

三種主軸成分法於數位影像特徵擷取與判別之研究

羅竣威

國立屏東科技大學

機械系碩士班研究生
屏東縣內埔鄉學府路 1 號
886-8-7703202 轉 7580

M9232021@mail.npust.edu.tw

謝清祿

國立屏東科技大學

生物系統工程系副教授
屏東縣內埔鄉學府路 1 號
886-8-7703202 轉 7583

chinglu@mail.npust.edu.tw

摘要

本研究使用三種主軸成分法(Principal Component Analysis, PCA)，分別為單一波段多樣本、單一多樣本多波段、多波段多樣本，進行數位影像特徵擷取及判別比較，測試對象為有汙染及無汙染培養基多分光影像，針對這兩類樣本試驗結果，採用多波段多樣本抽取策略，組合 480-560nm、850-870nm 波段可達 91% 判別正確率，高於另兩種策略的分類正確率，故該法則較單一影像或單一光譜空間的特徵抽取方式，有較佳的判別效能。本項影像維度縮減技術，甚值得在數位典藏中，進行特徵擷取、圖形辨識等應用研究。

關鍵字：

主軸成分、數位影像、特徵擷取、維度縮減

1. 前言

主軸成分法其應用範圍從統計學資料轉換分析擴展到影像處理應用上，藉由主成分方法將資料進行重要指標擷取，並能減少過多的高相關性資訊[1]，本研究針對主軸成分技術在多分光影像及圖形辨識之應用作探討。本研究將主成分方法對影像特徵抽取的概念進行比較，該法則可分成三種方式，其一是針對不同影像樣本中的特徵找出該影像一代表性的特徵空間，並藉由原始影像映射到特徵空間的方法找出影像特徵參數，這種 PCA 方法主要是針對「影像解析空間」來擷取特徵。該理論較早之應用為 Turk 及 Pentland[2]提出 PCA 特徵空間(Eigenspace)應用在人臉辨識之理論，其概念係由原始資料空間內，找出一個具代表性的子空間，子空間是由原始資料線性組合而成，將原始資料投影至特徵空間中，該研究利用十六張人臉影像作為原始資料，選擇前 7 個主成分作為特徵空間的基底，這些基底稱為特徵臉(Eigenface)，然後將人臉影像分別映射至特徵空間，可獲得 7 個維度的主成分分量，人臉影像可用此 7 個變數來表述，故縮減了龐大的影像資訊，而這些特徵能直接表現出人臉影像原始五官特徵，故對於複雜影像之辨識具有其功效。

另一種 PCA 方法主要是應用於分光影像技術，該方法為針對分光影像的「光譜解析空間」抽取特徵方

式，其相關研究有基於多分光螢光影像技術檢測受動物排泄物汙染之蘋果[3]，其中選擇四個代表性的螢光發射波段(450、530、685、735 nm)，以 PCA 方法針對此 4 個波段分光影像作轉換，可從第二主成分影像觀察出明顯的汙染斑點，PCA 讓多分光影像之蘋果汙染斑點，能更清楚呈現在前幾個成分影像，而使影像特徵強化。

第三種 PCA 策略則為綜合分光影像的「光譜解析空間」及「影像解析空間」來擷取特徵，其相關研究之應用有 Quintiliano 及 Santa-Rosa[4]用 PCA 方法對於地表衛星遙測的多光譜影像進行特徵之比對，區別地表水資源、土地資源及造林區三種地類，將具有三種波段的衛星影像串接成列向量的作法，運算其 PCA 特徵空間，再將各地物類別映射至特徵空間獲取特徵，藉由這些地物特徵以歐幾里德距離法則逐一比對已知的地物類別而將其區分。

以上所述之各項研究證實 PCA 對於龐大的光譜影像，為一種資料維度縮減及影像特徵抽取之工具，本研究針對上述三種不同的 PCA 特徵抽取策略，進行分光影像特徵抽取，其中測試之對象為植物組織作業中常見的 MS 培養基之影像[5]，將樣本分成有汙染及無汙染培養基，抽取其影像特徵，並將這些特徵使用統計學的貝氏分類器歸類影像，並比較這三種方法的分類正確率。

