

第二章 高光譜影像分析方法之回顧

高光譜影像分析一般包含了以下幾個步驟：(1)大氣改正 (Atmospheric Correction)，(2)資料轉換(Data Transformation)，(3)參考類別(Endmember)的選取與判釋，(4)影像分類(Classification)，及(5)分類精度之評估等，如圖 2-1。本章依處理步驟分別說明相關分析方法，包括：協變方矩陣(Covariance Matrix)與相關矩陣(Correlation Matrix)分析、主軸轉換分析(Principal Component Analysis)、MNF 轉換分析、參考類別選取之方法、光譜圖庫(Spectral Library)的建立、不同分類方法之原理及分類精度評估方式等等。最後另外說明以微分分析(Derivative Analysis)技術進行分類的原理及方法。

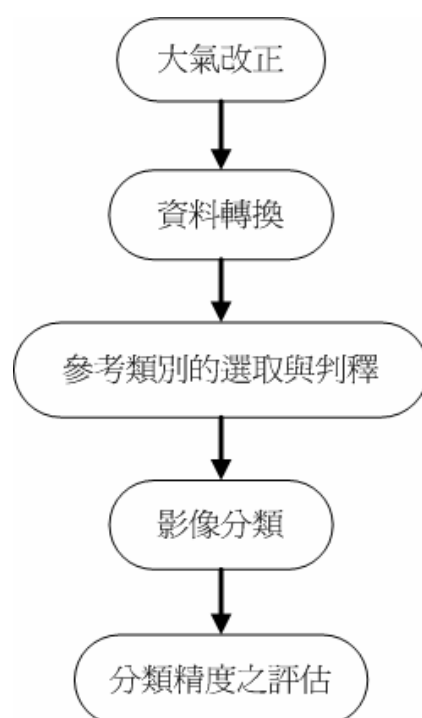


圖2-1 高光譜影像分析流程圖

2-1 協變方矩陣與相關矩陣分析

就單一波段而言，只需考慮單波段光譜反應值之平均值與其標準偏差；然而就 n 個波段而言，常必須知道兩兩波段間之相對變化量，因此必須計算各波段間

資料分佈的協變方矩陣或相關矩陣。協變方矩陣的計算公式如下：

$$\text{Covariance Matrix} = \begin{bmatrix} c_{11} & \cdots & c_{1n} \\ \vdots & \ddots & \vdots \\ c_{n1} & \cdots & c_{nn} \end{bmatrix} \quad (2-1)$$

$$\text{其為一對稱矩陣，其中 } c_{ij} = \frac{1}{N-1} \sum_{p=1}^N [(DN_{pi} - \mu_i)(DN_{pj} - \mu_j)] \quad (2-2)$$

i、j 為波段數，N 為總像元數， DN_{pi} 與 DN_{pj} 分別為第 p 個像元的第 i、j 個波段之光譜值， μ_i 與 μ_j 則為第 i、j 個波段光譜反應的平均值。對角線元素 c_{ij} 開根號後即為第 i 個波段之標準偏差。若協變方矩陣中的非對角線元素 c_{ij} 為負數，則表示若在波段 i 有極低之光譜反應值時，則在波段 j 則會有極高之光譜反應值，以此類推。

協變方矩陣可以轉換成相關矩陣，以觀查各波段間之相關性，相關矩陣計算方式如下：

$$\text{Correlation Matrix} = \begin{bmatrix} 1 & \cdots & \rho_{1n} \\ \vdots & \ddots & \vdots \\ \rho_{n1} & \cdots & 1 \end{bmatrix} \quad (2-3)$$

其中相關係數 $\rho_{mn} = c_{mn} / \sqrt{c_{mm} \cdot c_{nn}}$ 且 $|\rho_{mn}| \leq 1$ 。若相關係數為零 ($\rho = 0$)，則表示兩波段為不相關；相關係數為 1 或 -1 時 ($\rho = \pm 1$)，則表示兩波段具有高相關性。相關係數為正時表示正相關，即當兩波段中之一的光譜反應值增大時，另一波段之光譜反應值易增大；相關係數為負數時表示負相關，即當兩波段中之一光譜反應值增大時，另一波段之光譜反應值將會變小 [Schowengerdt, 1997]。兩波段間之相關性亦可藉由其在二維分佈圖 (Scatterplot) 中之分佈形狀分析，如圖 2-2 所示。由圖中可發現當點位分佈近似線性關係時，兩波段間具有高相關性；反之，若當分佈近似圓形，或成橢圓行且兩軸分別近似平行於座標軸時，則可說兩波段間呈現不相關的狀況。

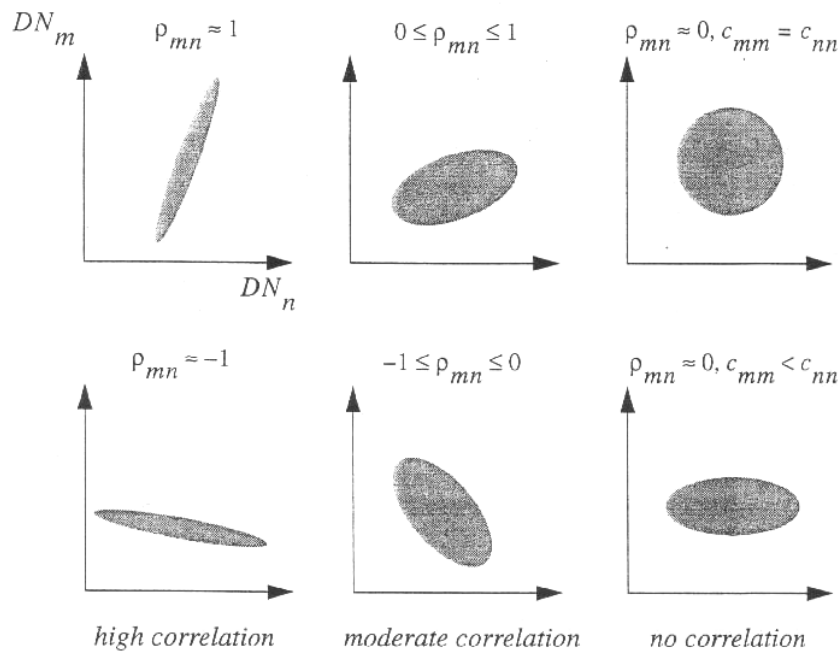



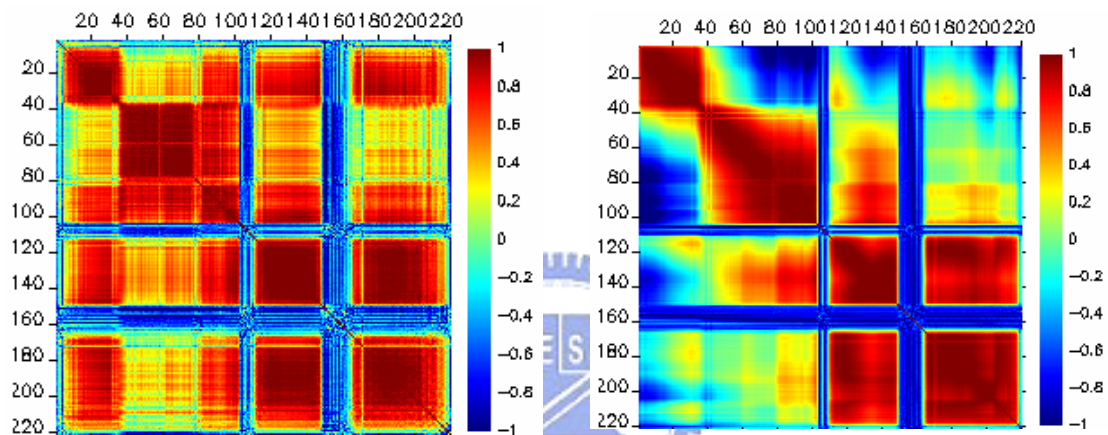
圖2-2 二維點分佈圖之形狀與相關係數之關係圖[Schowengerdt, 1997]

