

國立交通大學

土木工程學系

碩士論文

高解析度衛星影像分類應用於國土利用調查之研究

**The Application of Image Classification with High Spatial Resolution
Satellite Imagery for National Land-Use Inventory**



研究生：鄭雅文

指導教授：史天元

中華民國九十六年六月

高解析度衛星影像分類應用於國土利用調查之研究

學 生：鄭雅文

指導教授：史天元

國立交通大學土木工程學系

摘要

本研究採三幅不同土地覆蓋複雜度 SPOT 5 衛星融合影像作為實驗區，除了針對不同分類演算法進行成果比較外，並分析加入紋理統計量之前後成果，以及加入空間相關性之不同分類模式，探討影像的高空間解析度對於影像土地覆蓋分類精度是否具有提升效益。

實驗成果以誤差矩陣作展示及精度評估。研究成果顯示，在不同分類演算法之分類成果，得出物件導向分類方法於土地覆蓋複雜之分類成果為佳，且所分類之類別區域較為合理，少有歸屬為其他類別的零碎像元參雜其中。支持向量機在三個實驗區的分類成果非為最佳，主要是因為支持向量機在求取最佳參數組合時，因土地覆蓋類型過於複雜，故無法模擬出最適超平面以區分類別，而使其分類成果較倒傳遞神經網路不佳。

在加入空間相關性之分類成果，顯示不同紋理統計量於同一類別上的貢獻和取樣視窗尺寸十分相關，若取樣視窗過大，則紋理統計量所得成果，差異並不大，但對於紋理特徵相異之類別，紋理統計量的加入帶來的效益便有明顯區分。而且，紋理影像的加入對提升精度效果有限，某些紋理影像加入，甚至降低分類精度，故紋理特徵的選用及其參數的設定必須詳加考量。且加入 PCA 與加入 Rough Set 之分類模式不但具有顯著差異，而且透過 Rough Set 所萃取紋理之線性組合，相較於主成份分析法之萃取，較能有效提昇分類精度。

The Application of Image Classification with High Spatial Resolution Satellite Imagery for National Land-Use Inventory

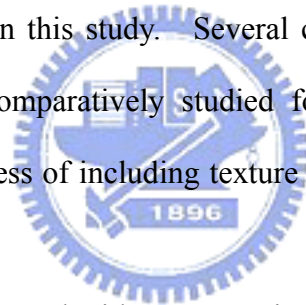
Student : Ya-Wen Cheng

Advisor : Tian-Yuan Shih

**Department of Civil Engineering
National Chiao Tung University**

Abstract

Three scenes of SPOT-5 high resolution imagery produced with image fusion are utilized for experiments in this study. Several classification schemes based on different methodology are comparatively studied for Land Cover and Land Use applications. The effectiveness of including texture measures in the classification is also analyzed.



The experiments are assessed with error matrices and also accuracy indices. It is shown that the classification schemes based on object, which takes the spatial homogeneity into consideration, performs better. Not only the classification accuracy is better, but also less scattered errors are found. Contradicting with earlier studies, Support Vector Machines (SVM) was not found to be better than neural network. This may result from the high complexity of the images under study. In some cases, SVM failed to produce the best hyper plane.

Regarding the effectiveness of textures based on GLCM, the sample window size is found to be very critical. Different land cover types are best suited with different window size. In the experiments conducted, introducing texture does not always improve the classification accuracy. The PCA and the method based on Rough Set

are compared for the two stages schemes, which utilize a feature selection scheme before the classification. It is found that Rough Set performs better than PCA.



致 謝

「半生閑隱今終止，一步江湖無盡期。」可說是我此刻心情的最佳寫照，研究所畢業，對我而言，代表著單純學生生活的結束，職涯戰場的開始，因此，論文的完成，可以視為自己人生裡一個重要的里程碑，也可視為另一段人生旅途的起始。在就讀研究所期間，雖有幾許波折，但因受到許許多多人的幫助、支持，而安然無恙的渡過，順利地劃下句點，因為你們，才有今日的我。

誠摯感謝史天元教授兩年來的悉心教導，感謝黃灝雄教授、雷祖強教授及陳繼藩教授對論文的不吝指教，感謝蕭國鑫學長、劉進金學長與徐偉成學長在研究期間給予的協助和意見，感謝好友嫻如、彩年、阿美、俊毅、玉芳、啟訓、嘉澍、JACO、熱狗的相互勉勵，昌哥、心瑜和學弟妹歷韋、俊宜、逸晴、小光等的加油打氣，以及室友子玲的援助和相陪，讓我兩年的交大生活充滿了溫馨喜悅，縱有千言萬語，仍難以表達我此刻心中的感激之情。

最後，深深感謝我摯愛的家人，謝謝你們多年來無私的包容與奉獻，造就了今日的我。

目 錄

中文摘要	I
英文摘要	II
致 謝	IV
目 錄	V
圖目錄	VII
表目錄	IX
第一章 前言	1
1-1 研究動機與目的	1
1-2 文獻回顧	2
1-3 研究方法	3
1-4 論文架構	4
第二章 影像分類理論	5
2-1 波譜型態分類法	5
2-1-1 高斯最大似然法	6
2-1-2 倒傳遞類神經網路	7
2-1-3 支持向量機	11
2-2 結合空間資訊分類法	15
2-2-1 紋理特徵	15
2-2-2 ECHO	16
2-2-3 Definiens Professional	18
第三章 實驗與分析	23
3-1 影像及檢核資料	23
3-1-1 實驗區影像資料	23
3-1-2 訓練樣本	28
3-1-3 國土調查計劃	28
3-2 影像自動判釋於國土利用調查	30
3-2-1 不同分類理論之分類成果	30
3-2-2 加入紋理影像之分類成果	35
3-2-3 原始影像光譜檢核	52

3-3 大幅影像之軟體執行效能	58
第四章 結論與建議	59
參考文獻	61
附錄A 各實驗區不同分類方法之誤差矩陣.....	64
附錄B 研究軟體.....	72



圖目錄

圖 2-1 影像分類理論結構圖	5
圖 2-2 不同地物之三維特徵空間表示圖 (Lillesand & Kiefer, 1994)	7
圖 2-3 不同地物之二維特徵空間表示圖 (Lillesand & Kiefer, 1994)	7
圖 2-4 倒傳遞類神經網路基本架構	8
圖 2-5 倒傳遞類神經網路演算流程圖	10
圖 2-6 本研究倒傳遞神經網路之架構	11
圖 2-7 選用二層隱藏層之示意圖 (陳承昌, 2006)	11
圖 2-8 線性可分及線性不可分示意圖 (陳承昌, 2006)	13
圖 2-9 DAG method 處理 5 種類別時之二元且無循環的有向圖(陳承昌, 2006)	14
圖 2-10 影像分割異質性指標計算流程圖 (莊雲翰, 2002)	20
圖 2-11 Nearest Neighbor原理示意圖	21
圖 2-12 歸屬函數示意圖	21
圖 2-13 Definiens Professional分類流程圖	22
圖 3-1 久美、霧社及瑪谷溪實驗區第二級土地分類圖	24
圖 3-2 久美實驗區地理位置及衛星影像	25
圖 3-3 霧社實驗區地理位置及衛星影像	26
圖 3-4 瑪谷溪實驗區地理位置及衛星影像	26
圖 3-5 各實驗區檢核影像	27
圖 3-6 國土調查計劃作業流程	29
圖 3-7 不同分類理論於久美實驗區之分類成果	31
圖 3-8 不同分類理論於霧社實驗區之分類成果	32
圖 3-9 不同分類理論於瑪谷溪實驗區之分類成果	33

圖 3-10 加入紋理影像之分類流程	37
圖 3-11 久美實驗區加入取樣視窗為 17x17 計算之紋理於不同類別之分類精度	38
圖 3-12 霧社實驗區加入取樣視窗為 17x17 計算之紋理於不同類別之分類精度	39
圖 3-13 瑪谷溪實驗區加入取樣視窗為 17x17 計算之紋理於不同類別之分類精度	40
圖 3-14 久美實驗區加入取樣視窗為 3x3 計算之紋理於不同類別之分類精度 .	41
圖 3-15 霧社實驗區加入取樣視窗為 3x3 計算之紋理於不同類別之分類精度 .	42
圖 3-16 久美實驗區以全幅影像訓練樣本之分類成果.....	52
圖 3-17 霧社實驗區以全幅影像訓練樣本之分類成果.....	52
圖 3-18 久美實驗區分類結果與檢核資料之比對成果圖	54
圖 3-19 霧社實驗區分類結果與檢核資料之比對成果圖	54



表目錄

表 3-1 不同實驗區之訓練樣本統計資訊	28
表 3-2 不同分類理論於久美實驗區之分類成果.....	31
表 3-3 不同分類理論於霧社實驗區之分類成果.....	32
表 3-4 不同分類理論於瑪谷溪實驗區之分類成果.....	33
表 3-5 各分類理論之Z-test.....	34
表 3-6 不同取樣視窗大小於不同實驗區分類之整體精度	43
表 3-7 各實驗區之主軸資訊 (取樣視窗為 17x17)	45
表 3-8 各實驗區之主軸資訊 (取樣視窗為 3x3)	45
表 3-9 原始波段加入PCA及Rough Set萃取影像之分類成果 (取樣視窗為 17x17)	47
表 3-10 原始波段加入PCA及Rough Set萃取影像之分類成果 (取樣視窗為 3x3)	48
表 3-11 各實驗區加入PCA與加入Rough Set前後之Z-test (取樣視窗 17x17)	49
表 3-12 各實驗區加入PCA與加入Rough Set前後之Z-test (取樣視窗 3x3) .	51
表 3-13 久美、霧社實驗區以全幅影像訓練樣本之分類精度.....	53
表 3-14 久美實驗區各類別光譜統計量.....	55
表 3-15 霧社實驗區各類別光譜統計量.....	55
表 3-16 久美實驗區各類別之分離度	56
表 3-17 霧社實驗區各類別之分離度	57
表 3-18 不同影像尺寸於不同分類演算法之執行效能	58
表A-1 高斯最大似然法於久美實驗區之分類結果.....	64
表A-2 ECHO於久美實驗區之分類結果	64

表A-3	SVM於久美實驗區之分類結果.....	64
表A-4	BP於久美實驗區之分類結果.....	65
表A-5	Definiens Professional於久美實驗區之分類結果.....	66
表A-6	高斯最大似然法於霧社實驗區之分類結果.....	67
表A-7	ECHO於霧社實驗區之分類結果.....	67
表A-8	SVM於霧社實驗區之分類結果.....	68
表A-9	BP於霧社實驗區之分類結果.....	68
表A-10	Definiens Professional於霧社實驗區之分類結果.....	69
表A-11	高斯最大似然法於瑪谷溪實驗區之分類結果.....	69
表A-12	ECHO法於瑪谷溪實驗區之分類結果.....	70
表A-13	SVM法於瑪谷溪實驗區之分類結果.....	70
表A-14	BP法於瑪谷溪實驗區之分類結果.....	71
表A-15	Definiens Professional法於瑪谷溪實驗區之分類結果.....	71



第一章 前言

1-1 研究動機與目的

隨著社會經濟的發展，人口數的增加，如何使作永續且有效的土地利用，對於地小人稠，高度開發的台灣而言，是十分重要的課題，為此，首先必須要瞭解當前國土利用的現狀與問題，以進行未來規劃與監控的土地利用，作有效的土地管理。而依目前發展最方便的方式便是採用航遙測技術，航遙測技術為運用儀器，不需和目標物作直接接觸，便可獲取目標資料的技術，加上航遙測的影像解析度日益提升，故可普遍執行土地利用調查作業，解決國土普查作業進度遲緩與資料更新困難等問題。

土地覆蓋為地表自然及人為影像所形成的覆蓋物，如農地、林地、水體等。而土地利用則是描述人類因經濟等目的，對土地的利用和管理，如水利用地、農業用地等，因此，土地利用為自然、經濟等諸多因素下所形成，故高空間解析度衛星影像無法對國土利用現況進行影像判釋，但仍可利用土地覆蓋類別所對應不同土地利用型式來進行調查。

然而以往利用多光譜影像進行土地覆蓋分類，受限於影像空間解析度低，混合像元情況十分嚴重，故未加以考量相鄰像元彼此間的相關性，大多採用頻譜方式分類，影像空間相關性的加入，對於分類的成果而言，助益並不高，而今高解析度多光譜影像的產生，能提供豐富的空間資訊，因此若能充份利用此優勢，應可提昇分類成果的精度。

本研究採三幅不同土地覆蓋複雜度高空解析度衛星影像作為實驗區，除了針對不同分類演算法進行成果比較外，並分析加入紋理統計量之前後成果，以加入空間相關性之不同分類模式，探討影像的高空間解析度對於影像土地覆蓋分類精度是否具有提升效益。

1-2 文獻回顧

利用航遙測影像來進行土地利用／土地覆蓋分類的研究，一直以來都是國內外的研究重點所在，尤其近年來，衛星影像的解析度更是日益提升，在高解析度影像中，具有意義的地物大多由非單一像元組成，相鄰像元間相關性高，因此許多研究嘗試萃取影像特徵的方式，藉以得到影像的空間資訊，來提昇分類成果。而萃取影像特徵的方法包含紋理影像、影像分割等，紋理為影像中像元灰階值變化的頻率（林榮章，1999），影像分割則為基於影像像元特性上的相似性，將像元與其鄰近相似像元群組化成一共軛區塊，即將影像中具有高相關性的相鄰像元合併成一個區塊，形成影像區塊圖。而國內外對萃取影像特徵對影像分類之助益研究有：

Huang et al. (2007) 採用一些新的統計量來萃取紋理特徵，包含 length、width、weighted mean、PSI、length-width ratio 及 standard deviation，這些統計量統稱為 SFS (Structural Feature Set)，為 LWEA 及 PSI 的改良，研究成果 SFS 相較於 GLCM、LWEA、PSI 而言精度為佳，且於不同分類方法：高斯最大似然法 (Gaussian Maximum Likelihood Classifier)、倒傳遞神經網路 (Error Back-propagation Network) 及支持向量機 (Support Vector Machine)，SFS 的加入皆有相當助益。

李瑞陽、莊佳文 (2006) 採用 QuickBird 衛星影像，利用影像分割方式進行土地利用類別的判釋，採用區域合併 (region-merging) 方法進行影像分割，透過灰階值的異質性指標和標準化法、適合度法兩種門檻值公式決定區塊合併與否，得到完整的影像區塊圖後，便進行影像分類。而洪蜜琪 (2007) 則是利用高斯最大似然法進行影像分類，並計求影像的多重影像梯度，以進行分水嶺影像分割計算，利用所求得的分割區塊修正分類結果，因而解決誤判的孤立點，提高混合像元的判釋率。實證後，皆可得出影像分割技術對於衛星影像判釋的確有正面助益。

