung University. He is currently a assistant professor in the Department of Biomedical Sciences and Engineering at National Central University.



郭博昭先生為陽明大學藥理學博士，現為臺北醫學大學醫學資訊研究所教授兼所長，並為國立陽明大學腦科學研究所教授。  
Terry B. J. Kuo received his Ph.D in

pharmacology from National Yang-Ming University. He is currently a professor and director in the Institute of Biomedical Informatics at Taipei Medical University. In the meantime, he is a professor in the Institute of Brain Science at National Yang-Ming University.



盧鴻興先生為美國康乃爾大學統計學博士，現為國立交通大學統計所教授並為國立交通大學教務長及大數據研究中心主任。

Henry Horng-Shing Lu received his Ph.D in statistics from Cornell University, USA. He is currently a professor in the Institute of Statistics at National Chiao-Tung University. In the meantime, he is a vice president of Academic Affairs and a director of Big Data Research Center at National Chiao-Tung University.