由於高光譜影像的波段數通常為數十或為數百個，為了易於檢視各波段間之變化情形，可藉由色彩展現高光譜資料中的協變方矩陣或相關矩陣的變化，如圖2-3。所示為普渡大學提供之印第安那州 AVIRIS 92AV3C 影像中計算所得燕麥與石塔之協變方矩陣及相關矩陣圖，相關矩陣圖中紅色或深藍色部份分別代表影像波段之間為正高相關或負高相關，而在協變方矩陣圖中色階亦代表其協變方值的大小。兩種圖形中所出現之帶狀現象亦為受大氣不同分子的吸收波段，例如103~112 波段與 148~166 波段，主要受大氣中水的吸收影響。圖2-3 (a)顯示燕麥於不同波段間協變方的變化量，可發現在紅光到近紅外光間有大的變方值存在(深紅色區域，從波段 22-70 處)；相對的，在深藍色區域處變方值相對較小。圖2-3 (b)顯示石塔於不同波段間協變方的變化量，可發現在可見光波段間有大的變方值存在(深紅色區域，從波段 6-35 處)；相反的，除去可見光與近紅外(VNIR)及受大氣吸收帶所影響之波段，則可發現其餘區域變方值相對較小(暗藍色)。此外在圖2-3 (c)與圖2-3 (d)中之深色(深紅及深藍色)部份代表波段間存在高相關，藉此可瞭解高光譜影像相鄰波段間之相關性，且不同類別間相關矩陣的差異性有助於提供分類時的資訊。



(a) 燕麥的協變方矩陣圖

(b) 石塔的協變方矩陣圖



(c) 燕麥的相關矩陣圖

(d) 石塔的相關矩陣圖

圖2-3 燕麥與石塔的協變方矩陣與相關矩陣圖

2-2 資料轉換

資料轉換的主要目的是將影像從其原始資料空間轉換至另一個資料空間，以凸顯某些重要的資訊或特徵，提升後續影像判釋及處理之效率。對於高光譜影像而言，各個波段間存在有很高的相關性，即高光譜資料本身存在有很高的冗餘性 (Redundance)。因此，如何對高光譜資料進行轉換，以萃取出重要的資訊或特徵為重要的研究課題之一。在傳統遙測影像分析上，最常用到的資料轉換方法有主軸分析法 (Principal Component Analysis, PCA)、波段比 (Band Ratio)、標準化植生指標 (Normalized Differential Vegetation Index, NDVI) 及傅立葉頻譜轉換 (Fourier Spectrum Transform) 等等。若於 PCA 轉換之前，加入雜訊模式 (Noise Model) 之考

量，使得轉換後之資料依照訊號之量排序，而非如 PCA 僅由變方大小排序，此方法稱為 MNF 轉換(Minimum Noise Fraction Transformation) [Green et al., 1988]。以下分別就主軸轉換及 MNF 轉換分別敘述其基本原理。

2-2-1 主軸分析(Principal Component Analysis, PCA)

主軸轉換的目的在將高光譜影像資料線性轉換到一個新的資料空間，移除原始資料波段間的相關性，產生一系列新的成分影像(Components)，其中資料變異量較大影像的做為主成分影像[Richards, 1993]。在圖 2-4 中，原本相關性很大的 DN_1 及 DN_2 資料經主軸轉換之後，主成分 PC_1 指向資料散佈較大的方向，而第二成份與第一成份則呈現正交的關係。於後續處理時，選取主軸轉換的前幾個成分可以降低原始資料的維度，達到特徵萃取之目的。主軸轉換的計算公式為：

$$PC = W_{PC} \cdot DN \quad (2-4)$$

其中 W_{PC} 為原始影像協變方矩陣之特徵向量(Eigenvectors)。

為了使轉換後之主軸影像互不相關，轉換後影像 PC 之協變方矩陣應為一對角線矩陣：

$$C_{PC} = W_{PC} C W_{PC}^T \quad (2-5)$$

$$C_{PC} = \begin{bmatrix} \lambda_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \lambda_k \end{bmatrix} \quad (2-6)$$

其中 C 為原始影像 DN 之協變方矩陣， λ_i 為特徵方程 $|C - \lambda I| = 0$ 之特徵值(Eigenvalues)， I 為單位矩陣。

經由主軸轉換後之影像，其協變方矩陣中所有特徵值之總和將等於原影像中所有波段變方之總和，亦即保留住原始資料之所有資訊[Schowengerdt, 1997]；且因轉換時其變方值以大小降冪方式排序： $\lambda_1 > \lambda_2 > \cdots > \lambda_k$ ，即 PC_1 影像具有最大的變異量，而 PC_k 為包含最小變異量之影像；因此前面數個成分影像即包含原影

像中大部分的資訊，因此在進行影像分類或資料壓縮時可以選擇前幾個成分影像當做是較重要的特徵。圖 2-5 為高光譜影像經主軸轉換後之成果，可以明顯地看出前幾個成分影像中各類別之間的差異較為明顯，反之特徵值較小的影像各類別間的差異性較小，甚至出現雜訊影像。主軸轉換之缺點為當影像完成轉換後，其主軸影像的視覺品質時常不與其排序成正比，圖 2-5 中可發現主軸影像中，第 9 幅之影像視覺品質明顯比第 8 幅好，且第 23 幅也比第 19 幅好。

由於主軸轉換係對整體影像進行資料轉換，並未考慮各個類別的資料散佈情況，且主軸轉換易受雜訊之干擾而使得主軸的顯著性不夠，無法明顯的和雜訊區隔開。有些具有小變異量的波段並不意味著粗劣的影像品質，這樣的波段可能比其他的波段帶有更高的訊雜比(SNR)；相對的，低訊雜比有可能是大的變異量。因此，若忽略這些小變異量的波段，則會造成影像品質維度估測不正確；反之，若試圖保留這些較小變異量的波段，則波段數增加且雜訊之影響無從去除。

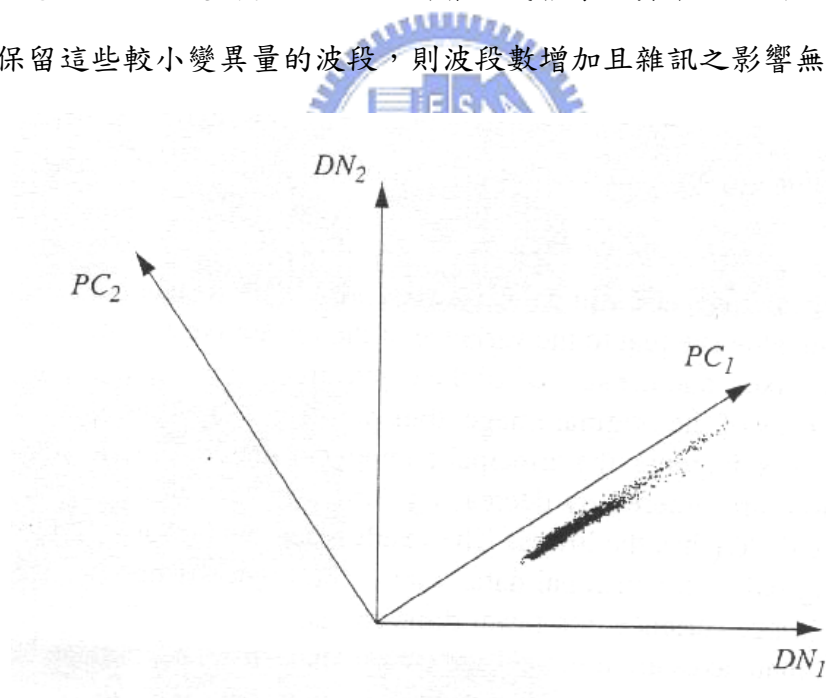


圖2-4 二維空間主軸轉換示意圖[Schowengerdt, 1997]