分類演算法除了利用統計分析方式進行影像分類，目前以影像區塊為基礎的物件導向分類演算法，是現今研究的一大方向，其演算法主要優點在於影像區塊可以提供形狀因子，如區塊周長、面積等，相較於單一像元僅能提供光譜上的資訊，更有利於地物的辨識與分類，同時，利用區塊整體的形狀來幫助識別地物，也較接近人類辨識的過程（莊雲翰，2002）。Kressler et al.（2003）便是單純利用衛星影像的高空間解析度來進行判釋，採用物件導向方法，僅對相同區域的 KOMPSAT-1 和 SPOT-5 的全色態衛星影像，進行土地覆蓋類別的判釋並進行比較，而所得之成果皆有 86% 以上的精度，但在農地和林地之間存有相當大的誤判，主要原因在於農林地之全色態光譜資訊難以區分，但由此可得利用區塊整體的形狀來幫助識別地物足以得到不錯的成果。

而與逐像元分類法比較，Oruc et al.（2004）採用 LANDSAT-7 ETM 影像，針對逐像元分類和物件導向分類進行比較分析，在逐像元分類上，先以 ISODATA 作群聚分析後，再進行 parallelepiped、minimum-distance 及 maximum-likelihood 分類，所得成果與物件導向分類方法作比較，顯示物件導向分類成果精度優於逐像元分類成果。

1-3 研究方法

本研究主要針對波譜型式分類與結合空間相關性分類方法進行成果比對，波譜型式分類所採用高斯最大似然法、倒傳遞神經網路及支持向量機，而結合空間相關性，除了加入紋理資訊進行分類外，還利用物件導向分類法作為主要分類理論，以驗證空間資訊的加入於土地覆蓋分類上，優於單用波譜資訊進行分類之成果。

在遙測影像方面，本研究採用三幅不同土地覆蓋複雜度高空解析度衛星影像作為實驗區，衛星影像採用 SPOT 5 融合影像，地理位置皆位於南投地區，以工研院能環所於國土利用調查成果作為本研究之檢核資料，除了針對不同分類演算法加入空間相關性前後成果進行分析比較外，也加以探討紋理影像的加入是否能

有效提昇不同分類演算法之分類精度，並以 Z-Test 方法檢定各分類模式是否具有顯著差異。

各分類實驗成果以誤差矩陣作展示，並計算各精度評估指標，包括使用者精度、生產者精度、整體精度及 Kappa 指標。透過上述精度評估，作為探討各分類方法優劣主要依據。

1-4 論文架構

論文架構共分為四章，說明如下：

第一章「前言」：說明本研究動機與目的，並回顧國內外相關研究之文獻及本研究流程與方法。

第二章「影像分類理論」：針對目前影像分類理論分為兩大類：波譜型態及結合空間相關性分類進行介紹。

第三章「實驗與分析」：描述本研究所採用之影像資料，並對實驗流程與成果分析作說明。

第四章「結論與建議」：對於研究成果歸納總結，並列出建議事項。

第二章 影像分類理論

隨著遙測影像來源日趨多樣化，且具空間解析度也改進甚多，所衍生的影像分類方法也日益增多，但大體而言，可歸納為兩大類，如圖 2-1 所示，一類是單純利用影像所包含的光譜資訊作分類，另一類則是結合光譜和空間資訊來進行分類。本章將說明不同影像分類之理論原理。

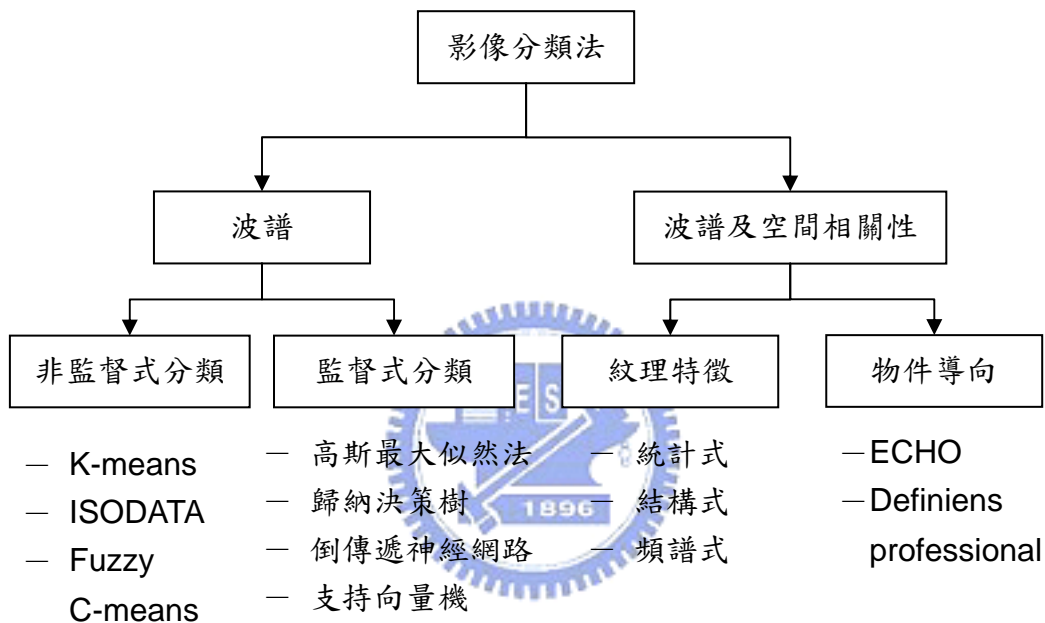


圖 2-1 影像分類理論結構圖

2-1 波譜型態分類法

單純以光譜資訊作分類的方法，可再簡分為兩大類，一是非監督式，另一個則是監督式分類。非監督式分類 (Unsupervised Classification)，為人為設定欲分類的類別數、迭代次數等參數，由系統自動給定各類別光譜中心的初始值，經不斷反覆迭代修正，直到達成收斂或超過所設最大迭代次數，得到最終分類成果，演算法包括包含 K-means、ISODATA、Fuzzy C-means 等。

有別於非監督式分類，監督式分類 (Supervised Classification) 主要為人工

介入選取訓練樣本區，依所選取訓練樣本區內的光譜資訊作為影像自動判釋之依據，對整幅影像進行分類，為本研究主要分類方法。

目前監督式分類除了利用統計分析方法進行分類，像是 Nearest-Neighbor、Parallelepiped Classification 及高斯最大似然法 (Gaussian Maximum Likelihood Classifier) 等外，人工智慧 (AI) 加入，也成為遙測影像分類的主要研究方向，而人工智慧分類方法包含決策樹、類神經網路等，因此，本節有關監督式分類主要針對高斯最大似然法、歸納決策樹、倒傳遞神經網路及支持向量機的分類理論作介紹。

2-1-1 高斯最大似然法

高斯最大似然法 (Gaussian Maximum Likelihood Classifier) 是假設選取的各訓練樣本區之像元值在光譜空間是屬於常態分佈 (Normally Distribution)，因此，各類別波譜反應類型與每一種類別的波譜均值及協變方矩陣 (Covariance Matrix) 為相關，在此前提下，利用均值及協變方矩陣，便可計算每一像元為特定分類的統計機率，以最大機率當作判斷類別歸屬的標準。

此方法除了考慮訓練區之中值外，同時亦考慮訓練樣本區內光譜的變異量及協變方，但主要的缺點為在分類每個像元時，計算量大。若將此機率值繪於三維的特徵空間上，縱軸表一個像元屬於一種地物分類的機率密度函數，兩水平軸則分別表示兩波段之灰階值，以最大機率當作判斷類別的標準。如圖 2-2 所呈現數個鐘形分佈，分別表示都市 (Urban)、沙地 (Sand)、穀物 (Corn)、乾草 (Hay)、森林 (Forest) 與水體 (Water) 六種土地覆蓋類別之機率密度函數值。




圖 2-2 不同地物之三維特徵空間表示圖 (Lillesand & Kiefer, 1994)

若於二維特徵空間中描述，呈現出橢圓狀的等機率線，如圖 2-3 所示，等機率線的形狀可以表示協變方之情形。以點位 1 為例，其在穀物類別的機率較其他類別高，故被歸屬為穀物類別。

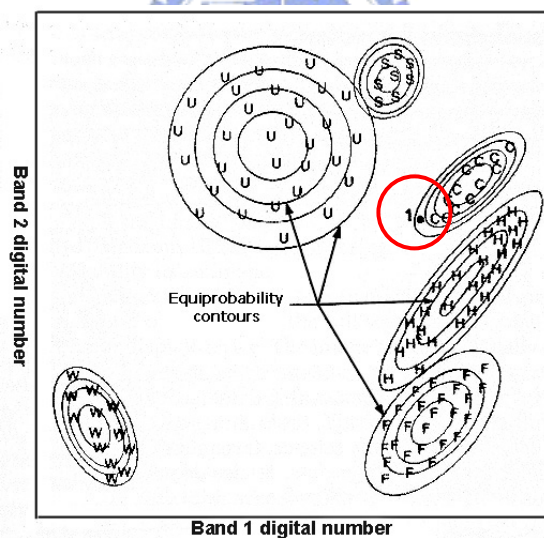


圖 2-3 不同地物之二維特徵空間表示圖 (Lillesand & Kiefer, 1994)

2-1-2 倒傳遞類神經網路

倒傳遞類神經網路 (Error Back-propagation Network, BP)，由 Rumelhart 等人於 1986 年提出，是頗具代表性的類神經網路模式，屬於監督式的學習網路，基本原理是以最陡坡降法 (Gradient Steepest Descent Method) 來調整神經元間之加權值，使誤差函數 E 達到最小。

$$\min E = \frac{1}{2P} \sum_{p=1}^P \sum_{k=1}^K (d_{pk} - o_{pk})^2 \quad (2-1)$$

d_{pk} 為已知期望輸出值 (Desired Output), o_{pk} 為計算而得的輸出值 (Computed Output), P 為訓練樣本數, K 為輸出結點數。




圖 2-4 倒傳遞類神經網路基本架構

倒傳遞類神經網路基本架構，如圖 2-4 所示，包含輸入層、隱藏層及輸出層。演算法基本上包含三個階段：向前饋入 (Feedforward)、誤差倒傳遞 (Error back-propagation) 及修正權值 (Update the weights)，整體流程如圖 2-5 所示。

I. 向前饋入 (Feedforward)

每個神經元可接收所連結的輸入訊號，並經轉置函數 (Transform Function) f 和閾值 θ 計算，輸出其反應值。以第 n 層之神經元 j 的輸出值 o_j^n 為例，其為第 $n-1$ 層之所有神經元輸出值經轉換函數計算後所得之值：

$$net_j^n = \sum_i W_{ji} o_i^{n-1} - \theta_j \quad (2-2)$$

$$o_j^n = f(net_j^n) \quad (2-3)$$

上式中， W_{ij} 為第 n 層神經元 j 與第 $n-1$ 層神經元 i 間的連結加權值； θ_j 為第 n 層神經元 j 的閾值。

II. 誤差倒傳遞 (Error back-propagation)

當 $(d_{pk} - o_{pk})^2$ 未達最小時，便修正網路權值 W ，先修正輸出層和隱藏層間的權值，再修正隱藏層間的權值，最後修正輸入層和隱藏層間的權值，也因此故，此類神經網路模式方稱之為倒傳遞類神經網路。其修正量的計算為下：

(1) 輸出層和隱藏層間的權值修正量 ΔW

$$\begin{aligned}\Delta W_{kj} &= \eta \delta_k o_j \\ \delta_k &= -\frac{\partial E}{\partial net_k} = (d_k - o_k) o_k (1 - o_k)\end{aligned}\quad (2-4)$$

(2) 隱藏層間或輸入層和隱藏層間的權值修正量 ΔW

$$\begin{aligned}\Delta W_{ji} &= \eta \delta_j o_i \\ \delta_j &= -\frac{\partial E}{\partial net_j} = o_k (1 - o_k) \sum_{k=1}^K \delta_k W_{kj}\end{aligned}\quad (2-5)$$

III. 修正權值 (Update the weights)

修正方式如下所示：

$$\begin{aligned}W_{kj}(t+1) &= W_{kj}(t) + \Delta W_{kj}(t) + \alpha \Delta W_{kj}(t-1) \\ \Rightarrow W_{kj}(t+1) &= W_{kj}(t) + \eta \delta_k o_j + \alpha \Delta W_{kj}(t-1)\end{aligned}\quad (2-6)$$

其中 η 為學習因子 (Learning Ratio)， α 為動量因子 (Momentum ratio)， t 為迭代次數。

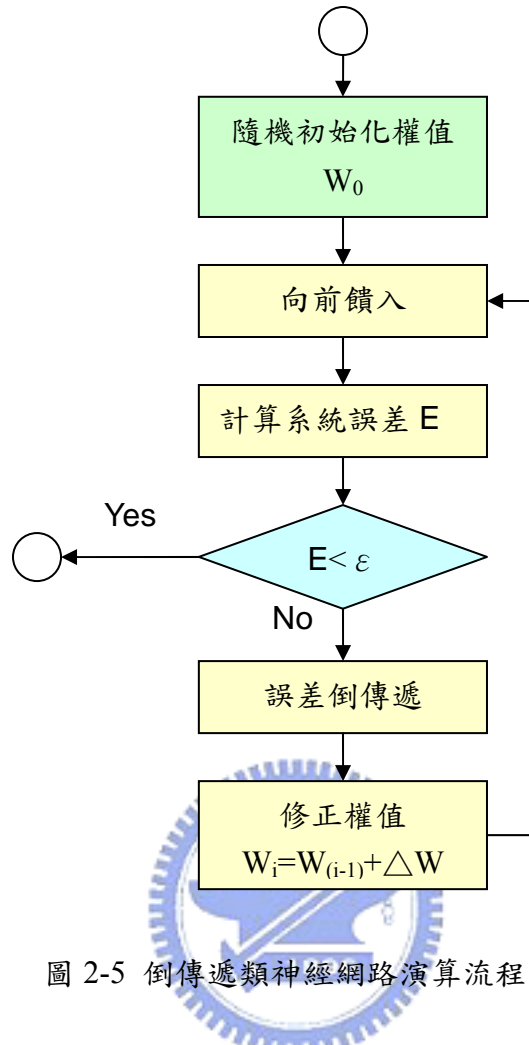


圖 2-5 倒傳遞類神經網路演算流程圖

倒傳遞類神經網路的主要缺點在於不具對其網路權重進行解釋的能力，且在訓練網路時會耗費相當長的時間，學習因子 η 可能會造成非系統的收斂。基本的倒傳遞神經網路是採用最陡坡降法調整權值，雖然是以負梯度方向來進行調整，但未必達到最快的收斂，而共軛梯度法則是沿共軛方向搜尋，相較於最陡坡降法而言，能產生較快的收斂，本研究採用比例共軛梯度法，其由 Moller 所發展，由於共軛梯度法在每一次疊代上都需要一個線搜尋，但線搜尋十分耗時，而比例共軛梯度法可避免耗時的線搜尋，在函數逼近問題上，與近以二階訓練的 Levenberg-Marquardt 一樣快，且具有適度的記憶體需求（羅華強，2001），故本研究採此法來調整權值。