2. 實驗設備與方法

2.1 數位分光影像擷取

本研究使用自行研發的多分光攝影系統[6]攝取多分光影像，並進行不同波段之拍攝，主要分類受汙染之培養基影像與未受汙染分光影像特徵，針對第 4 日培養基，總共拍攝七個波段，分別為 400~700 nm、400~770 nm、480~560 nm、560~620 nm、300~400 nm、850~870 nm、850~1050nm。而其中培養基樣本製作數目共為 300 個樣本，有及無汙染之樣本各佔 150 個，其中隨機挑選出 150 個為訓練組樣本，其餘 150 個樣本則為測試組。另藉由 MathWorks 公司所開發的 MATLAB(6.5 版)軟體，並搭載影像處理程式工具庫

(Image processing toolbox)作為輔助，進行影像處理程式之撰寫。

2.2 影像正規化處理

原始攝取的影像為 640×480 像素 24Bits 的 RGB 影像，在進行 PCA 轉換前，要先將所有圖像作正規化，正規化目的在減少影像雜訊，並讓所有影像大小一致、目標物置中，正規化之步驟首先將彩色影像轉換為灰階化的影像，接著以二值化方法，選取目標區域，並進行第一次邊緣搜尋，然後另以該影像中心繪製二值化中心圓影像，並將中心圓影像侵蝕 80 次，即可選取該影像的中心區域，正規化後之影像為 292×292 像素，色階為 8Bits。

2.3 主軸成分法特徵擷取

主軸成分法是一種資料轉換方法，其基本概念係將原始變數轉換成一組線性無相關且獨立的變數向量，其稱為主軸向量(Principal Components, PC)，資料被轉換、旋轉到一個新的座標系統，並加大資料間的變異性。對於多光譜影像擁有龐大資訊之影像，縮減維度更能增加判別之效率。本研究使用的PCA理論分成三種，即單一波段多樣本、單一多波段、多波段多樣本。今設有兩類待辨識的樣本，分別為群 1 及群 2，此以代號 G_1 及 G_2 表示，其方法分述如下：

2.3.1 單一波段多樣本

單一波段多樣本的方法係以一張長乘寬($N \times N$) pixels 的影像，將之排成行向量 Γ ($N^2 \times 1$) 形式，全部類別訓練組 M 張影像(包含 G_1 及 G_2 兩個類別群的樣本)，各串接排列成 $N^2 \times 1$ 維度之形式(Column vectors)，圖 1 為單一波段多樣本向量串接的示意圖。如公式(1)所列：[2][7]

$$\Gamma_{i,1} = \Gamma'_{j,k} \quad (1)$$

$$(i = 1, \dots, N^2; j, k = 1, \dots, N)$$

式中 Γ' 為單一波段原始影像向量， Γ 為串接排列後之向量。




圖 1 單一波段多樣本向量串接示意圖

由公式(2)計算 M 個 Γ 向量的平均值 Ψ ，該平均值 Ψ 為各張影像串接的 $N^2 \times 1$ 階向量，予以加總並除以影

像樣本的個數，故亦能將此平均向量稱作平均影像 (Average image)。

$$\Psi = \frac{1}{M} \sum_i^M \Gamma_i \quad (2)$$

接著，逐一將 Γ 向量與平均值 Ψ 相減計算求得 Φ_i ($i = 1, 2, \dots, M$) 差值向量，每個差值向量亦可用影像表示，該影像可稱作差值影像 (Difference image)，如公式(3)所列。

$$\Phi_i = \Gamma_i - \Psi \quad (i = 1, \dots, M) \quad (3)$$

由 M 個差值向量 Φ_i 逐列排成維度 $M \times N^2$ 的 A 矩陣，並將 A 矩陣與其轉置矩陣內積，求出共變異矩陣 (Covariance matrix, C)，如公式(4)所示：

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T, \quad A = [\Phi_1, \Phi_2, \dots, \Phi_M] \quad (4)$$