圖2-5 主軸轉換後影像成果(以MASTER影像為例)

2-2-2 MNF 轉換(Minimum Noise Fraction Transformation)

一般當影像完成主軸轉換後，其主軸影像的品質容易受雜訊所影響，因此 Green et al. [1988]提出最小雜訊分量(Minimum Noise Fraction, MNF)轉換以降低雜訊對主軸轉換成果之影響，為此 MNF 轉換將訊雜比(Signal-to-noise, SNR)視為是對影像品質評估的一個指標，藉以分離原始影像中之雜訊及訊號。MNF 轉換的概念仍以主軸轉換為基礎，其差別在於尋找轉換軸時以最大訊雜比取代原本的最大變方，其方法如下：

考慮一個 p 波段的多變量灰階為：

$$Z_i(x), i=1, \dots, p \quad (2-7)$$

這裡的 x 為樣本的座標，則可假設：

$$Z(x) = S(x) + N(x) \quad (2-8)$$

其 $Z^T(x) = \{Z_1(x), \dots, Z_p(x)\}$ ，且 $S(x)$ 與 $N(x)$ 為 $Z(x)$ 之兩不相關的訊號及雜訊成分，因此

$$\text{Cov}\{Z(x)\} = \Sigma = \Sigma_S + \Sigma_N \quad (2-9)$$

Σ_S 與 Σ_N 各自為 $S(x)$ 及 $N(x)$ 的協變方矩陣。

接著定義第 i 個波段的「雜訊量比例」(Noise Fraction)為

$$\text{Var}\{N_i(x)\} / \text{Var}\{Z_i(x)\} \quad (2-10)$$

則 MNF 轉換採取線性轉換模式，

$$Y_i(x) = a_i^T Z(x), \quad i=1, \dots, p \quad (2-11)$$

其中 a_i 為 $\Sigma_N \Sigma^{-1}$ 之特徵向量，且 μ_i 為 a_i 之特徵值亦為 $Y_i(x)$ 中的「雜訊量比例」。因此，從 MNF 定義中可知，當 $\mu_1 \leq \mu_2 \leq \dots \leq \mu_p$ 時，其轉換後的影像品質隨波段的增加而降低，即前面的波段影像視覺品質比後面波段好，成果影像如圖 2-6。

由上述之條件可得知，如要進行 MNF 轉換計算，必須要先知道 Σ 及 Σ_N ，其中 Σ_N 必須從影像中估計求得。在 MNF 轉換中， Σ_N 之估計方式採用 MAF 模式(Minimum/Maximum Autocorrelation Factors Model)。MAF 雜訊協變方矩陣預估模式為假設於遙測影像中，訊號像元不論位於影像之何處，其與相鄰之像元應為高相關；反之，雜訊像元之空間相關性低。遙測影像中常產生之雜訊如條紋狀雜訊(Striping Noise)或是隨機雜訊(Salt-and-pepper Noise)都適合此模式。根據上述之基本雜訊預估假設，可以將 MAF 雜訊預估視為是利用相鄰影像灰度值差之協變方矩陣，推算得到雜訊之協變方矩陣 Σ_N 。

因影像像元中之 $S(x)$ 與 $N(x)$ 互不相關，設相鄰像元之訊號及雜訊協變方矩陣分別為：

$$\text{相鄰像元訊號協變方矩陣：} \text{Cov}\{S(x), S(x+\Delta)\} = b_\Delta \Sigma_S \quad (2-12)$$

$$\text{相鄰像元雜訊協變方矩陣：} \text{Cov}\{N(x), N(x+\Delta)\} = c_\Delta \Sigma_N \quad (2-13)$$

其中 b_Δ 與 c_Δ 為常數，當相鄰影像中訊號為高相關則 $\text{Cov}\{S(x), S(x+\Delta)\}$ 與 Σ_S 近似，即 $b_\Delta \approx 1$ ；此時 $\text{Cov}\{N(x), N(x+\Delta)\}$ 則趨近於 0，亦即 $c_\Delta \approx 0$ 。如此 $\Sigma_\Delta \Sigma^{-1}$ 之特徵向量與 $\Sigma_N \Sigma^{-1}$ 則有一定程度的近似。兩者間的關係如式 2-14：

$$\mu_i = \frac{\lambda_i / 2 - (1 - b_\Delta)}{b_\Delta - c_\Delta} \quad (2-14)$$

λ_i 為 $\Sigma_\Delta \Sigma^{-1}$ 之特徵向量，

當 $b_\Delta \approx 1$ 且 $c_\Delta \approx 0$ 時， $\lambda_i / 2$ 可視為 $\text{Var}\{Y_i(x)\}$ 中雜訊之近似預估值。可求得如式 2-15：

$$1 - \lambda_i / 2 = \text{corr}\{Y_i(x), Y_i(x+\Delta)\} \quad (2-15)$$

其中 $1 - \lambda_i / 2$ 為第 i 個 MNF 之相鄰像元的相關係數。





圖2-6 MNF轉換後影像成果(以MASTER影像為例)

此外，MNF 轉換後之影像中有時仍可發現部分影像視覺品質排序前後顛倒，此應為其雜訊模式不佳或不能完整預估影像之雜訊協變方矩陣之故。如圖 2-7 中之第 14 及 16 幅 MNF 影像即為一例。



第 14 幅影像

第 16 幅影像

圖 2-7 MNF 轉換後部分影像品質排序明顯顛倒(以 MASTER 影像為例)

2-3 參考光譜(Endmember)之選取

在光譜混合求解中，參考光譜的選擇為一關鍵性的步驟[Lin et al., 2004]。一般參考光譜選定之評估標準包含線性獨立、光譜及空間之總括描述[Maselli, 1998]。若參考光譜間具有高相關性，將使得求解過程與結果產生不完善及不可靠的情況，且求解同時使用非代表性的參考類別亦將使其分量估算產生不正確的結果。一般而言，參考光譜選定的方式有兩種，一為從影像本身選取，另一為從事先建立好的光譜圖庫中選取。光譜圖庫中的地物光譜大都是在具理想狀況的實驗室中建立，可真實地描述地物獨一無二的光譜反應；然而，通常需要大量的人力及時間來建置一個完整的光譜圖庫。在沒有光譜圖庫可用的情況下，如何從影像中選取具代表性的參考光譜是一個重要關鍵。Boardman [1993]提出將原始資料重複投影到維度較低空間的單位向量，並找出位於向量兩端(Extreme)的像元，視其為參考光譜之像元。經重複投影及累積計算之後，可以計算每一個像元之純度

指標(Pixel Purity Index, PPI)，之後配合 n-維資料視覺工具反覆選取，根據 PPI 選取出地物參考地物之依據[Boardman et al., 1995; Kruse et al., 1996; Kruse et al., 2000]。

2-3-1 純像元之決定

純像元之決定可以利用波段間的二維分佈圖(Scatter Plot)以凸面幾何理論(Convex Geometry Argument)輔助判斷[Boardman, 1993]，在凸面幾何上的角(Corner)即可能為類別的位置，以此可作為類別的選擇依據。然而以二維方式選取恐因維度空間的關係造成類別數量選取的重複或錯誤，故可將其投影至 n 維的空間進行選取，或配合多組二維分佈圖反覆分析。