另外，本研究中的倒傳遞類神經網路模式採用兩層隱藏層，如圖 2-6，其意義為以圖 2-7 作說明。圖 2-7 (1) 找出兩個類別之分類界線；圖 2-7 (2) 透過第

一個隱藏層，網路學習權重可找出線性的類別界線；圖 2-7(3) 經第二個隱藏層，相關的線性類別界線經由一次合併，成為封閉的矩形區塊；圖 2-7(4) 最後至輸出層，則各矩形區塊再一次合併，得到適當的分類界線（陳承昌，2006）。




圖 2-6 本研究倒傳遞神經網路之架構

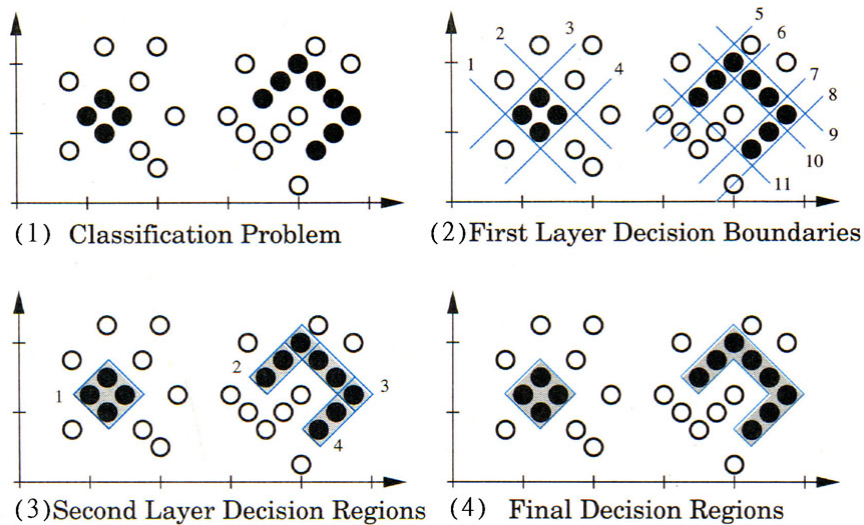


圖 2-7 選用二層隱藏層之示意圖（陳承昌，2006）

2-1-3 支持向量機

支持向量機（Support Vector Machine，SVM）為貝爾實驗室 Vapnik 博士於 1990 年以統計學習理論為基礎，所建構出的機器學習系統，目的是產生一個可預估出測試例之屬性值的模型，其主要原理是在於特徵空間中尋求具最大邊界的超平面以區分二元類別。依訓練樣本在空間中的分佈，支持向量機不但可以處理線性可分問題外，亦可處理非線性問題，其中，線性可分問題又可分為線性可分或線性不可分兩種情況，以下將針對線性、非線性及多類支持向量機作說明（陳承昌，2006）。

（一）

I. 線性支持向量機

線性支持向量機又可分為線性可分或線性不可分之情況。在線性可分的情況下，如圖 2-8(1)，假設存在訓練樣本 (x_i, y_i) ， $i=1, 2, \dots, l$ ， $x_i \in R^n$ ， $y_i \in \{-1, +1\}$ ；支持向量機會尋求一個具最大邊界 (margin) 的區分超平面 (separating hyperplane) $(w \cdot x_i) + b = 0$ ，將標註為「-1」及「+1」的訓練樣本給完全分離。線性可分主要為求解下式：

$$\min \Phi(w) = \frac{1}{2}(w \cdot w) \quad (2-7)$$

$$\text{subject to } y_i[(x_i \cdot w) + b] \geq 1, i=1, 2, \dots, l。$$

透過 Lagrangian 轉換，可將 (2-7) 式轉換為：

$$L(w, b, \alpha) = \frac{1}{2}(w \cdot w) - \sum_{i=1}^l \alpha_i \{[(x_i \cdot w) + b]y_i - 1\} \quad (2-8)$$

上式 α_i 為 Lagrange multipliers，且 $\alpha_i \geq 0$ 。

將 (2-8) 式對 w 及 b 作偏微，並將偏微所得代入 (2-8) 式後，考慮 Karush-Kuhn-Tucker 條件，可將其轉換為求解下式：

$$\max W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (2-9)$$

$$\text{subject to } \alpha_i \geq 0$$

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad i=1, 2, \dots, l。$$

透過 (2-9) 式的求解，可求得最後分類函數：

$$f(x) = \text{sign} \left(\sum_{i=1}^l y_i \alpha_i (x_i \cdot x) - b \right) \quad (2-10)$$

上式中， x_i 為支持向量， α_i 為相應 x_i 之 Lagrange multipliers， b 為一常數門檻值。當 $f(x) > 0$ 時，表示該樣本與標註為「+1」的樣本屬同一類別，反之則屬另一類別。

若為線性不可分的情況，如圖 2-8 (2)，(2-7) 式可改寫成 (2-11) 式，求解具最大邊界的區分超平面及使懲罰項 $(C \sum_{i=1}^l \xi_i)$ 的值為最小：

$$\begin{aligned} \min \quad & \Phi(w, \xi) = \frac{1}{2}(w \cdot w) + C \left(\sum_{i=1}^l \xi_i \right) \quad (2-11) \\ \text{subject to} \quad & y_i [(w \cdot x_i) + b] \geq 1 - \xi_i \quad i = 1, 2, \dots, l \\ & \xi_i \geq 0 \end{aligned}$$

上式 C 為懲罰參數 (penalty parameter)、 ξ_i 為沉滯變數 (slack variable)。




圖 2-8 線性可分及線性不可分示意圖 (陳承昌, 2006)

II. 非線性支持向量機

若輸入的訓練樣本無法以線性支持向量機分離，則可透過映射函數 φ ，將原本輸入的訓練樣本空間 R^n 映射至高維度的特徵空間 (feature space, Z)，在 Z 中建構最佳區分超平面，以近似線性支持向量機方式完成分類。在滿足 Mercer 條件下，映射函數的點乘積可以適當的核函數作取代，得最終的分類函數為：

$$f(x) = \text{sign} \left[\sum_{i=1}^l y_i \alpha_i K(x_i, x) - b \right] \quad (2-12)$$

上式中， $K(x_i, x) = \varphi(x_i) \cdot \varphi(x)$ ，為滿足 Mercer 條件的核函數。

一般常見的三種核函數分別為：(1) 多項式 (polynomial kernel)，

$K(x_i, x) = (x_i \cdot x + 1)^d$ ；(2) 輻狀基底函數 (radial basis functions kernel, RBF)，

$K(x_i, x) = \exp\left(\frac{-\|x_i - x\|^2}{2\sigma^2}\right)$ ；(3) 兩層式類神經網路 (two-layer network)，

$K(x_i, x) = \tanh(\kappa x_i \cdot x - \delta)$ 。本研究將採輻狀基底函數作為本研究支持向量機影像分類之核函數。

(二) 多類支持向量機

支持向量機的基本分類原理主要是以二元類別為主，若要將其延伸到多類別的分類問題上，目前有以下幾種方法（陳承昌，2006；黃國矩，2006）：

1. 一對多方法（one-versus-rest）：該方法是先把某一類別的樣本當作一種類別，其餘類別的樣本當作另一種類別，若有 k 種類別，則會產生 k 個支持向量機，並以具有最大分類函數值的支持向量機為欲分類樣本之所屬類別。
2. 一對一方法（one-versus-one）：若有 k 種類別，則每兩種類別樣本皆會產生一個支持向量機，故將產生 $k(k-1)/2$ 個支持向量機，並以投票策略（voting strategy）決定樣本之類別。
3. DAG method (Directed Acyclic Graph SVM)：此方法的支持向量機產生方式，與一對一方法相同，同樣會產生 $k(k-1)/2$ 個支持向量機。不同之處是此方法共 $k(k-1)/2$ 個節點，分支為單向，每個節點有兩個或無分支，會建立一個二元且無循環的有向圖，如圖 2-9，欲處理 5 種類別時，共有 10 個內部節點及 5 個葉節點，每一個內部節點皆表示一個二元支持向量機，5 個葉節點則表示 5 種類別。

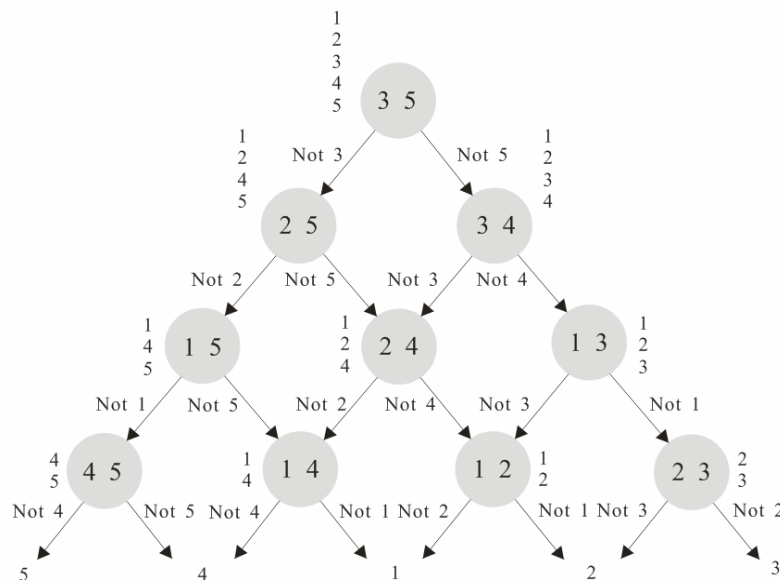


圖 2-9 DAG method 處理 5 種類別時之二元且無循環的有向圖(陳承昌，2006)

2-2 結合空間資訊分類法

2-1 節所列的分類理論皆是單純以影像光譜資訊為主所作的分類，未考慮到鄰近像元間的相關性，而加入空間相關性的分類方法有很多，本章主要介紹紋理特徵萃取及物件導向分類法之理論。

2-2-1 紋理特徵

在影像中，不同波段之光譜輻射值、反射值，可描述不同地物。但同時，不同地物之輻射值或反射值，在其鄰近區域之相關性，亦可用以區分不同之地物。此一空間分佈相關之性質，可以紋理描述，紋理是以基元為基本的組成元素，基元則是指具有某種屬性而彼此相連的單元的集合，屬性包括灰階、局部一致性等，而空間關係包括基元的相鄰性、在一定角度範圍內的最近距離等。一般紋理描述可分成三大類：即方向性紋理、週期性紋理與隨機性紋理。

而要讓電腦能夠運用影像的紋理資訊，則必須針對影像的紋理描述進行量化，常見有三種主要的方法，統計分析方法 (Statistical approaches)、結構分析方法 (Structural approaches) 和頻譜分析方法 (Spectral approaches) (林榮章，1999)，依其計算方式又可以被分為一階、二階及高階等。

(一) 統計分析方法

統計分析方法著重於紋理特徵的抽取，強調整個紋理給觀察者的印象 (林榮章，1999)，故其紋理主要描述影像灰階值空間分佈情形的統計特性，如影像灰階值的平均值、直方圖或變異數等，常用的方法有共生矩陣 (GLCM)、碎形維度 (Fractal Dimension) 及半變異元法 (Semi-variogram) 等。

其中，共生矩陣 (GLCM, Gray Level Co-Occurrence Matrix, 也可稱為 grey level dependency matrix) 為 Haralick 於 1973 年所提出，共十四種紋理統計量，是一種二階的統計方法，可以計求像元對的聯合機率分配的估計值，也就是像元對的灰階值出現在特定相關位置的機率，而本研究以 GLCM 為主要紋理萃取方式，而 GLCM 主要變量包含影像空間解析度、光譜波段、影像量化解析度、取

樣視窗大小及取樣的距離及方向 (Marceau et al, 1990)。

(二) 結構分析方法

結構分析方法便是著重研究紋理基元及其空間關係，認為紋理是由一個或多個基元呈現透過某一排列規則組合而成的，故結構分析方法係為描述影像紋理基元的分佈規則，此方法需先了解萃取紋理的規則性，對影像解析度甚為敏感，加上，自然環境之紋理多為隨機，故此法於自然環境紋理的萃取上有所限制。

(三) 頻譜分析方法

頻譜分析方法則用以描述具方向性和週期性的紋理，常用的有傅利葉轉換 (Fourier Transform) 和小波轉換 (Wavelet Transform)。傅利葉轉換描述影像時，可從不同角度的頻譜峰值可以看出紋理的主要方向，而從峰值的位置則可顯示紋理的週期性 (何裕琨, 2003)。小波轉換則允許在不同尺度下萃取不同的紋理特徵，通過小波變換可將影像分解為不同的頻率域，計算頻率域的能量等作為紋理描述。



2-2-2 ECHO

ECHO (Extraction and Classification of Homogeneous Object) 是一種利用資料特徵會呈現自然相鄰狀態的方法，為一種利用空間和光譜資訊的分類技術，和逐像元進行分類的方法不同；逐像元進行分類方法是每個像元依其光譜特徵單獨進行分類，而ECHO方法則是樣本空間內的每個像元是依和自己相似的鄰接像元光譜特性進行分類。

假設影像為規則和不規則區域所組成，並都包含一個覆蓋類別，則影像中均調區域便是物件。因此，基本的處理目標便是定出物件位置，之後進行分類。分類過程包含兩個階段：影像分割和影像分類。先將影像分割成不同的區塊

(block)，每一個區塊即為一均調區域 (homogeneous region)，再利用不同分類演算法進行分類。

ECHO影像分割主要是將影像分割成許多不相交的長方形區域，設影像 I 之分

割 P 為影像 I_1, I_2, \dots, I_L 之有限集合，則每一個 $I_j \in P$ 時，則稱 I_j 為 P 之區塊。

$$I = \sum_{i=1}^L I_i$$

$$I_j \cap I_i = \phi \quad j \neq i$$
(2-13)