然後經由矩陣 C 計算其特徵值及特徵向量，其中 C 矩陣為一對角矩陣，因公式(4)中的共變異矩陣 C 維度為 $N^2 \times N^2$ ，於求取共變異矩陣 C 之特徵向量 x_i (Eigenvectors) 及特徵值 λ (Eigenvalues) 較為困難且複雜，Turk 等人[2]提出以計算 L 矩陣的方法予以簡化運算複雜度， L 矩陣其大小維度為 $M \times M$ ，由 L 矩陣求得特徵向量 v_i ($i = 1, 2, \dots, M$)，其得到的 M 個特徵向量遠小於 N^2 ($M < N^2$)，將可大量減少電腦運算時間及降低錯誤的產生。

$$L = A^T A \quad (5)$$

公式(5)使共變異矩陣維度縮小至 $M \times M$ ，故只需求 M 個特徵向量及特徵值即可；由 L 矩陣求出 M ($M < N^2$) 個特徵向量 v_k 及特徵值 λ_k ($k = 1, 2, \dots, M$)，將特徵值 λ_k 的大小依照其所對應的特徵向量作排序 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_M$ ，只須選擇前 M' 個最大的特徵值，本研究選取前 23 個主成分為特徵空間 (即 $M'=23$)，使用前 M' 個擁有較大特徵值的特徵向量作為特徵空間 U 的基底，這些特徵向量即可表現大部分的變異情形，因使用少數幾個特徵向量作為影像子空間 ($M' < M$)，故同時能達到資料維度縮減的目的，如公式(6)所列：

$$U_l = \sum_{k=1}^M v_{l,k} \Phi_k \quad l = 1, \dots, M \quad (6)$$

訓練階段則將 G_1 及 G_2 訓練樣本映射至公式(6)產生的特徵空間 U ，即可獲得特徵參數 Ω ，公式如(7)及(8)所示。

$$\Omega_1 = U^T (\Gamma_1 - \Psi) \quad (7)$$

$$\Omega_2 = U^T (\Gamma_2 - \Psi) \quad (8)$$

(7)及(8)式中， Ω_1 及 Ω_2 分別為 G_1 及 G_2 之特徵參數，其維度為 $M' \times 1$ 階，可表示成 $\Omega_1 = [\omega_{11}, \omega_{12}, \dots, \omega_{1M'}]^T$ 及 $\Omega_2 = [\omega_{21}, \omega_{22}, \dots, \omega_{2M'}]^T$ 。然後將待測的影像 Γ_i

同樣映射至訓練階段所產生的特徵空間U，如公式(9)所示， Ω_i 即測試影像映射後所產生的特徵參數，其維度同樣為 $M \times 1$ 階。最後將訓練與測試組的特徵參數經由判別分析法進行試驗。

$$\Omega_i = U^T(\Gamma_i - \Psi) \quad (9)$$

2.3.2 單一樣本多波段

單一樣本多波段為針對同一樣本且相同類別的多光譜影像進行PCA轉換處理，影像各像素點有B個波段特徵，將一組B個波段影像組合成X矩陣，並轉換成原始變數X與共變異數矩陣C之特徵向量E的線性組合 $PC=E^T \cdot X$ ，此線性組合PC即為主成分轉換後的指標，其主成分線性組合如公式(10)所示。各個波段以公式(1)串接成向量 X_i 形式，如圖2的多波段單一樣本向量串接示意圖，串接後的行向量為 $X_i(i=1,2,\dots,B)$ ，並計算變數間的共變異矩陣C。[8]

$$\begin{bmatrix} PC_1 \\ PC_2 \\ \vdots \\ PC_B \end{bmatrix} = \begin{bmatrix} e_{11} & e_{12} & \cdots & e_{1B} \\ e_{21} & e_{22} & \cdots & e_{2B} \\ \vdots & \vdots & & \vdots \\ e_{B1} & e_{B2} & \cdots & e_{BB} \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_B \end{bmatrix} \quad (10)$$

(10)式係將共變異矩陣C求得 λ_i 特徵值及特徵向量 e_i ，同單一波段多樣本的方法，將特徵向量 e 所對應的特徵值 λ_B 的大小作排序，式中 X_i 為某一波段的原始影像， X_i 映射至特徵向量E矩陣中，即可獲得光譜空間的主成分影像(PC image)，本研究取前2個主成分指標的平均值作為光譜空間特徵資訊。