將經前一步驟選取之像元進行反覆迭代，即資料一再的投影於隨機單位向量上，並記錄每個投影的端點像元(Extreme Pixels)與累積計算值，如此可得到一個純度像元影像(Pixel Purity Image)。大部分光譜純像元與混合類別相符合，利用門檻值的設定僅選擇最具純度的像元，以保持最小量的分析處理。

2-3-2 n 維視覺化

如上述由於僅以二維方式進行類別的選取，恐因維度空間的關係造成類別數量選取的重複或錯誤，故將其投影至 n 維的空間進行選取，這也就是為何採用 n-D Visualization 的原因。利用一個幾何模型可將光譜視為點在 n 維(波段數)的分佈，而這些在 n 維空間分佈的點可用來評估光譜類別數與它們的純光譜圖樣。在 n-D Visualization 中以互動的方式檢視類別在 n 維空間的分佈及類別間的分離度，藉以選定各類別。在幾何圖形中純度類別出現在頂點處；而混合類別出現於沿著線(兩種類別混合)與面(一個三角形內的三種類別混合、四邊形內的四種類別混合，以此類推)，如圖 2-8。

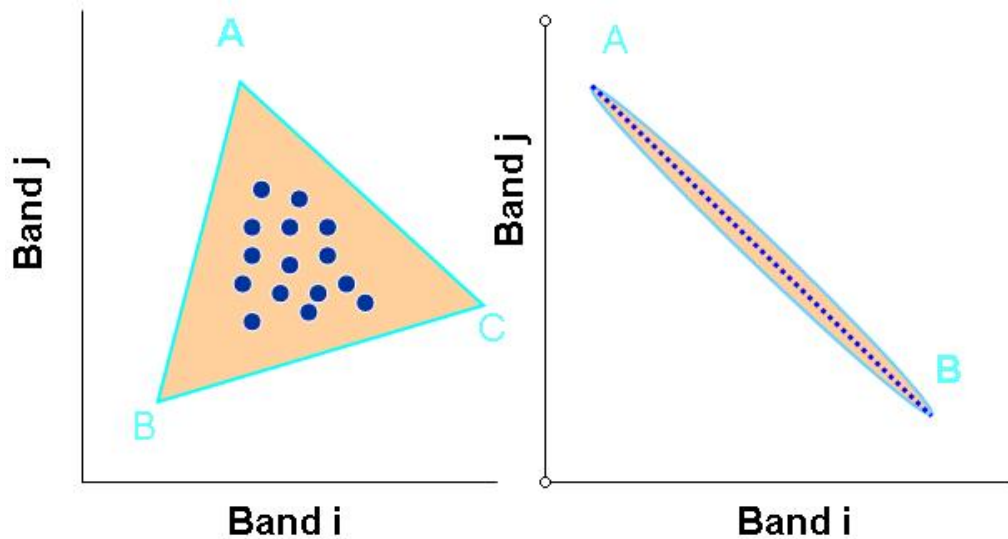


圖2-8 各類別與混合關係之二維分佈示意圖

2-4 光譜圖庫(Spectral Library)

遙感探測中，大多光譜圖庫的產生建立乃由於地球與行星成像光譜學的研究需求。不論是從實驗室、航空器或是太空船上，其光譜學的資料分析皆仰賴於一個知識基礎。而光譜圖庫(Spectral Library)提供了這樣一個知識，詳述礦物及其他種種重要相關物質之光譜特性。例如，AVIRIS (Airborne Visible/Infra-Red Imaging Spectrometer)成像光譜儀，本身具有大量、連續波段且光譜波段之間範圍狹窄的特性，提供可精確定義各種物質之吸收特徵，這樣資料中的物質識別則需要一個具有礦物、植被、人工與其它物質等廣泛的光譜圖庫作為辨識的基礎。因此，光譜圖庫的品質必須非常的良好；然而，品質的好壞依賴於科學問題的解決與演算法的使用。當地面物質進行光譜比對時，需要先將物質的輻射反應值轉換成光譜反應值，此時欲比對的地面物質可能並非純度樣本，只要具有特徵的吸收波段(Absorption Bands)之診斷特徵(Diagnostic Feature)未受影響，亦可進行光譜比對[Clark et al., 1993]。

光譜學乃在研究光線從固體、液體與氣體經放射、反射及散射的波長函數[Clark, 1999]。當光子進入一個物質時，部分從晶體反射，部分通過晶體，另外部份則被吸收。物質的所有反應過程乃由於不同物質本身具備有其特殊的化學成

分及原子與分子之種類與排列型式，這也使得不同物質的光譜強度與形狀具有其獨特性，這樣的光譜吸收波段形狀與位置即為光譜特徵。近年來光譜學原理已成功應用在不同物質的量測與識別上，例如礦物(Kruse et al., 1993; Clark & Swayze, 1995)、植被(Ustin et al., 1997)、植物特性(Gamon et al., 1993; Roberts et al., 1993; Ustin et al., 1996)、雪與冰(Clark & Swayze, 1995)及土壤(Palacios-Oreuta & Ustin, 1996)。

物質的光譜吸收波段產生的原因一般有兩種過程：電子(Electronic)及振動(Vibrational)。在原子或分子層的電子運動過程中，不同物質之原子層隨著晶體的結構而變化，產生不同的吸收作用，這可作為以光譜學分析及識別特殊物質的基礎。圖 2-9 展示兩種輝石(Pyroxene)的反射光譜曲線，圖中可發現在波長 $1\ \mu\text{m}$ 與 $2\ \mu\text{m}$ 處，透輝石(Diopside)與古銅輝石(Bronzite)之間的吸收波段位置與形狀有所改變，這是由於兩種物質所含的 Fe^{2+} 量不同之原因。

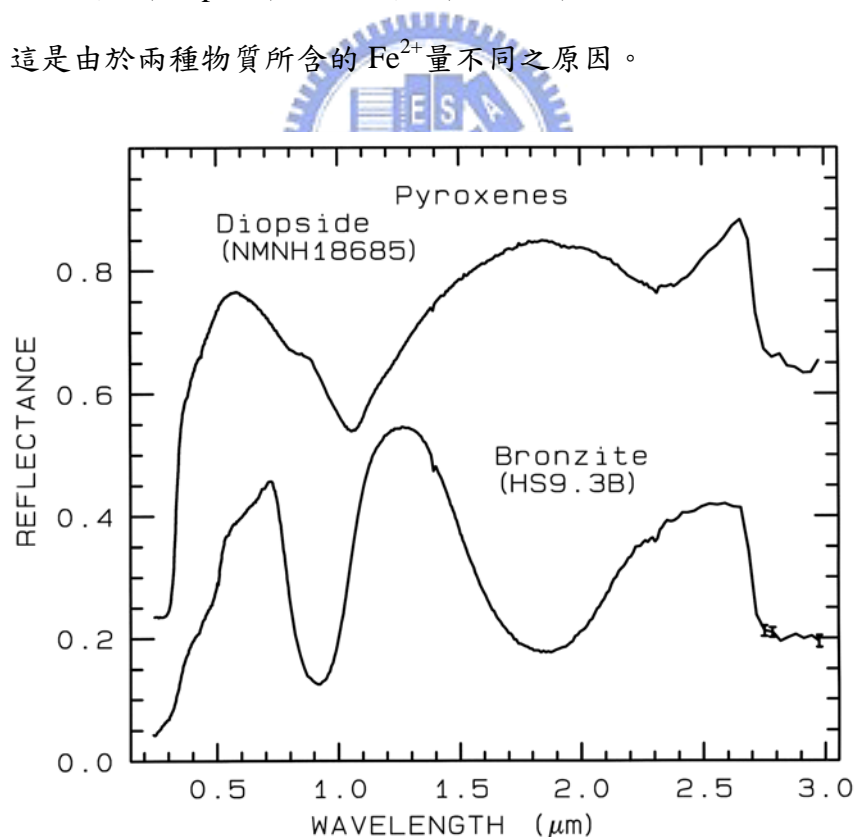


圖2-9 兩種含 Fe^{2+} 量不同之輝石光譜反射值[Clark, 1999]