Robertson (1973) 提出一簡單ECHO演算法，所採用的影像分割演算法，係將整幅影像依所設定之均調門檻值逐一細分成不同均調區塊，且假設特徵資料為多變量常態分佈 (Multivariate Normal Distribution)，利用Bhattacharyys距離量測所分割區塊內灰階值估計分佈與已知類別子影像灰階值估計分佈間的距離，以最短距離判斷每個區塊所屬類別，見2-14式，但其缺點在於資料量小時會失敗 (Kettig and Landgrebe, 1976)。

$$\text{for } N(X; M_i, C_i) \quad N(X; M, C)$$

$$B = \frac{1}{4} \left(\ln \frac{|(C_i + C)|^2}{|C_i||C|} + \text{tr} \left((C_i + C)^{-1} (M_i - M)(M_i - M)^t \right) \right)$$
(2-14)

然而MultiSpec的ECHO演算法所採用的影像分割技術相較Robertson而言較為複雜，為Kettig和Landgrebe兩人所創，影像分割方式為區塊合併，透過兩種檢定機制來決定區塊合併或分割，檢定機制為：

1. Cell Selection Criterion：判斷每個區塊是否滿足所設之均調門檻值。

$$Q_j(Y) = \text{tr} \left(C_j^{-1} \sum_{i=1}^m Y_i Y_i^t \right) - 2M_j^t C_j^{-1} \sum_{i=1}^m Y_i + m M_j^t C_j^{-1} M_j$$

$$\text{if } Q_j(Y) < c \quad \text{then } Y \text{ is homogeneous}$$
(2-15)

Y 為影像區塊， c 為所設之門檻值。

2. Annexation Criterion：每個區塊和相鄰區域進行比較，依門檻值決定是否進行合併，假設 X 、 Y 為通過Cell Selection Criterion檢定後，則進行此，若接受 H_0 ，即可進行區塊合併。

$$\begin{aligned}
H_0(X, Y) &= \{p(x, y | f, g) : g = f, f \in \Omega\} \\
H_1(X, Y) &= \{p(x, y | f, g) : f = \Omega, g \in \Omega\} \\
\Omega &= \{p(x | W_i) : i = 1, \dots, K\} \\
\Lambda &= \frac{\max p(X | W_i) p(Y | W_i)}{\max p(X | W_i) \max P(Y | W_i)} \\
T &= 10^{-t} \quad t \geq 0 \\
&\text{if } \Lambda < T \text{ or } -\log \Lambda > t \text{ then reject } H_0
\end{aligned} \tag{2-17}$$

其中， $p(x|W_i)$ 為每個像元值於類別 W_i 之條件機率值。

在分類演算法方面，MultiSpec軟體的ECHO，提供了兩種分類演算法：

Quadratic Maximum Likelihood、Fisher Linear Discriminant，兩者差別在於 Quadratic Maximum Likelihood對每種類別使用各自的共變異矩陣計算，而Fisher Linear Discriminant則是所有類別皆採用共同的共變異矩陣。

2-2-3 Definiens Professional

Definiens Professional為一商用軟體，由於所採用分類演算法未有專有名稱，故本研究便以Definiens Professional作為演算法代表名稱，其分類演算法主要利用模糊邏輯（fuzzy logic）的概念，也就是以一個介於0-1之間的數值表示資料點歸屬於某個群聚類別的程度。分類過程包含兩個階段：分割影像和影像分類。在影像分割階段，使用者可依照影像特性以及地物特徵設定影像分割的參數，在經過影像分割之後，會產成許多影像區塊，再依此區塊影像進行影像判釋分類。

Zhang(1997)將影像分割技術可分為兩大類：boundary-based及region-based。其中region-based包含兩類演算法：多尺度門檻（Multilevel thresholding）及區塊成長（Region-growing）。Definiens Professional便是以區塊成長的方式進行分割的處理，且在分割處理上能加入形狀因子，故可依照不同的影像特性，設定不同的分割機制，而區塊成長演算法決定區塊分割、合併的標準為區塊變異（光譜異質性Spectral heterogeneity）及區塊形狀（空間異質性Spatial heterogeneity）(Carleer et al, 2004)，利用計算影像中每個物件的異質性指標，與所定之門檻值進行分

割。

影像分割異質性指標整體計算流程如圖2-10所示，而在計算區塊異質性指標的過程中，需滿足兩個機制：區塊的異質性平均值需為最小，以及區塊的異質性平均值乘上區塊面積需為最小。Definiens Professional異質性因子的定義如下（莊雲翰，2002）：

a. 光譜異質性指標 h_{color} ：

$$h_{color} = \sum_c w_c \times \sigma_c \quad (2-28)$$

其中 w_c 為圖層權重值， σ_c 為圖層標準差， c 為圖層數，依不同影像特性及目標區塊，圖層間的權重可按使用者需求作調整。

b. 空間異質性指標 h_{shape} ：

$$h_{shape} = w_{smoothness} \times h_{smoothness} + w_{compactness} \times h_{compactness} \quad (2-29)$$

$$h_{smoothness} = \frac{l}{b} \quad (2-30)$$

$$h_{compactness} = \frac{l}{\sqrt{n}} \quad (2-31)$$

其中，形狀的異質性指標是由平滑（smoothness）與緊密（compactness）這兩個子異質性指標所構成， $w_{smoothness}$ 與 $w_{compactness}$ 代表兩者間的權重值，兩者和為1。(2-30)、(2-31)式為平滑指標與緊密指標計算， l 為區塊的實際邊長， b 為區塊的最短邊長， n 為區塊面積。

c. 整體異質性指標 h ：

$$h = w_{color} \times h_{color} + w_{shape} \times h_{shape} \quad (2-32)$$

物件整體的異質性指標是由上述的光譜異質性指標與形狀異質性指標所組成， w_{color} 與 w_{shape} 代表影像光譜與形狀兩者間的權重調配，和亦為1。

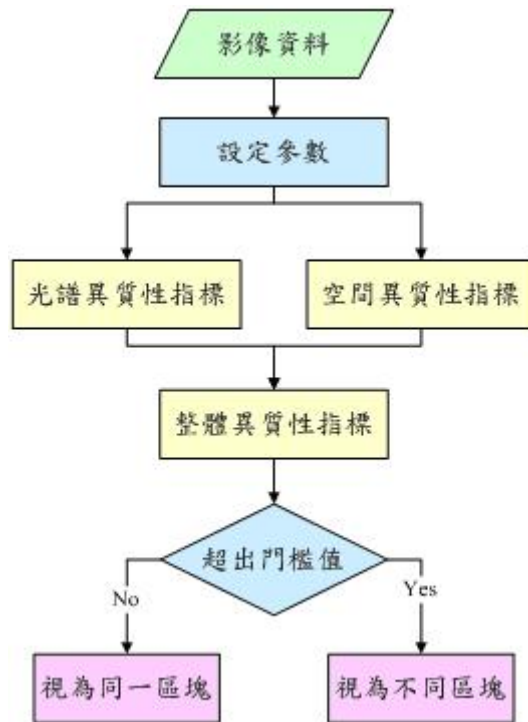


圖 2-10 影像分割異質性指標計算流程圖（莊雲翰，2002）

故Definiens Professional於影像分割介面有三個主要參數：Scale parameter、Color/Shape及Smoothness/Compactness，涵意為下（Oruc，2004）

- a. Scale parameter：和物件大小非直接相關，但此參數決定均調物件的大小，值愈大，便會產生較大的物件。
- b. Color/Shape：用以設定物件產生時，光譜和形狀的均調性，當Shape值愈高，代表產生物件的的光譜均調性愈低。
- c. Smoothness/Compactness：當前所設之Shape的值大於零時，此參數便是用以決定物件的形狀的平滑程度。

而Definiens Professional在分類上有兩種分類方式，分別為Sample base及Rule base。Sample base主要是依所選取樣本物件的光譜資訊，利用統計分析方式，計求得各區塊所屬類別，所採用的演算法為Nearest Neighbor，Nearest Neighbor是一種監督式模糊（fuzzy）分類法，針對每個影像物件在特徵空間中尋找出一個最接近的樣本物件，見圖2-11，作為所屬類別依據（WEI，2005）。

$$d = \sqrt{\sum_f \left[\frac{v_f^{(s)} - v_f^{(o)}}{\sigma_f} \right]^2} \quad (2-33)$$

d 為樣本物件 s 和影像物件 o 間的距離， $v_f^{(s)}$ 為特徵 f 之樣本物件特徵值， $v_f^{(o)}$ 為特徵 f 之影像物件特徵值， σ_f 為特徵 f 特徵值的標準差。

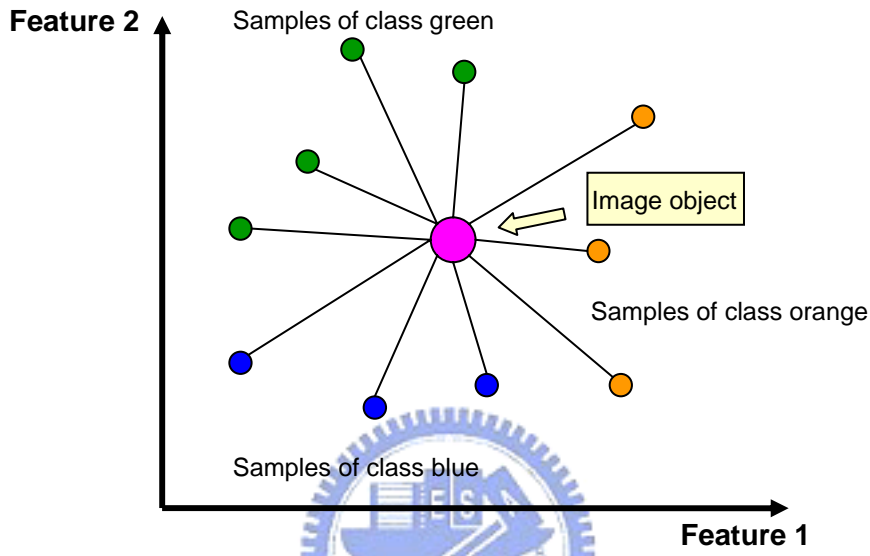


圖 2-11 Nearest Neighbor 原理示意圖

Rule base主要是針對不同類別，設定不同的歸屬函數 (membership function) 作為判釋機制，將參數轉換成對此條件的歸屬值，經邏輯運算因子後，可得對各類別之歸屬值，歸屬值最大的類別則被定義為此區塊之類別，以圖2-12為例，設其為林地類別於NDVI之歸屬函數，則NDVI值愈高，屬林地類別的可能性就愈大。




圖 2-12 歸屬函數示意圖

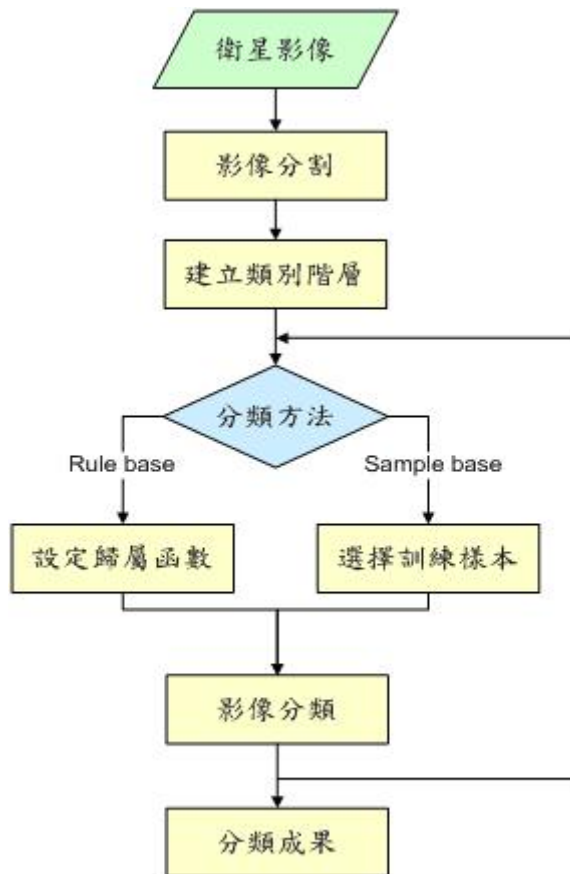


圖 2-13 Definiens Professional 分類流程圖

因此，Definiens Professional 整體分類流程大致如圖2-13所示，而本研究於影像分割的設定上，Scale parameter 設為50，主要是相較於設20、100而言，區塊較不分割過於零碎或粗糙。因本研究之影像分割主要以光譜均調性為主，故Color 設為0.8，又影像所含之地物包括建物、水體等，所分割區塊的形狀不宜太過平滑或太過尖銳，故將Smoothness及Compactness皆設為0.5。而在分類演算法選擇上，因歸屬函數需依影像特性、目標區域及個人經驗所設定，且本研究主要探討物件導向演算法相較逐像元分類法於影像分類之效益，故以Sample base作為本研究主要分類方法。

Scale parameter	Color	Smoothness	分類法
50	0.8	0.5	Sample base

第三章 實驗與分析

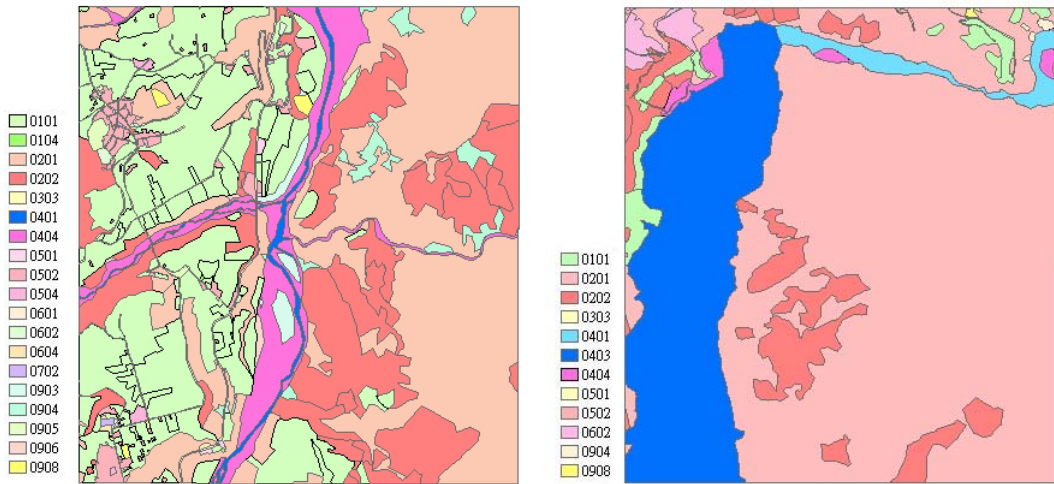
3-1 影像及檢核資料

3-1-1 實驗區影像資料

本研究所採用的影像為 SPOT 5 影像，而 SPOT 系列衛星自 1986 年成功發射至 2002 年，已發射五顆，此系列衛星為太陽同步衛星，平均航高 832 公里。而 SPOT 5 衛星搭載兩個高分辨率幾何裝置 (High Resolution Geometric Imaging Instrument, HRG)、植物感測器 (Vegetation Instrument, VI) 及高分辨率立體成像裝置 (High Resolution Stereoscopic Instrument, HRS)。而每一個 HRG 儀器分別擁有兩個全色態模式(HM)、一個多光譜模式(HI)、以及一個短波紅外線波段 (Shortwave Infrared, SWIR)。若利用兩組 HRG 感測器同時拍攝全色態影像，再經過影像融合處理後，其空間解析度可以提昇到 2.5 公尺。而本研究實驗區便是採用此類影像。