圖2 單一波段多樣本向量串接示意圖

2.3.3 多樣本多波段

多波段多樣本的PCA方法，以特徵空間理論將分光波段影像合併組合進行PCA轉換，假設M個樣本中分別有B個波段分光影像，則每單一數樣本可組合成 $N \times N \times B$ 三維資料矩陣，此三維矩陣同時包含了影像空間及光譜空間資訊；將M個影像樣本之三維 Γ' 向量，同樣以公式(11)之方法排列成單維的行向量形式，圖3為多波段多樣本向量串接方式的示意圖。公式如下，式中 Γ' 為綜合波段原始影像向量， Γ 為多波段多樣本排列後之向量接著依照單一波段多樣本進行PCA轉換，重複公式(2)~公式(9)的方法計算出特徵參數 Ω ，於此本研究亦選取前23個主成分為特徵空間：[4]

$$\Gamma_{i,1} = \Gamma'_{j,k,p} \quad (11)$$

$$(i = 1, \dots, BN^2; j, k = 1, \dots, N; p = 1, \dots, B)$$

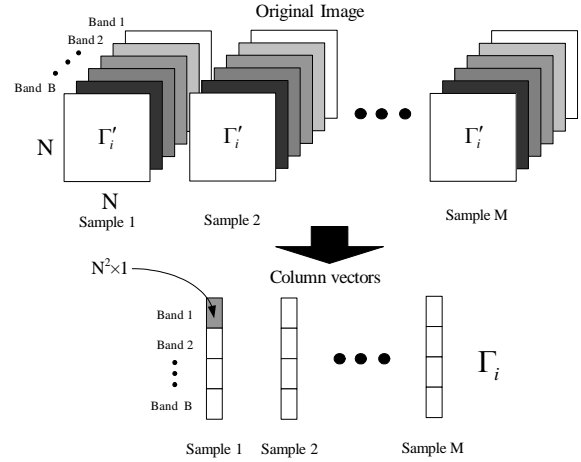


圖3 多波段多樣本向量串接排列示意圖

因電腦計算速度及記憶體空間上之限制，過多的波段組合會造成所需記憶體容量過於龐大，本研究針對多波段多樣本之策略僅選取具代表性的波段作特徵抽取，組合的波段為「480-560nm+850-870nm」之方式。

2.4 貝氏分類器

貝氏分類器又稱作最佳統計分類器，該理論係藉由母體的事前機率(Prior Probability)及已知類別之原始資訊(樣本機率)去推得事後機率(Posterior Probability)，事後機率即為用以歸類的鑑別機率，本研究假設兩個受高斯密度支配的類別，其貝氏分類器決策函數 $d_j(x)$ 如下表示[9][10][11]：

$$d_j(x) = p(x/\omega_j)P(\omega_j) \quad j=1,2 \quad (12)$$

(12)式中 $p(x/\omega_j)$ 為待測樣本 x 來自 ω_j 類別的機率密度函數，即表示未知類群 x 屬於 ω_j 類別的機率，貝氏理論法則即是根據類別的機率來進行分類，另外 $P(\omega_j)$ 是 ω_j 類別發生的機率，可將其假設為G1群及G2群於母體的發生機率為相同，即事前機率相等 $P(\omega_1)=P(\omega_2)=0.5$ ，故(12)式可把 $P(\omega_j)$ 省略，今兩類別呈高斯模式分佈，故將(12)式以公式(13)表示。

$$d_j(x) = \frac{1}{(2\pi)^{n/2}|C_j|^{1/2}} \exp\left[-\frac{1}{2}(x-m_j)^T C_j^{-1}(x-m_j)\right] \quad j=1,2 \quad (13)$$

式中 m_j 及 C_j 分別為 j 類的平均值和共變異矩陣， n 為類別向量的維度，其計算公式如(14)式所列：

$$m_j = \frac{1}{N_j} \sum_{i=1}^{N_j} x_{i1} \quad C_j = \sum_{i=1}^{N_j} (x_{i1} - m_j)(x_{i1} - m_j)' \quad (14)$$

(14)式中 N_j 為訓練樣本數目，而(13)式可將其由指數形式轉為自然對數，其轉換後結果如公式(15)所列：

$$d_j(x) = -\frac{1}{2}(x - m_j)^T C_j^{-1} (x - m_j) - \frac{1}{2} \log |C_j| \quad j=1, 2 \quad (15)$$