另外在振動的過程中，分子中的原子與離子間或是晶體晶格(Crystal Lattice)像似跳躍般的相關聯，所以整個系統能夠振動；不同的振動頻率在某些特殊的波

長處產生吸收波段，分子中的振動頻率取決於每一個元素的關聯與質量。例如水(H₂O)、氫氧根(OH)、碳酸鹽(CO₃)、磷酸鹽(Phosphate)、硼酸鹽(Borate)、砷酸鹽(Arsenate)和釩酸鹽(Vanadate)為產生特殊診斷振動吸收過程的典型物質，如圖2-10。

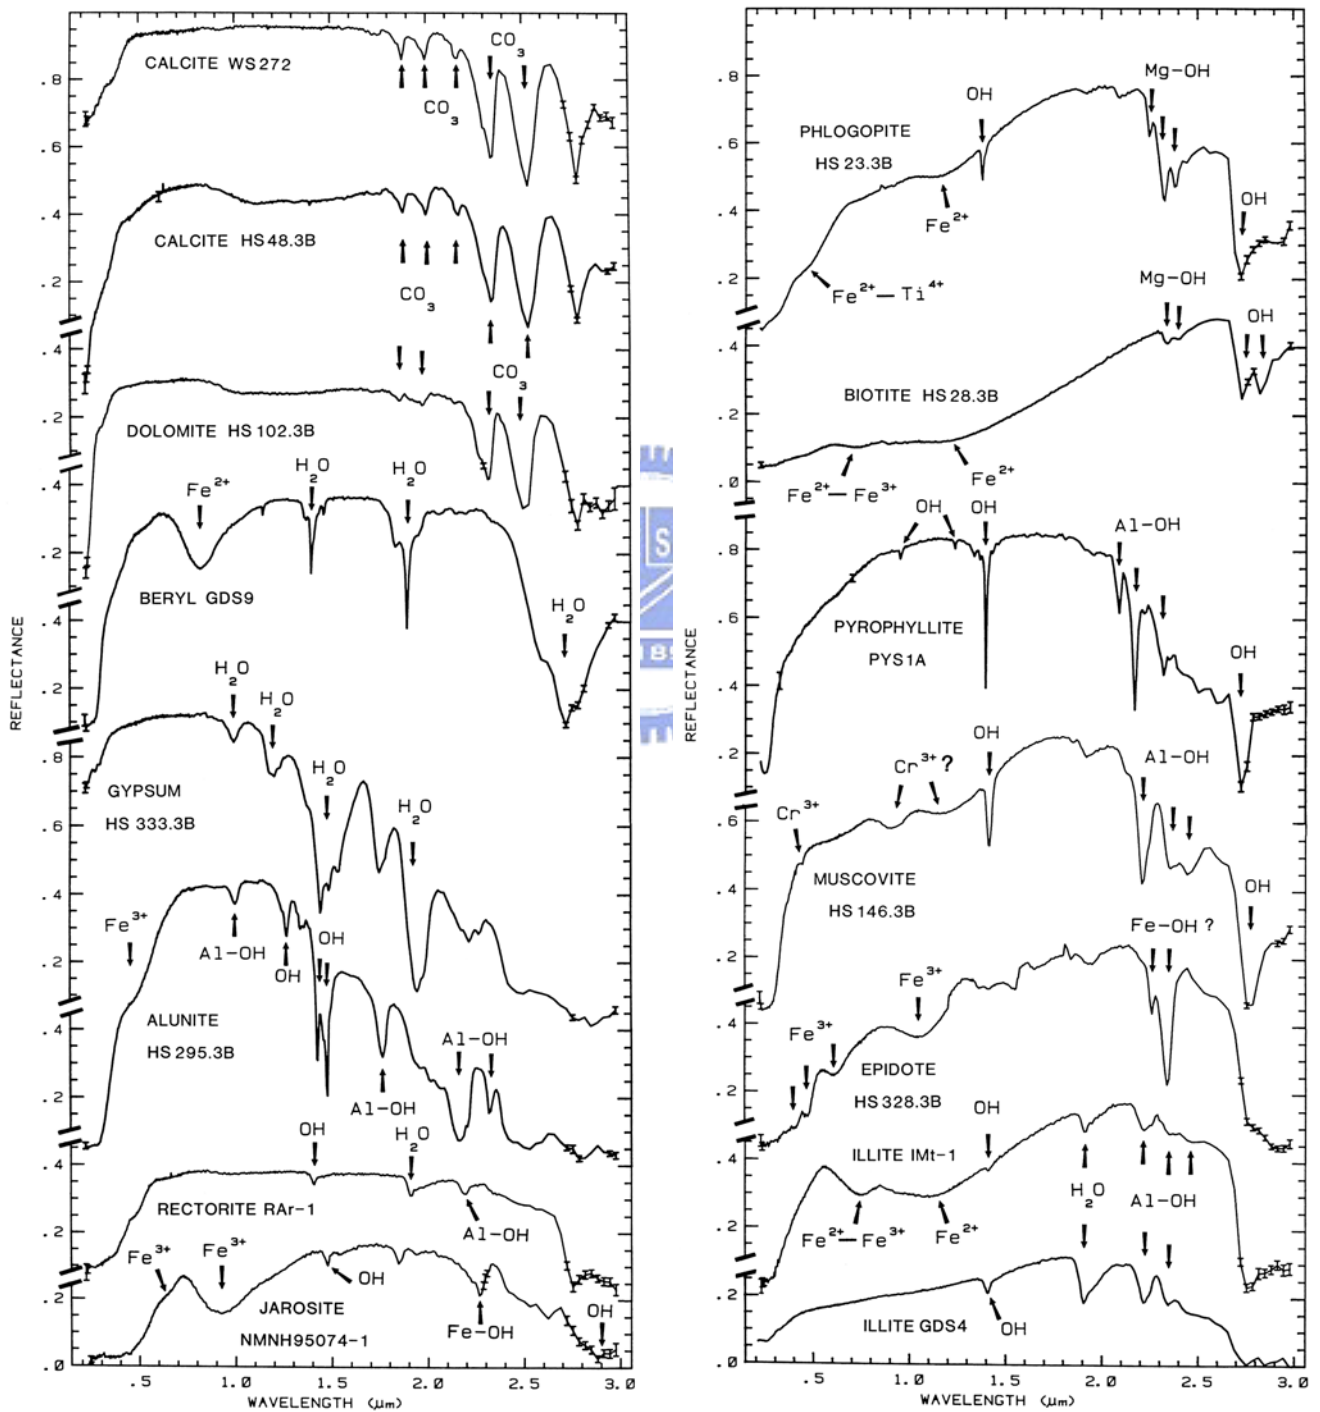


圖2-10 水(H₂O)、氫氧根(OH)、碳酸鹽(CO₃)的振動波段[Clark, 1999]

礦物的光譜學吸收原理亦可應用於植被上，大體來說，所有植被的光譜大都相似，主要原因乃在於它們具有相同的基本成分，如葉綠素(Chlorophyll)、水、纖維素(Cellulose)、木質素(Lignin)及氮(Nitrogen)。一般植被光譜具有以下兩種類型：(1)光合作用(綠色與含水分)植被，(2)無光合作用(乾燥)植被。而實際上植被的光譜係為此兩種物質的混合。圖 2-11 展示綠色植被、乾燥植被及土壤的反射光譜，圖中可發現綠色植被在中紅外線 1.4 μm 、1.9 μm 及 2.5 μm 處有顯著的吸收波段，乃由於液態水振動吸收過程所產生；且綠色植被在可見光的範圍(0.7 μm) 產生劇烈的跳動，稱之為紅邊(Red-edge)，這是由於植被中葉綠素的影響，此亦為植被重要之光譜特徵，並可用來描述植物狀態與健康情形的指標。另外，乾燥植被的光譜受纖維素、木質素及氮的影響亦有些許吸收過程。