上述空間解析度為 2.5 公尺之 SPOT 5 影像，包含三個波段：綠光波段(XS1：0.50 μ m–0.59 μ m)，紅光波段(XS2：0.61 μ m–0.68 μ m)以及近紅外光波段(XS3：0.79 μ m–0.89 μ m)，取三幅不同土地覆蓋複雜度影像作為本研究實驗區域，分別為久美實驗區、霧社實驗區及瑪谷溪實驗區，如圖 3-2、圖 3-3 及圖 3-4 所示。

而三個實驗區檢核資料取自工研院能環所於國土利用調查之成果，其成果為外業調查後，記錄於圖紙上，再經由人工判釋及相關資料輔助後，數化成向量檔案，通過審查而得，第二級土地分類檢核資料如圖 3-1 所示，本研究分類成果檢核為整幅影像以逐像元方式進行，利用整體精度(Overall Accuracy, OA)及 Kappa 值作為評估分類成果之準確性。



(a) 久美實驗區

(b) 霧社實驗區



(c) 瑪谷溪實驗區

圖 3-1 久美、霧社及瑪谷溪實驗區第二級土地分類圖

(一) 久美實驗區

影像大小為 1021 x 1109 pixels，地理位置處於南投縣信義鄉， 2° TM 坐標為：左上角為 (E = 238065 m, N = 2613315 m)，右下角為 (E = 240617.5 m, N = 2610542.5 m)。久美實驗區較其他兩實驗區，經濟活動繁盛，故土地覆蓋類型繁雜，多為農地、林地、水體、建物及裸露地所組成。

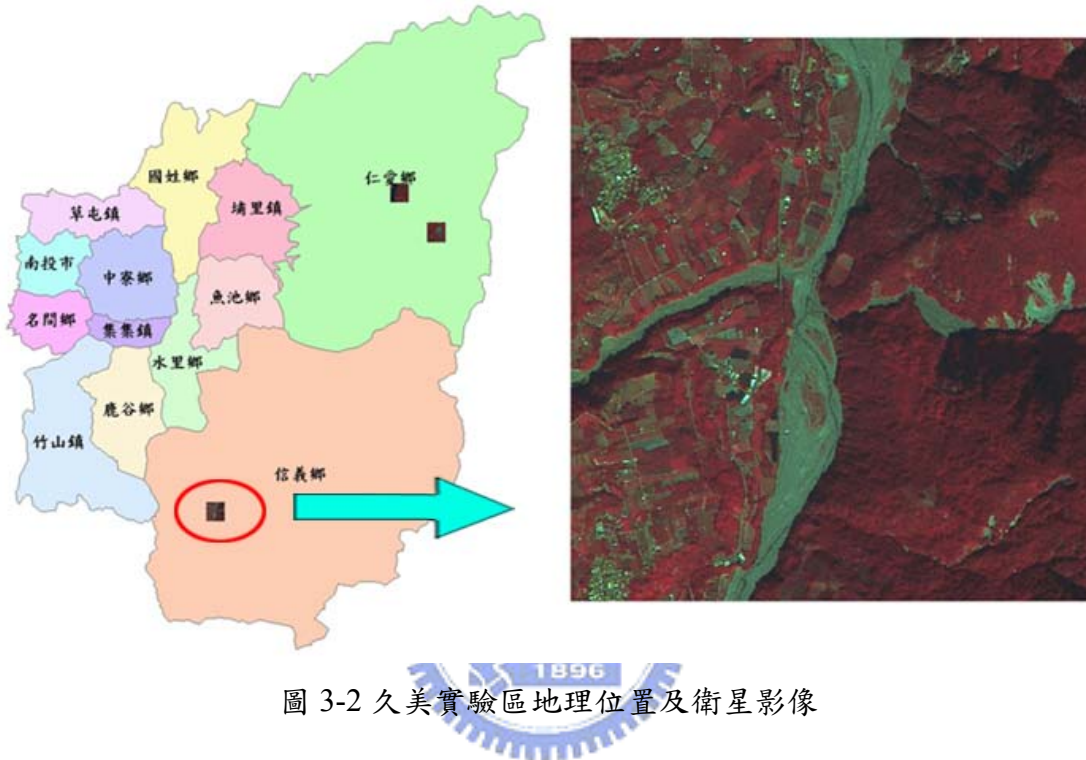


圖 3-2 久美實驗區地理位置及衛星影像

(二) 霧社實驗區

影像大小為 1018 x 1108 pixels，地理位置處於南投縣仁愛鄉， 2° TM 坐標為：左上角為 (E = 263535 m, N = 2657615 m)，右下角為 (E = 266080 m, N = 2654845 m)。霧社實驗區位置近萬大水庫，地處郊區，土地覆蓋類型多為林地、水體及些許建物和裸露地所組成。




圖 3-3 霧社實驗區地理位置及衛星影像

(三) 瑪谷溪實驗區

影像大小為 1020 x 1109 pixels，地理位置處於南投縣仁愛鄉， 2° TM 坐標為：左上角為 (E = 268627.5m, N = 2652085 m)，右下角為 (E = 271177.5m, N = 2649312.5 m)。瑪谷溪實驗區地處高山偏遠地帶，土地覆蓋類型簡單，多為林地及裸露地所組成。




圖 3-4 瑪谷溪實驗區地理位置及衛星影像

依光譜性質將不同土地利用類別歸類成不同土地覆蓋類別，以用來進行本研究分類成果評估，則久美及霧社實驗區可分為五類、而瑪谷溪實驗區則可分為二類，如圖 3-5 所示。

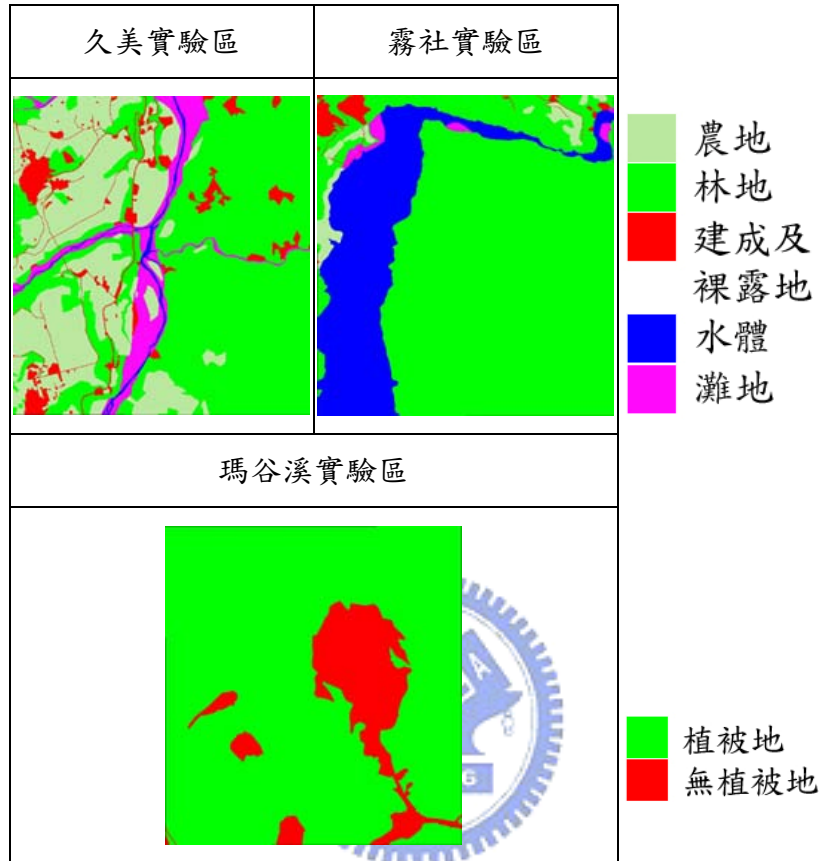


圖 3-5 各實驗區檢核影像

3-1-2 訓練樣本

本研究三個實驗區之訓練樣本為依檢核資料進行初始選取，為避免所選取訓練樣本不足以代表各類別光譜，便以 PCI 軟體計算所選取訓練樣本集合之分離度，作為選取之檢核標準。

表 3-1 不同實驗區之訓練樣本統計資訊

		XS3		XS2		XS1		訓練區像元	
		Mean	Stdev	Mean	Stdev	Mean	Stdev	個數	占總比例
久美	農地	100.53	17.19	68.86	16.06	61.48	7.49	6820	2.0%
	林地	70.24	21.55	40.52	5.60	44.58	5.12	42894	6.8%
	建成及 裸露地	89.72	37.93	114.52	42.76	85.00	31.77	3824	5.2%
	水體	63.43	9.50	90.28	10.06	73.85	7.08	661	5.5%
	灘地	79.67	7.32	124.65	9.89	93.83	6.95	5027	6.5%
霧社	農地	91.87	17.44	68.18	23.79	59.68	10.89	1560	5.8%
	林地	89.08	18.32	41.02	4.81	45.12	4.09	41059	5.1%
	建成及 裸露地	111.84	13.50	134.78	13.66	88.32	8.94	237	1.3%
	水體	17.75	11.12	44.38	13.98	53.35	7.41	27144	10.3%
	灘地	75.68	15.08	106.73	11.42	79.83	6.41	1086	9.6%
瑪谷 溪	植被地	96.28	12.27	43.50	6.48	45.71	4.51	54805	7.23%
	無植被地	51.55	9.26	100.56	14.90	85.07	10.17	11236	5.64%

3-1-3 國土調查計劃

國土調查計劃之目的是透過運用高解析度衛星影像及航空影像，掌握國土利用現況及動態變化，故於 95、96 年度辦理國土利用調查及成果資料整合與建置，並建立完善之更新機制，藉定期更新維護，提供土地規劃管理及永續利用基礎資料，整體作業流程大致為圖 3-6 所示，前置作業準備完成後，進行外業調查，將調查成果記錄於圖紙上，交由數化人員，數化人員透過調查成果與人工判釋後，將其數化成向量檔，交由審查人員，經審查通過後便公佈成果。

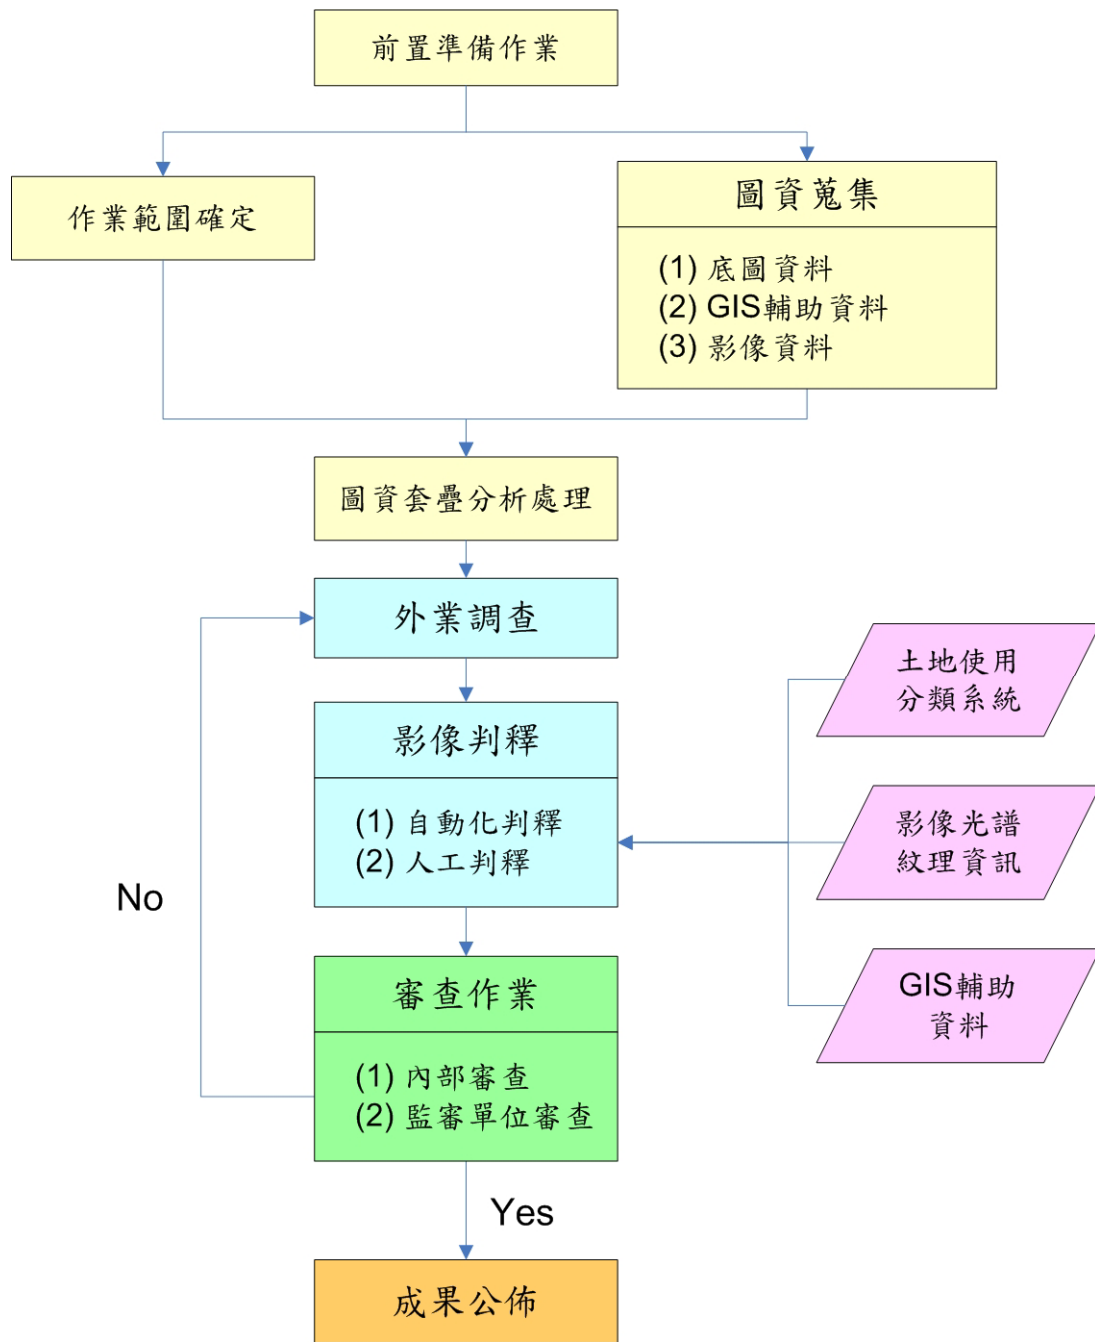


圖 3-6 國土調查計劃作業流程

3-2 影像自動判釋於國土利用調查

3-2-1 不同分類理論之分類成果

本章節主要探討不同分類理論於高解析度影像之分類成果，所採用的分類演算法為高斯最大似然法、ECHO、SVM、BP 及 Definiens Professional。所得分類成果為圖 3-7、圖 3-8、圖 3-9 及表 3-2、表 3-3、表 3-4 所示，顯示土地覆蓋類型愈簡單，所得之分類精度較高，而瑪谷溪實驗區成果顯示高斯最大似然法、ECHO 成果為佳，可能原因為此實驗區各類別分佈為常態分佈，符合兩者演算法之前提假設之故。另外，在土地覆蓋複雜區域，物件導向之分類演算法相較逐像元的分類演算法而言，分類成果精度較高，而且物件導向分類所分類之類別區域較為合理，不會有歸屬為其他類別的零碎像元參雜其中。