若待測資料x的決策函數 $d_1(x)$ 大於 $d_2(x)$ ，則x屬於群1；反之，則x屬於群2。

3. 結果與討論

本研究分別針對受污染的培養基及無污染的培養基影像來進行特徵抽取，使用了三種不同的 PCA 特徵抽取策略，有污染的培養基影像如圖 4 所示，該圖顯示 7 種不同波段的分光影像，有污染的培養基影像時常有不同形態及複雜的汙染菌落外觀特徵，由 300~400nm 波段可看到在不同光譜波段的特殊影像特性。

另外，無污染的培養基則為圖 5 所示的影像，與有污染的培養基影像比較下，該影像有較均一的灰階色彩情況。




圖 4 有污染培養基在不同波段之分光影像





圖 5 無污染固態培養基在不同波段之分光影像

在進行 PCA 特徵抽取之前，需要先進正規化的動作，讓圖片大小一致並使目標物圖置中，正規化過程之影像，如圖 6(A)~(H)所示，圖 6(A)為經灰階處理的影像，然後經由二值化處理並搜尋切割邊緣，即圖 6(B)~(D)的影像，由圖 6(D)的影像與經侵蝕的中心圓相乘，可選取培養基的中心區域圖 6(G)，而圖 6(G)經二次邊緣搜尋切割可獲得正規化影像圖 6(H)。




圖 6 單一波段多樣本向量串接示意圖

經過正規化後的培養基影像如圖 7 所示，圖 7 (A) 為無污染類別的影像，而圖 7 (B)則是有污染樣本的影像，該圖形分別為經過正規化處理的有汙染及無污染的培養基影像。






圖 7 有污染(A)及無污染(B)固態培養基正規化之影像


接著，分別利用三種 PCA 方法可獲得不同的特徵影像，如圖 7 所示為三種特徵抽取法計算出的主成分影像。各影像具有共同的 PCA 特性，各 PCA 影像在後面幾個皆無明顯的特徵表現，在前面幾個主成分影像則有較多的特徵資訊，其中單一波段多樣本的方法，為圖(A)所示，而圖(B)是七種波段分光影像轉換的 PCA 影像，圖(C)則為多波段多樣本方法為兩種不同光譜資訊綜合的特徵影像。



(A) 單一波段多樣本 PCA 影像



(B) 單一様本多波段 PCA 影像



(C) 多樣本多波段 PCA 影像

圖 8 三種主成分分析方法之影像

3.1 不同 PCA 特徵抽取之分類結果

利用三種 PCA 方法針對培養基各分光影像抽取其特徵參數，且採用貝氏距離分類器來進行有污染及無污染培養基影像的歸類，該樣本為製作後第 4 日的培養基，使用單一波段多樣本的判別結果，各波段的判別正確率如表一所示，表中顯示各波段之分類正確率皆在 70% 以上，最佳的分類正確率為在紅外線波段

的 850~870nm 之影像，該判別率能達到 86% 的分類正確率。

表 1 單一波段多樣本 PCA 不同波段影像之判別正確率

波段 日數	300-400 nm (%)	850-870 nm (%)	400-700 nm (%)	480-560 nm (%)	560-620 nm (%)	400-770 nm (%)	850-1050 nm (%)
第 4 日	78	86	74	75	74	76	70

另外比較三種 PCA 特徵抽取策略的分類結果，如表 2 所示，單一波段多樣本的方法在紅外線波段 (850~870nm) 可達到 86% 的分類正確率；而單一様本多波段，結合所拍攝的七種波段，進行光譜特徵的資料轉換方式，該 PCA 的特徵參數僅用前 2 個主成分平均值進行分類，該方法可獲得 71% 的分類正確率，另外，若使用第三種的 PCA 特徵抽取方法，針對分光影像的「影像空間」及「光譜空間」資訊特徵抽取法，同樣採用前 23 個特徵向量為特徵空間，該方法能將分類正確率提升到 91% 之正確率，此結果顯示，比較這三種 PCA 策略，多波段多樣本的方法所抽取的特徵參數，對於原始影像樣本有較佳的特徵表現。