圖2-11 綠色植被、乾燥植被及土壤的反射光譜[Clark, 1999]

建立一個理想的光譜庫應考慮五個因素：(1)具代表性的物體樣本(Pure Samples)、(2)多種的覆蓋物質、(3)大的波譜範圍與非常高的準確性、(4)樣本分析及(5)建立光譜品質的文件。然而，由於預算、時間與可利用的設備等限制因素常無法完全滿足以上五個條件。理想情況下，當進行礦物樣本分析時，應包含

X 光繞射(X-ray Diffraction, XRD)、電子探測針(Electron Microprobe, EM)或 X 光螢光(X-ray Fluorescence, XRF)及岩石分類的顯微分析(Petrographic Microscopic Analyses)；此外，為了某些礦物如鐵氧化物(Iron Oxides)，則需再如入梅思堡(Mossbauer)效應的分析[Clark et al., 1993]。

2-5 光譜混合求解

理想狀況下，影像中一個像元只記錄單獨一個地物類的光譜反應，則稱此像元為純像元(Pure Pixel)，然而實際上遙測影像的像元所對應的 GIFOV 不只涵蓋一種類型的地面覆蓋物，此時稱其為混合像元(Mixed Pixels)，如圖 2-12 所示。光譜混合求解(Spectral Unmixing)的主要目的即定性地求出各種地物於每一個像元中所佔的比例。早期由於感測器之光譜解析度較低，致使以光譜混合求解方法進行影像分類受到限制；然而，成像光譜儀的出現，使得高光譜影像的波段數目增加很多，提升了以這種方式應用於影像分類的可能性。

如第一章所述，造成混合像元的原因很多，因此選擇一適當的數學模式來描述光譜混合的現象在光譜混合求解中為一關鍵問題。最常用的光譜混合模式為線性混合模式(Linear Mixing)，其假設輻射線與地面之間的交互作用是單一的，如圖 2.13(a)所示，因此單一像元之光譜反應為各種純地物光譜反應之線性組合；惟實際上輻射線與地面之間的交互作用並非是單一的，例如單一像元的光譜反應可能來自植被覆蓋(Vegetation Canopy)的第一次反射與土壤表面的第二次反射之總和，也有可能包含來自土壤內層的多種反射，如圖 2.13(b)所示，此時必須使用非線性混合(Non-linear Mixing)模式來描述混合像元。[Roberts et al.,1993; Borel & Gerstl, 1994; Ray & Murray, 1996; Tseng, 1999]。本文將探討三種以線性混合模式為基礎的光譜混合求解方法，即線性光譜混合求解、匹配濾波(MF)及混合調協匹配濾波(MTMF)等，以下分別說明其基本原理。

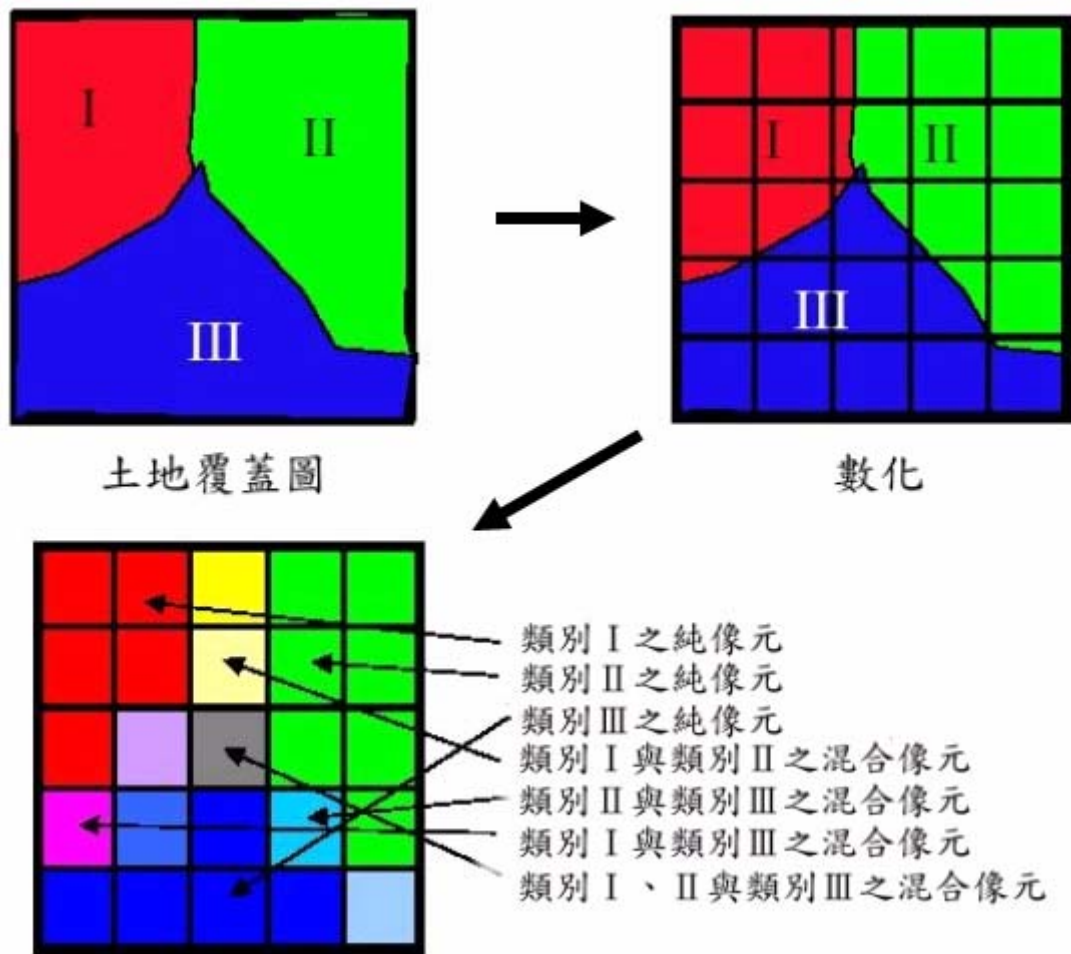



圖2-12 影像中純像元與混合像元示意圖



(A)線性光譜混合

(B)非線性光譜混合

圖2-13 線性光譜混合與非線性光譜混合模式之示意圖[Keshiva and Mustard,

2001]

2-5-1 線性光譜混合求解(Linear Spectral Unmixing)