表 3-2 不同分類理論於久美實驗區之分類成果

	高斯最大似然法		ECHO		SVM		BP		Definiens Professional	
	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA
農地	71.40	58.10	79.06	61.69	61.36	63.82	71.40	58.10	76.91	67.37
林地	71.75	87.83	73.84	92.63	83.66	82.99	71.75	87.83	84.16	87.94
建成及裸露地	44.89	26.37	50.46	30.70	41.24	33.66	44.89	26.37	28.58	48.57
水體	51.17	28.89	53.23	32.46	45.91	33.49	51.17	28.89	46.95	31.33
灘地	62.26	88.23	61.75	89.43	69.37	83.31	62.26	88.23	81.01	79.79
OA	69.063		72.844		72.794		72.322		77.744	
Kappa 值	0.50573		0.56772		0.54169		0.53844		0.62578	

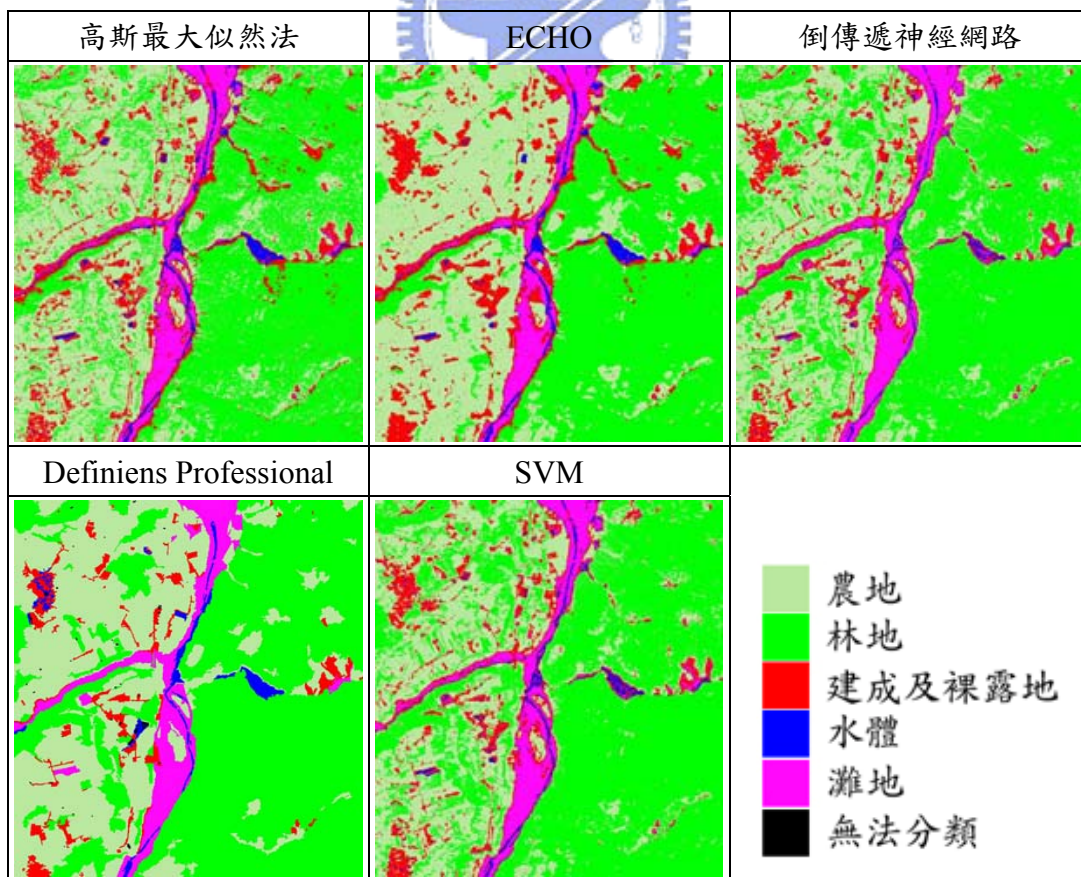


圖 3-7 不同分類理論於久美實驗區之分類成果

表 3-3 不同分類理論於霧社實驗區之分類成果

	高斯最大似然法		ECHO		SVM		BP		Definiens Professional	
	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA
農地	73.06	15.54	81.92	18.44	43.64	26.08	55.55	29.92	66.17	25.12
林地	90.22	98.99	91.80	99.18	98.04	92.27	97.05	97.86	94.01	97.88
建成及裸露地	21.67	57.63	21.35	65.90	17.43	59.68	15.56	67.95	50.21	49.84
水體	88.57	98.41	89.06	98.27	94.13	97.46	95.73	96.77	95.12	97.78
灘地	44.75	25.09	26.61	20.01	32.36	43.63	38.99	38.26	30.54	61.74
OA	87.871		89.146		93.878		93.861		92.266	
Kappa 值	0.74732		0.77034		0.8572		0.8591		0.8289	

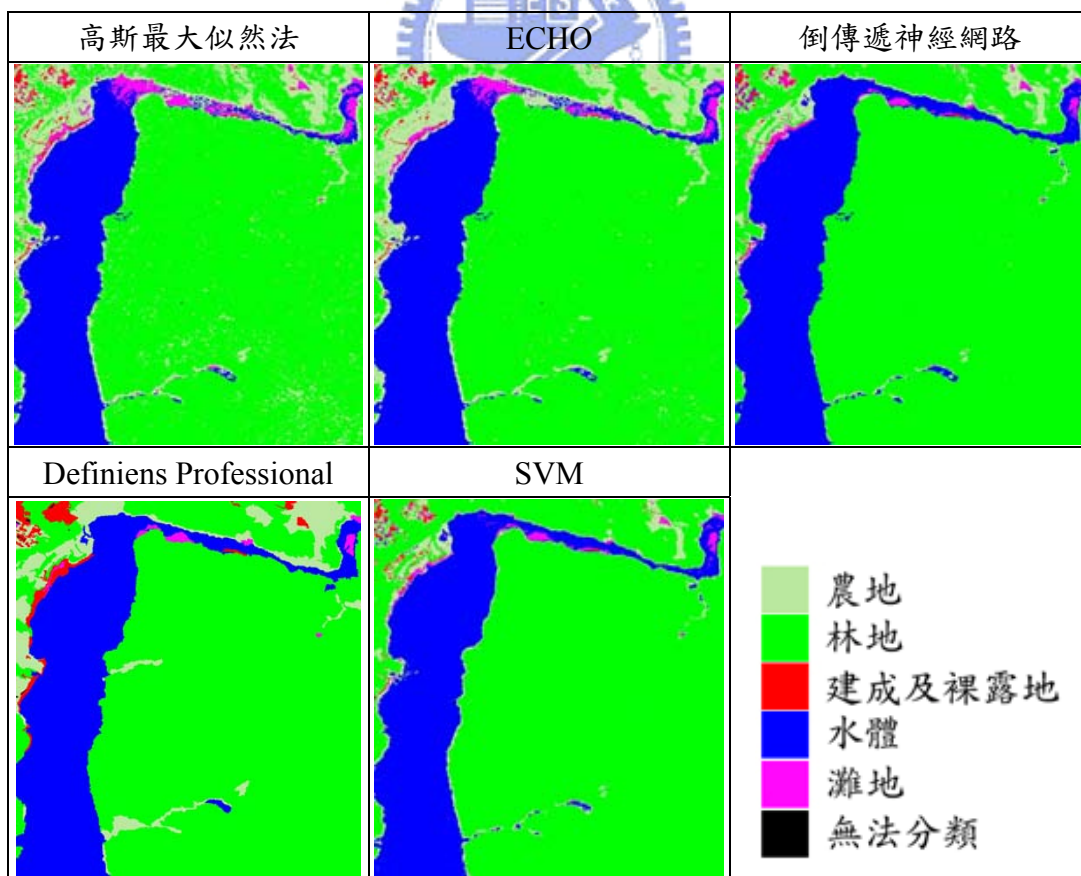


圖 3-8 不同分類理論於霧社實驗區之分類成果

表 3-4 不同分類理論於瑪谷溪實驗區之分類成果

	高斯最大似然法		ECHO		SVM		BP		Definiens Professional	
	PA	UA	PA	UA	PA	UA	PA	UA	PA	UA
無植被地	76.95	87.49	75.93	86.23	76.96	87.51	75.88	88.26	78.70	86.27
植被地	98.24	96.38	98.06	96.22	98.24	96.39	98.39	96.23	97.33	96.90
OA	95.306 %		95.31 %		95.01 %		95.284%		94.759%	
Kappa 值	0.79199		0.79215		0.77896		0.78918		0.77799	

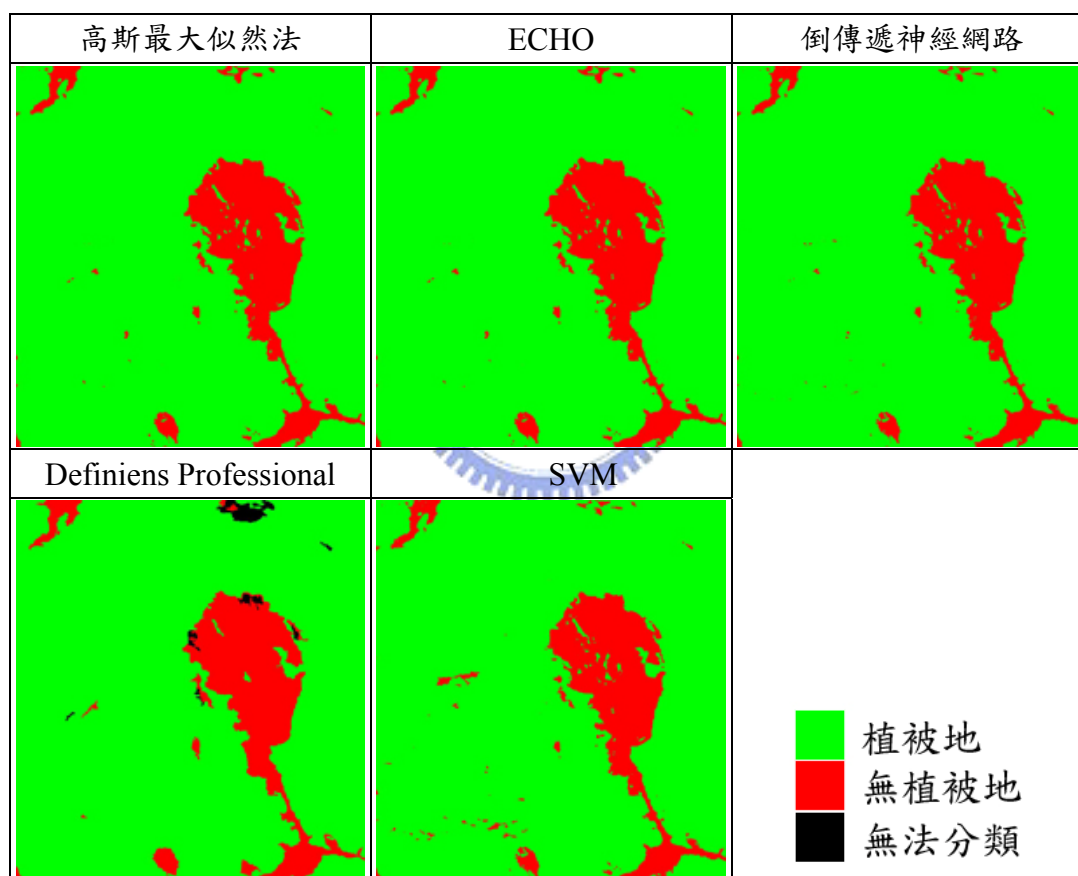


圖 3-9 不同分類理論於瑪谷溪實驗區之分類成果

以 Z-test 檢定各分類理論所建立的分類模式是否具有顯著差異性，以 95% 為信心水準，若兩模式間 Z 值大於 1.96，即表示兩分類模式具有顯著性。各模式間的 Z 值如下表所示，顯示在久美、霧社實驗區各分類模式皆具有顯著差異，而於土地覆蓋類別簡單之分類模式，差異性降低，ECHO 與高斯最大似然法、SVM

與 Definiens Professional 之分類模式不具顯著差異，分類成果相近。

表 3-5 各分類理論之 Z-test

久美實驗區	ECHO	SVM	BP	Definiens Professional
高斯最大似然法	64.291	36.262	33.064	125.229
ECHO		26.839	30.266	62.026
SVM			3.267	87.201
BP				90.801