表 2 三種 PCA 特徵抽取最佳分類正確率之比較

判別方法 PCA 策略	貝氏分類器
單一波段多樣本 (850-870 nm)	86%
單一様本多波段	71%
多波段多樣本 (480-560nm+850-870nm)	91%

使用 PCA 方法針對具有大量資訊的影像，能夠達到不錯的壓縮效果，本研究使用單一波段多樣本的策略，每張影像大小為 292x292 像素點(Pixels)，經壓縮及抽取後的特徵，則只需要 23 個特徵即可達到不錯的判別成果；另外，對於多波段多樣本之試驗，每個樣本的資訊量為 292x292x2 像素點數目(Pixels)，同樣被縮減至 23 個特徵且結合了更多有用的資訊，結果指出，此不但能提升判別效能，亦可大幅縮減了分光影像資訊。

4. 結論

主軸成分法配合判別分析的貝氏分類器進行影像特徵歸類，PCA 的特徵抽取方法，可將複雜的影像辨識問題簡化，無須繁複的特徵抽取運算，即能有最佳的影像資訊表現，而 PCA 所提供的資料維度縮減方式，可針對分光影像降低龐大的特徵資訊，且不流失原始影像的重要資訊，試驗結果顯示，在不同 PCA 的抽取策略，利用多波段多樣本的 PCA 法則，對於這些擁有多種光譜特性的數位影像於特徵抽取上，較單一多波段、單一波段多樣本的抽取策略，有較佳的效果。另外，本方法亦能用在多維度的影像空間，例如應用在彩色數位影像的辨識上，彩色影像為 R、G、B 所產生的三維空間資訊，同樣能以 PCA 方法將此三維空間進行特徵的抽取及壓縮，對於彩色影像的圖案辨識，亦可提升辨識上的效率。本研究建議，此方法甚值得於資訊量龐大的數位典藏系統中，數位影像資訊儲存、檢索、及辨識等的研究應用。

5. 致謝

本研究承蒙行政院國科會計畫經費支助(計畫編號 93-2313-B-020-017)，特致謝忱。

6. 參考文獻

[1] 周文賢，2002，多變量統計分析：SAT / STAT 的使用方法，智勝文化，台北，965 頁。

- [2] Turk, M., Pentland, A., 1991, Eigenfaces for Recognition. *Journal of Cognitive Neuro-science*, 3(1), pp.71-86.
- [3] Kim, M. S., Lefcourt, A. M., Chen, Y. R., Kim, I. Chan, D.E., Chao. K., 2002, Multispectral detection of Fecal Contamination on Apples based on Hyperspectral imagery: part II. Application of Hyperspectral Fluorescence Imaging. *Transactions of the ASAE*, 45(6), pp.2039-2047.
- [4] Quintiliano, P., Santa-Rosa, A., 2003, ATR Applied to Multispectral Images Classification Based on KLT. *Pattern Recognition and Image Analysis*, 13(2), pp.173-191.
- [5] 楊美桂、上野洋一郎、柯俊良、陳怡菁、郭順宇、郭榮烈、陳泓志、胡威文、張傳偉，2000，植物組織培養與技術，藝軒，台北，322 頁。
- [6] 翁肇男，2004，多分光影像系統於培養基污染判別之研究，國立屏東科技大學機械工程系碩士班碩士論文，屏東縣，131 頁。
- [7] Huber, Reinhold, Ramoser, Herbert, Mayer, Konrad, Penz, Harald, Rubik, Michael, 2005, Classification of coins using an eigenspace approach. *Pattern Recognition Letters*, 26, pp.61-75.
- [8] 林金樹，2002，應用主軸轉換法辨認空載高光譜影像土地利用型特性之研究，*台灣林業科學*，17(3)，347-359 頁。
- [9] 張建邦，1997，多變量分析，三民圖書，台北，356 頁。
- [10] 鐘國亮，2004，影像處理與電腦視覺，東華書局，台北，420 頁。
- [11] Gonzalez, Rafael C., Woods, Richard E., 2002, *Digital Image Processing*, Prentice-Hall, New Jersey, USA, p.793.