線性光譜混合求解假設影像中單一混合像元之光譜反應為各種純地物參考光譜之線性組合，利用已知的參考光譜可以求出一個混合像元內各參考光譜所佔之比例(Fraction) [Lin et al., 2004]。線性混合模式可以一個線性矩陣方程式描述：

$$r(x, y) = M\alpha + n \quad (2-16)$$

其中 r 為觀測向量，亦為影像中任一個像元 (x, y) 灰度值的觀測向量，矩陣大小為 $l \times 1$ ， l 為光譜波段數，

M 為類別矩陣，大小為 $l \times p$ 。

α 為分量矩陣，大小為 $p \times 1$ 。

n 為雜訊矩陣，大小為 $l \times 1$ 。

M 矩陣是由 p 種不同類別的矩陣所組成， $M_1, M_2, M_3, \dots, M_i, \dots, M_p$ ，其中任一個類別的矩陣 M_i 亦為大小 $l \times 1$ 之矩陣，代表第 i 種類別在光譜上的特性。 α 矩陣係由 $(\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_i, \dots, \alpha_p)^T$ 所構成，其中任一個分量 α_i 代表是像元 (x, y) 屬於第 i 種類別時的機率，存在有以下的限制條件：

$$\sum_{i=1}^p \alpha_i = 1, \quad 0 \leq \alpha_i \leq 1 \quad (2-17)$$

n 為雜訊矩陣，可用來評估線性光譜混合求解結果之均方根誤差(RMSE)：

$$RMSE = \sqrt{\frac{\sum_{i=1}^l (n_i)^2}{l}} \quad (2-18)$$

當 RMSE 的值大時，代表線性混合模式的假設並不恰當，或是所選取的參考光譜並不適合描述地面真實的覆蓋[Lu et al., 2003]。

相較於多光譜影像，線性光譜混合求解法更適用於分析高光譜影像資料，乃由於高光譜影像的波段數目可達二百個以上，可形成一條視為連續的光譜曲線，不同的物質於不同波長時具有不同之光譜反應，此種光譜圖樣的差異性即可做為

地物辨識的依據。反之，多光譜影像因為其波段寬度一般約在 100~200 nm 左右，故波段數目較少，不易顯示出不同物質之光譜圖樣的差異性。且以線性光譜混合求解法進行分析，所強調的乃需要參考類別的純光譜值，並非如統計為基礎的分類法取決於樣本的數量；這也就是說，若以混合像元的光譜作為參考類別光譜值，則求解的結果必產生錯誤的現象。

由於線性光譜混合求解法假設影像中每個像元內的光譜反應值為該像元內不同物質光譜反應之線性組合，利用線性方程式可以求解出各類別相對的含量比例。採用此方法仍有其限制，亦為(1)所有類別總數必須小於影像光譜的波段數，且(2)必須已知影像中所含全部類別的參考光譜值，因為在線性光譜混合求解的模式下，如果像元內的主要類別被移除則次要類別將取而代之，如此將導致不正確之分類結果。

2-5-2 匹配濾波(Matched Filter)

匹配濾波法的目的乃增顯混合像元內已知地物之重要性，抑制未知地物或背景之影響，以解決如上節所述線性光譜混合求解之缺點。其方法乃利用使用者所定義之類別為參考光譜，進行部分混合求解(Partial Unmixing 或稱 Matched Filtering)以估算使用者所定義之各類別的比例含量。其方法如下：

利用線性混合公式，將觀測光譜值分成上述兩部分： d (欲求解之參考光譜) 及 U (欲抑制之地物或背景)

$$r = M\alpha + n = d\alpha_p + U\alpha_{p-1} + n \quad (2-19)$$

假設類別矩陣 M 中最後一欄為某一特定類別的參考光譜 d ，剩下的其他欄位則以矩陣 U 來表示， U 為一個 $l \times (p-1)$ 的矩陣，其 $U = (U_1, U_2, U_3, \dots, U_{p-1})$ 代表其他剩下的類別，亦為不感興趣的類別。

對 r 進行投影轉換 $w^T r_i$ ，轉換後使其能量最小 $E = (w^T r)^2 = \min$ ，且使 $w^T d = 1$ ，可引進 Lagrange 常數 2λ ，使得

$$F = \Sigma(w^T r)^2 - 2\lambda(w^T d - 1) = \min \quad (2-20)$$

上式對 w 及 λ 進行偏微分，可得

$$w = \frac{R^{-1}d}{d^T R^{-1}d} \quad (2-21)$$

其中 $R = \Sigma rr^T$ 為所有光譜資料觀測值之相關係數。

在高光譜影像中 R 容易受到限制，因為當最大特徵值與最小特徵值的比率過大時，則誤差亦可能降低 R^{-1} 的精度，為了 R^{-1} 的計算有更好的精度，相關矩陣僅使用最前面 p 個重要的特徵向量表示，方程式如式 2-22：

$$R = V\Lambda V^T \quad (2-22)$$

$V = (v_1 \dots v_i \dots v_p)$ ，係為樣本相關矩陣之特徵向量的 $l \times p$ 矩陣。

$\Lambda = \text{diag}(\lambda_1 \dots \lambda_i \dots \lambda_p)$ ，為樣本相關矩陣之特徵值的 $p \times p$ 對角線矩陣。

經匹配濾波法處理後，若像元中並無目標物質的存在時，其 DN 值為 0；反之，若目標物質完全覆蓋於像元中時，其 DN 值為 1。實際上，由於目標物的自然物質其光譜圖樣具有變化性或者其他類別沒有良好的特徵性質，也可能是 V 組成中的特徵向量選取的不適當，都可能使結果的 DN 值產生負值或是稍微大於 1 的現象產生 [Farrand & Harsanyi, 1997]。

2-5-3 混合調協匹配濾波(Mixture Tuned Matched Filtering)

由於匹配濾波法乃增顯混合像元內已知地物之重要性，抑制未知地物或背景之影響，但也使得在各類別的分量中產生不正確正值(誤授)的現象。相對的，混合調協匹配濾波(Mixture Tuned Matched Filtering, MTMF)是一種結合匹配濾波及線性混合的理論為光譜混合方式，利用匹配濾波具有容易計算與在其他類別未知的情況下可處理單個類別之特性，並藉由線性混合模式給予限制條件 [Boardman, 1998; Kruse et al., 2000]。經 MTMF 的分析後，可得到各類別的匹配濾波及不可信度(Infeasibility)的分量影像，並藉由類別的兩種分量影像之二維分佈圖找出不

正確正值像元及具有高匹配濾波分量且低不可性度分量的像元的分佈位置，圖 2-14 為 MTMF 的圖解說明。圖中等量或然率收斂於目標光譜的圓錐體，且亦描述目標光譜與混合光譜的分離情形，其中大於 3δ (99.7%的信心區間)外的值視為該類別匹配濾波分量之不正確正值。




圖2-14 MTMF方法示意圖[Kruse et al., 2000]

2-6 分類精度評估之方法

以不同的分類方法進行影像分類後可得到不一樣的分類成果，為了評估且相互比較分類成果的好壞，則必須有一客觀的評估指標作為評斷依據，一般最常用評估指標為誤差矩陣(Error Matrix)，主要是比較實驗區影像之參考資料(地真資料)與分類成果間的關係。誤差矩陣的大小是依據影像分類之類別數目而定，對角線各元素即為分類正確之像元數，其他非對角線各元素則為分類錯誤之像元個數，如表 2-1 所示。

表 2-1 誤差矩陣之型式

		分類成果			
		類別-1	類別-2	合計	UA
檢核精度	類別-1	E_{11}	E_{12}	N_{r1}	P_{A1}
	類別-2	E_{21}	E_{22}	N_{r2}	P_{A2}
	合計	N_{c1}	N_{c2}	N	
	PA	U_{A1}	U_{A2}		
整體精度：OA 平均精度：AA <i>Kappa</i> 指標：K					

分類錯誤又可分為漏授(Omission Error, OE)及誤授(Commission Error, CE)兩種。另外利用誤差矩陣內之數值，又可計算出幾個常用的分類精度指標，例如生產者精度(Producer's Accuracy)、使用者精度(User's Accuracy)、整體精度(Overall Accuracy)、平均精度(Average Accuracy)及 *Kappa* 值等評估指標，簡單說明如下：