霧社實驗區	ECHO	SVM	BP	Definiens Professional
高斯最大似然法	25.816	132.460	135.550	96.103
ECHO		106.752	109.760	70.268
SVM			2.569	36.920
BP				39.673

瑪谷溪實驗區	ECHO	SVM	BP	Definiens Professional
高斯最大似然法	0.128	10.287	2.238	11.174
ECHO		10.415	2.366	11.304
SVM			8.025	0.763
BP				8.882

3-2-2 加入紋理影像之分類成果

本實驗欲探討空間相關性的加入是否有助分類精度的提昇，林榮章（1999）指出 GLCM 適合用於自然界影像的紋理分析，故本研究採用 GLCM 方法進行影像紋理的萃取，而針對 GLCM 的參數設定問題，Marceau et al（1990）曾針對此進行探討研究，文中指出取樣視窗尺寸影響性最大，約佔 90%；而不同紋理統計量對於紋理分析的結果約佔 7%的影響量；而灰階編碼參數約佔 3%影響量。由於紋理影像包含空間分佈相關資訊，因此，可以增加影像分類時之區分資訊，故在某些情況下，適當地加入紋理影像，能夠增加分類精度。

而像元對之取樣距離和方向，依周明中（2005）文中指出，像元對方向與紋理走向呈垂直時為最佳，但在一般遙測影像分析上，由於地物並無特定走向，因此多採用像元對方向進行 GLCM 運算。而取樣距離的選擇，比起五個像元以上的距離，一個像元的取樣距離在分辨效果上較有明顯的提升，當取樣距離的距離逐漸拉長以後，相隔的兩個像元已經逐漸不相關了，因此，太大的取樣距離對於紋理分析並沒有幫助，因此本研究所選用的像元對間距為一個像元。

因此，本研究在計算紋理時，取樣視窗大小採用 17x17，取樣方向設為 45°，且為節省計算量，對於 SPOT 影像的紅外波段、紅光波段、及綠光波段，分別採用六種紋理量產生各波段的紋理影像：Homogeneity (H)、Contrast (C)、Angular Second Moment (A)、Dissimilarity (D)、Standard Deviation (S) 及 Entropy (E)。各紋理意義為下所述：

1. Homogeneity：用來衡量影像中均調性。

$$\sum_i \sum_j P_{\delta}(i, j) / (1 + (i - j)^2) \quad (2-34)$$

2. Contrast：和 Homogeneity 相反，用來衡量影像中局部變化的強烈程度，其值和強度呈正比。

$$\sum_i \sum_j (i - j)^2 \times P_{\delta}(i, j) \quad (2-35)$$

3. Angular Second Moment：用來衡量影像局部的均調程度，也就是衡量影像中紋理一致性的程度。

$$-\sum_i \sum_j P_\delta(i, j)^2 \quad (2-36)$$

4. Dissimilarity：和 Contrast 相似，用來衡量影像中灰階值的不相似程度，對灰階值於空間中 pattern 或影像色調都十分敏感。

$$\sum_i \sum_j P_\delta(i, j) \times |i - j| \quad (2-37)$$

5. Standard Deviation：為影像局部區域的標準差值。

$$\sum_i \sum_j P_\delta(i, j) \times (i - Mean_i)^2 \quad (2-38)$$

6. Entropy：和 ASM 相反，用來衡量紋理的雜亂程度，若影像圖樣越接近隨機時，其值就愈大。

$$-\sum_i \sum_j (i - j)^2 \times P_\delta(i, j) \quad (2-39)$$

本章節大致分為二個部分進行探討，整體研究流程為圖 3-10 所示，一個是探討不同紋理影像對不同類別之貢獻程度，另一個則是探討以 PCA、Rough Set 於紋理資訊萃取之前處理，是否有助於精度的提升。由於取樣視窗 17x17 有過大之疑，因此，針對於久美實驗區與霧社實驗區另以取樣視窗為 3x3 進行成果比較。

另外，由支持向量機及倒傳遞神經網路於一幅影像分類之執行效率低，十分耗時，而 Definiens 則是受限於參數設定問題，依不同影像特性須設定不同參數，無法作客觀比較，因此，在加入紋理影像分類實驗，主要以高斯最大似然法和 ECHO 作為主要分類器，僅於以 PCA、Rough Set 於紋理資訊萃取前處理之研究部分，加入支持向量機分類器。

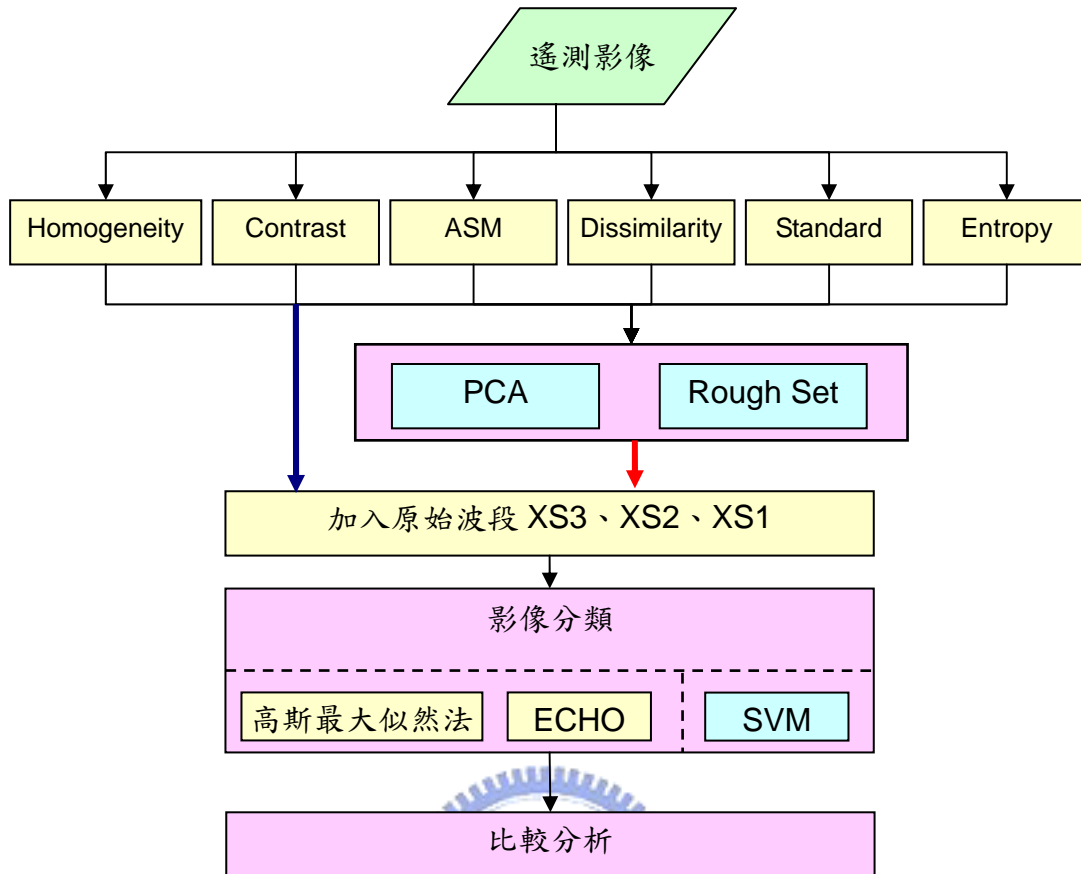


圖 3-10 加入紋理影像之分類流程

(一) 不同紋理影像對不同類別之分類成果

為探討不同紋理影像對不同類別之貢獻，故針對三個波段所產生的同一紋理影像統計量，分別進行高斯最大似然法及 ECHO 演算法進行分類，再依不同類別之分類精度進行比較分析，圖 3-11、3-12、3-13 則為三個實驗區加入取樣視窗為 17x17 計算之紋理後不同類別之分類精度比較。





圖 3-11 久美實驗區加入取樣視窗為 17x17 計算之紋理於不同類別之分類精度





圖 3-12 霧社實驗區加入取樣視窗為 17x17 計算之紋理於不同類別之分類精度





圖 3-13 瑪谷溪實驗區加入取樣視窗為 17x17 計算之紋理於不同類別之分類精度

而針對於久美實驗區與霧社實驗區改以取樣視窗為 3x3 計算紋理，加入後對於不同類別，各紋理的貢獻度比較，如下圖 3-14、3-15 所示。

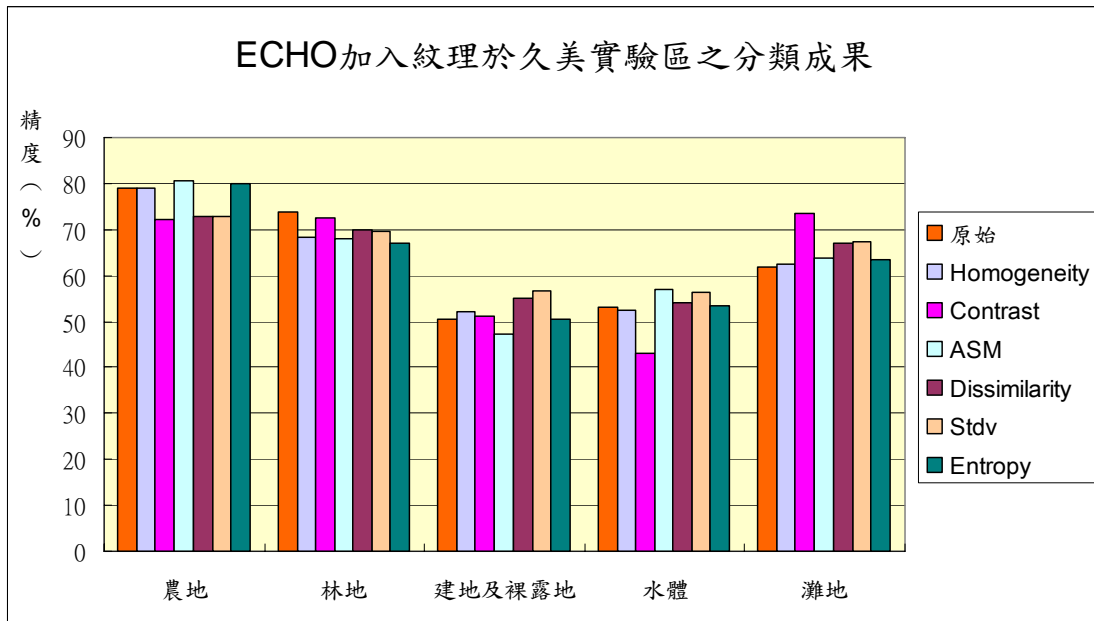



圖 3-14 久美實驗區加入取樣視窗為 3x3 計算之紋理於不同類別之分類精度





圖 3-15 霧社實驗區加入取樣視窗為 3x3 計算之紋理於不同類別之分類精度

由上可得，兩種不同大小的取樣視窗所計求得的紋理統計量，對於不同類別的貢獻度，呈現不同成果，17x17 取樣視窗於在三個實驗區，不同紋理統計量於同一類別上的貢獻相近，差異並不大，但對於紋理特徵相異之類別，貢獻度便有明顯區分，可能原因在於 17x17 的取樣視窗，對於實驗區紋理計算而言過大，故不同紋理統計量無法發揮其特性。而 3x3 取樣視窗於在久美、霧社實驗區中，不同紋理統計量對同一類別的貢獻度不盡相同，由圖 3-14、3-15 可看出 Contrast

所得紋理對於灘地類別有相當助益，但對於農地則否，且在各類別的貢獻上，Contrast 和其他紋理統計量明顯不同，ASM 對於建地及裸露地類別則效果不彰。

而兩種不同大小的取樣視窗所得紋理皆無法有效提昇分類精度，見表 3-6。但相較於高斯最大似然法，紋理的加入對於 ECHO 助益不大，可能原因為物件導向分類法於影像分割階段，紋理的加入，導致分割出影像區塊更加零碎，故在分類上，近似高斯最大似然法，降低 ECHO 以區塊方式分類的長處。

比較六種紋理統計量於不同類別之分類精度，紋理統計量對於建成及裸露地類別區分上，有所助益，尤其久美實驗區經濟繁盛，因此建物、道路等較為集中，具有規則性，紋理特徵較為明顯，因此，紋理統計量較能有效提昇此類別之精度，但在霧社實驗區則不一定，可能原因在於霧社實驗區地處郊區，建物小且分散，且多為山路。

表 3-6 不同取樣視窗大小於不同實驗區分類之整體精度

	紋理統計量	久美實驗區		霧社實驗區	
		17 x 17	3 x 3	17 x 17	3 x 3
高斯最大似然法	Homogeneity	71.099	68.235	86.780	88.203
	Contrast	67.487	69.513	86.308	87.454
	ASM	62.156	67.753	90.297	89.057
	Dissimilarity	69.713	68.073	85.440	87.797
	Stdev	64.474	68.4	87.036	87.759
	Entropy	70.200	67.990	87.521	88.970
ECHO	Homogeneity	71.090	69.952	87.060	89.061
	Contrast	69.192	70.748	86.883	88.289
	ASM	62.914	69.946	90.207	89.147
	Dissimilarity	69.427	69.506	86.297	88.719
	Stdev	64.454	69.408	87.350	88.331
	Entropy	70.045	69.512	87.522	88.970

(二) 以 PCA、Rough Set 於紋理資訊萃取之前處理

PCA 及 Rough Set 皆是萃取資訊的方法，降低資料維度過多的問題。

主成分分析(Principal Component Analysis, PCA)是一種將光譜特徵空間轉換至另一個主軸特徵空間的轉換方法，透過轉換，加大資料間的差異，去除遙測影像高相關波段間的冗餘光譜資訊 (spectral redundancy)，同時可以避免在分類時因樣本太少而發生 Hughes 現象 (林金樹，2002)。由於原始變數資料經 PCA 轉換後，有多少原始變數便會產生多少主軸，轉換後全部主軸之變異數總和等於原始所有變數之變異數總和，且各變數大部分的資訊均會被轉換到少數幾個主軸上，因此只要選用大部分變異量的少數主軸進行分析，便可達到資料減量目的。

選取少數的主軸雖可達成降低資料維度的目標，但卻會降低少數主軸對原始變數資料之代表性，反之，選取多數的主軸雖可增加其解釋原始變數光譜資訊的能力，但卻會失去降低資料維度之目標。然選取多少個主軸作為分析之用，是一項難題，傳統的選定主軸數之方法有特性根閾值法 (Eigenvalue Threshold method, ET)、特性根陡坡圖檢定法 (Scree Test, ST) 及累積變異數百分比閾值 (Threshold of Cumulative Variance Proportion, TCVP) 等三種方法 (林金樹，2002)。