1. 生產者精度(Producer's Accuracy)

$$PA = \frac{E_{ii}}{E_{i+}} \times 100\% \quad (2-23)$$

2. 漏授誤差(Omission Error)：表示已知類別被遺漏而歸納到其它類別。

$$OE = 1 - PA \quad (2-24)$$

3. 使用者精度(User's Accuracy)：表示分類後之類別被正確歸類之百分比。

$$UA = \frac{E_{ii}}{E_{+i}} \times 100\% \quad (2-25)$$

4. 誤授誤差(Commission Error)：表示分類後之類別被分類錯誤之百分比。

$$CE = 1 - UA \quad (2-26)$$

5. 整體精度(Overall Accuracy)：代表誤差矩陣之對角線被正確分類總數與像元總數的比例。

$$OA = \left[\frac{1}{N} \sum_{i=1}^r E_{ii} \right] \times 100\% \quad (2-27)$$

6. 平均精度(Average Accuracy)：被正確分類百分比的平均值，即生產者精度加總

後之平均值。

$$AA = \left[\frac{1}{N} \sum_{i=1}^r \frac{E_{ii}}{E_{i+}} \right] \times 100\% \quad (2-28)$$

7.Kappa

$$K = \frac{OA - CA}{1 - CA} = \left[\frac{N \sum_{i=1}^r E_{ii} - \sum_{i=1}^r (E_{i+} \times E_{+i})}{N^2 - \sum_{i=1}^r (E_{i+} \times E_{+i})} \right] \times 100\% \quad (2-29)$$

其中：

CA (Change Agreement) 為預期隨機分類正確率。

E_{ii} 為誤差矩陣中對角線元數。

E_{i+} 為誤差矩陣第 i 列之和。

E_{+i} 為誤差矩陣第 i 行之和。

整體而言，整體精度及平均精度只考慮誤差矩陣之對角線元素，亦即分類正確部分，故無法完整表示出分類成果精度。相較之下 $Kappa$ 指標則同時考慮了誤差矩陣中對角線與非對角線元素而得之統計指標，可計算出分類成果及參考資料之間的相似程度。所以 $Kappa$ 指標可以用來作為誤差矩陣之精度好壞，並可用來表示兩矩陣間之差異性。

2-7 微分分析

由於高光譜影像具有大量的資料及維度，若以傳統多光譜的處理方式進行分類研究則將面臨困難，如何有效的使用這些可利用的資料量亦成為重要的探討課題。除了 1-2 節中所述之方法外，微分(Derivative)分析亦為另一種方式。不同於其他光譜分析的方法，微分分析並不需要獨立的參考光譜，也不依賴於訊號的強度，完全取決於原光譜曲線與其受影響所改變形狀兩者間之變異性。微分分析常見使用在實驗室光譜學中，也由於二階或高階微分對於因太陽角、雲的遮蔽或地形等因素所造成照明強度改變並不敏感，使此方法適用於高光譜影像的分析[Tsai

et al., 2002]。然而，並非所有在光譜學中所使用的方法都可以直接應用於遙測影像分析上，這是由於兩者間資料的外在環境因素不同，一般在實驗室中物質的光譜測定是假設在一個理想的環境下進行，例如：同質性物質、照明(Illumination)強度與光譜分佈的控制等。相反的，高光譜影像資料是在自然照明下所收集，且儀器本身空間解析度的限制及地形影響等，皆使得兩者之間有所差異；也因如此，當以微分分析應用於遙測資料時會產生許多問題，由於微分分析易受雜訊所影響，如何以平滑化或是其他方法使隨機雜訊降低至最小亦為最主要的問題所在。一般常使用之方法基礎有最小二乘拟合(Least-square-fitting)、最小均方根(Least-mean-square)、中值濾波(Mean Filter)及有限近似值(Finite Approximation)等[Tsai et al., 1998]。

Tsai et al. [2002]提出以類別間的分離度輔助微分分析的方法，這是利用類別間的統計分離度越大，則錯誤分類機率越小的概念。此方法所採用計算兩類別間的分離程度係以 Bhattacharyya distance (B-distance)為基礎的 Jeffreys-Matusita distance (JM-distance)。其定義如下：

$$J_{ij} = \int_x \left(\sqrt{p(X|w_i)} - \sqrt{p(X|w_j)} \right) dx \quad (2-30)$$

i 與 j 為類別， $p(X|w)$ 為機率密度函數，若假設類別的機率密度函數為常態分佈時，上式可簡化如下：

$$J_{ij} = 2(1 - e^{-\alpha}) \quad (2-31)$$

其中

$$\alpha = \frac{1}{8} (m_i - m_j)^t \left\{ \frac{\Sigma_i + \Sigma_j}{2} \right\}^{-1} (m_i - m_j) + \frac{1}{2} \ln \left\{ \frac{\left| \frac{\Sigma_i + \Sigma_j}{2} \right|}{|\Sigma_i|^{1/2} |\Sigma_j|^{1/2}} \right\} \quad (2-32)$$

Σ_i 與 Σ_j 分別為 i^{th} 與 j^{th} 的協變方矩陣，

為避免矩陣行列式計算時會產生溢位(Overflow)現象，式 2-21 可改寫成以 10

為基底之對數：

$$\alpha = \frac{1}{8}(m_i - m_j)^t \left\{ \frac{\Sigma_i + \Sigma_j}{2} \right\}^{-1} (m_i - m_j) + \frac{1}{2} \delta \quad (2-33)$$

$$\delta = \ln \left[\frac{10^{\lg(d_{ij})}}{\sqrt{10^{\lg(|\Sigma_i|)}} \sqrt{10^{\lg(|\Sigma_j|)}}} \right] \quad (2-34)$$

$$d_{ij} = \left| \frac{\Sigma_i + \Sigma_j}{2} \right| \quad (2-35)$$

則式 2-34 可表示如下：

$$\delta = \ln(10) \left[\lg(d_{ij}) - \frac{1}{2} \lg(|\Sigma_i|) - \frac{1}{2} \lg(|\Sigma_j|) \right] \quad (2-36)$$

當 JM-distance 值越大，分類精度隨之增加，且使用微分方式識別其特徵將有助於分類；在此估算光譜微分使用有限近似值演算法，如光譜 $s(\lambda)$ 的一階微分估算如下：

$$\frac{\partial s}{\partial \lambda} \approx \frac{s(\lambda_j) - s(\lambda_i)}{\Delta \lambda} \quad (2-37)$$

$\Delta \lambda$ 為兩相鄰波段間之分離度，亦即 $\Delta \lambda = \lambda_j - \lambda_i$ 且 $\lambda_j > \lambda_i$ 。

相同的，二階微分為：

$$\frac{\partial^2 s}{\partial \lambda^2} \approx \frac{s(\lambda_k) - 2s(\lambda_j) + s(\lambda_i)}{(\Delta \lambda)^2} \quad (2-38)$$

$\Delta \lambda = \lambda_k - \lambda_j - \lambda_i$ 且 $\lambda_k > \lambda_j > \lambda_i$ 。因此，第 n 階微分可表示如式 2-39：

$$\frac{\partial^n s}{\partial \lambda^n} \Big|_j = \frac{\partial}{\partial \lambda} \left(\frac{\partial^{n-1} s}{\partial \lambda^{n-1}} \right) \approx \frac{s(\lambda_{i+n}) - \dots + s(\lambda_i)}{(\Delta \lambda)^n} = \frac{\sum_i^{i+n} C_k s(\lambda_i)}{(\Delta \lambda)^n} \quad (2-39)$$

式中，如果 $(2i+n)$ 為偶數，則 $j = (2i+n)/2$ ；反之若為奇數，則 $j = (2i+n+1)/2$ 。 C_k 為權係數。

此法係以多階微分萃取出變化較大的位置當作特徵，基本上可歸納為特徵萃取中之一種方法。然而，此方法中仍有部分缺點待改善，例如，如何選取最佳之微分階數組合，目前乃應用經驗法則決定，但是不同影像可能有不同之最佳組

合。此外如何有效降低計算時計算機資源的耗用與提升處理速度等，亦為可探討之議題。