本研究採用 TCVP 法，此法是以各主軸所能解釋的全體變數資料變異量的比例為依據，設定所用以分析的主軸數，其變異數百分比的累積值之最低限值，依黎瑋 (1998) 所設定 95% 為主要門檻值，剔除資訊含量過少的影像。表 3-7 為各實驗區以取樣視窗為 17x17 之紋理影像經 PCA 法轉換後前八個主軸資訊，而表 3-8 則是針對久美實驗區及霧社實驗區以加入取樣視窗為 3x3 計算之紋理影像經 PCA 法轉換後前八個主軸資訊，表 3-7、3-8 中，藍色區域為所選用之主軸影像。

表 3-7 各實驗區之主軸資訊 (取樣視窗為 17x17)

Eigen Channel	久美實驗區		霧社實驗區		瑪谷溪實驗區	
	EigenValue	Cumulative	EigenValue	Cumulative	EigenValue	Cumulative
1	7901.8135	52.80%	12956.18	65.83%	18495.32	76.34%
2	4218.2246	80.99%	2966.301	80.90%	2825.945	88.00%
3	1180.0802	88.88%	1035.807	86.16%	1002.647	92.14%
4	550.8677	92.56%	939.1375	90.93%	852.8278	95.66%
5	427.2045	95.41%	772.2014	94.85%	338.4072	97.06%
6	299.4473	97.41%	242.7369	96.08%	257.4453	98.12%
7	123.5441	98.24%	222.3466	97.21%	174.992	98.84%
8	90.3272	98.84%	175.4893	98.10%	95.03559	99.23%

表 3-8 各實驗區之主軸資訊 (取樣視窗為 3x3)

Eigen Channel	久美實驗區		霧社實驗區	
	EigenValue	Cumulative	EigenValue	Cumulative
1	2834.048	76.42%	2202.134	81.80%
2	708.6702	95.53%	366.7329	95.42%
3	159.9344	23.42%	118.0907	18.01%
4	3.3098	4.40%	2.7724	4.49%
5	1.3912	0.13%	0.7596	0.13%
6	0.5443	0.05%	0.6404	0.05%
7	0.249	0.02%	0.4498	0.04%
8	0.1514	0.01%	0.1792	0.03%

粗糙集方法 (Rough Set) 目的在於處理含糊 (vagueness) 及不確定性 (uncertainty) 資料之關係發掘。為將訓練樣本及其相應之屬性所組成的資訊系統，透過離散化及縮減等方式，擷取足夠描述各樣本在何種屬性條件下能被分類的規則，即對樣本屬性進行縮減，將多餘的屬性予以剔除，僅以縮減後的屬性進

行規則擷取（陳承昌，2006）。

因此利用原始三個波段加入全部波段的六種紋理影像以 PCA 法萃取前 95% 資訊量之主軸波段，以及透過粗糙集所擷取的有用波段後，進行分類作業，所得到的成果為表 3-9 及表 3-10 所示。

顯示加入 PCA 前 95% 資訊量萃取之前處理所得主軸波段對於分類結果助益不大，但 Rough Set 的加入，有時提升高斯最大似然法及 SVM 的分類精度，主要是因 PCA 雖可以降低資料維度，但可能在剔除資訊含量過少的影像同時，也將足以區分不同類別的波段也跟著剔除了，所選取的主軸波段雖然資訊豐富，但卻不足以區分類別，反而造成分類時的雜訊，使精度下降。其中，霧社實驗區於 SVM 加入 Rough Set 所萃取的波段未得到提升，可能是因為 SVM 於霧社實驗區中無法得取得最佳參數進行分類，而導致成果不如未加入前成果為佳。

但 Rough Set 所擷取的是足以描述樣本類別的波段，因此，除了可以達到資料維度的減少，也可以得到具代表性的波段，因此相較於 PCA 所萃取的主軸波段，分類成果較佳。

瑪谷溪實驗區兩者之分類成果精度皆不如單用原始光譜，可能是於瑪谷溪實驗區紋理特徵並不明顯，因此不論是加入用 PCA 或 Rough Set 所萃取的紋理資訊，都無法提升分類精度。

表 3-9 原始波段加入 PCA 及 Rough Set 萃取影像之分類成果(取樣視窗為 17x17)

實驗區	萃取方式	分類理論	OA	Kappa 值
久美	Original	高斯最大似然法	69.063%	0.50573
		ECHO	72.844 %	0.56772
		SVM	72.794%	0.54169
	PCA	高斯最大似然法	63.908%	0.44802
		ECHO	63.996%	0.45029
		SVM	69.625%	0.51180
	Rough Set	高斯最大似然法	69.589%	0.51882
		ECHO	69.457%	0.52023
		SVM	74.736%	0.57802
霧社	Original	高斯最大似然法	87.871%	0.74732
		ECHO	89.146%	0.77034
		SVM	93.878%	0.8572
	PCA	高斯最大似然法	88.716%	0.76133
		ECHO	88.910%	0.76472
		SVM	91.395%	0.81219
	Rough Set	高斯最大似然法	88.092%	0.75276
		ECHO	88.210%	0.75497
		SVM	92.251%	0.82795
瑪谷溪	Original	高斯最大似然法	95.306%	0.79199
		ECHO	95.310%	0.79215
		SVM	95.01%	0.77896
	PCA	高斯最大似然法	94.460%	0.74208
		ECHO	94.460%	0.74208
		SVM	94.54%	0.75539
	Rough Set	高斯最大似然法	94.353%	0.72689
		ECHO	94.353%	0.72689
		SVM	95.109%	0.78161

表 3-10 原始波段加入 PCA 及 Rough Set 萃取影像之分類成果(取樣視窗為 3x3)

實驗區	萃取方式	分類理論	OA	Kappa 值
久美	Original	高斯最大似然法	69.063%	0.50573
		ECHO	72.844 %	0.56772
		SVM	72.794%	0.54169
	PCA	高斯最大似然法	68.141%	0.49742
		ECHO	69.703%	0.52876
		SVM	73.236%	0.55405
	Rough Set	高斯最大似然法	68.375%	0.50033
		ECHO	70.230%	0.53172
		SVM	72.924%	0.54919
霧社	Original	高斯最大似然法	87.871%	0.74732
		ECHO	89.146%	0.77034
		SVM	93.878%	0.85720
	PCA	高斯最大似然法	87.481%	0.73868
		ECHO	88.508%	0.75684
		SVM	93.684%	0.85249
	Rough Set	高斯最大似然法	88.498%	0.75770
		ECHO	88.938	0.76636
		SVM	93.849%	0.85649

以 Z-test 檢定各分類理論加入 PCA 及 Rough Set 前後所建立的分類模式是否具有顯著差異性，以 95% 為信心水準，由表 3-11、3-12 可得，不論計算紋理統計量所採用的取樣視窗大小為何，加入 PCA 與加入 Rough Set 之分類模式皆具有顯著差異，且加入萃取資料前後之分類模式也具有顯著差異。

表 3-11 各實驗區加入 PCA 與加入 Rough Set 前後之 Z-test (取樣視窗 17x17)

久美		MLC			ECHO			SVM		
		Original	PCA	RoughSet	Original	PCA	RoughSet	Original	PCA	RoughSet
MLC	Original		58.793	13.395	64.291	56.542	14.882	36.262	6.165	74.367
	PCA			72.794	124.747	2.326	74.466	94.891	65.076	134.375
	RoughSet				51.201	70.539	1.461	23.271	7.195	61.474
ECHO	Original					122.522	49.879	26.839	58.088	10.844
	PCA						72.206	92.691	62.829	132.177
	RoughSet							21.900	8.666	60.194
SVM	Original								30.186	37.160
	PCA									68.229
	RoughSet									

霧社		MLC			ECHO			SVM		
		Original	PCA	RoughSet	Original	PCA	RoughSet	Original	PCA	RoughSet
MLC	Original		15.585	6.037	25.816	19.399	8.504	132.460	75.251	94.800
	PCA			9.588	10.189	3.811	7.128	116.687	59.526	79.047
	RoughSet				19.831	13.411	2.471	126.752	69.371	88.972
ECHO	Original					6.370	17.367	106.752	49.422	68.990
	PCA						10.951	112.859	55.695	75.214
	RoughSet							124.315	66.914	86.519
SVM	Original								57.626	38.069
	PCA									19.618
	RoughSet									

瑪谷溪		MLC			ECHO			SVM		
		Original	PCA	RoughSet	Original	PCA	RoughSet	Original	PCA	RoughSet
MLC	Original		37.353	47.419	0.128	37.353	47.419	10.287	28.085	8.201
	PCA			10.453	37.478	0.000	10.453	27.253	9.593	29.231
	RoughSet				47.542	10.453	0.000	37.475	20.030	39.407
ECHO	Original					37.478	47.542	10.415	28.212	8.329
	PCA						10.453	27.253	9.593	29.231
	RoughSet							37.475	20.030	39.407
SVM	Original							17.847		2.064
	PCA									19.868
	RoughSet									



表 3-12 各實驗區加入 PCA 與加入 Rough Set 前後之 Z-test (取樣視窗 3x3)

久美		MLC			ECHO			SVM		
		Original	PCA	RoughSet	Original	PCA	RoughSet	Original	PCA	RoughSet
MLC	Original		8.463	5.501	64.291	23.776	26.751	36.262	49.121	44.116
	PCA			2.977	73.237	32.499	35.461	44.831	57.817	52.778
	RoughSet				70.221	29.488	32.459	41.893	54.857	49.822
ECHO	Original					41.172	37.924	26.839	14.214	19.239
	PCA						3.104	13.272	26.177	21.115
	RoughSet							10.203	23.043	18.001
SVM	Original								12.494	7.571
	PCA									4.946
	RoughSet									

霧社		MLC			ECHO			SVM		
		Original	PCA	RoughSet	Original	PCA	RoughSet	Original	PCA	RoughSet
MLC	Original		9.460	11.522	25.816	10.547	21.286	132.460	125.965	131.473
	PCA			20.947	35.220	19.960	30.697	141.548	135.064	140.563
	RoughSet				14.262	0.958	9.740	120.796	114.326	119.813
ECHO	Original					15.201	4.524	106.752	100.287	105.770
	PCA						10.686	121.548	115.091	120.567
	RoughSet							111.221	104.754	110.239
SVM	Original								6.271	0.952
	PCA									5.320
	RoughSet									

3-2-3 原始影像光譜檢核

本章節主要檢驗原始影像光譜資訊，針對複雜土地覆蓋類別的久美及霧社實驗區，以全幅影像作為訓練樣本，再利用高斯最大似然法及 ECHO 進行全幅影像分類，所得分類成果圖如圖 3-16、3-17。

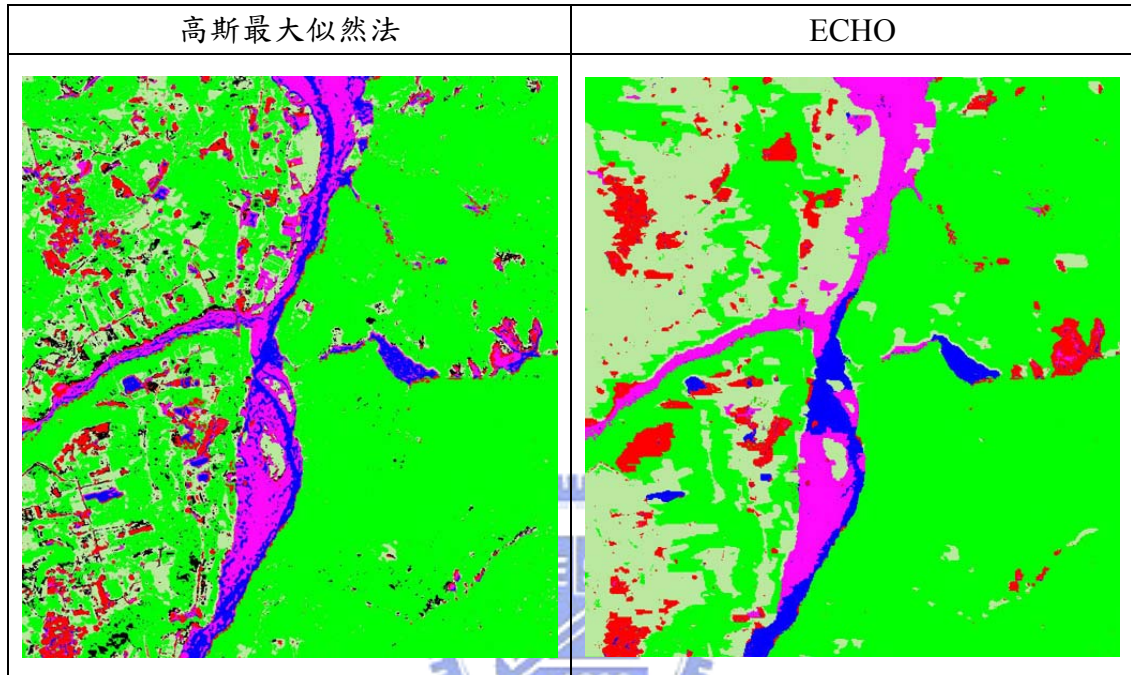


圖 3-16 久美實驗區以全幅影像訓練樣本之分類成果




圖 3-17 霧社實驗區以全幅影像訓練樣本之分類成果

表 3-13 久美、霧社實驗區以全幅影像訓練樣本之分類精度

	久美實驗區				霧社實驗區			
	高斯最大似然法		ECHO		高斯最大似然法		ECHO	
	PA	UA	PA	UA	PA	UA	PA	UA
農地	38.477	70.473	56.659	710.092	44.004	29.349	73.881	39.987
林地	92.28	75.552	89.332	81.051	96.052	98.341	95.892	98.844
建成及 裸露地	32.41	39.094	37.07	43.465	31.753	44.390	45.076	56.011
水體	78.914	21.232	56.945	22.090	88.264	98.645	85.949	99.259
灘地	59.96	63.514	68.242	71.103	82.051	18.759	86.35	19.018
OA	69.809		74.291		91.818		92.136	
Kappa 值	0.46725		0.55711		0.81747		0.82639	

由表 3-13 可以看出，雖然精度較原先單選幾處區域作訓練樣本區之成果為佳，但並非達到最好分類成果。再透過視覺比對、光譜統計量及分離度進行分類成果評估，以檢驗原始影像光譜資訊：

(一) 視覺比對

圖 3-18、3-19 分別為久美實驗區和霧社實驗區於不同分類法之分類成果，與檢核資料進行比對所得，紅色區域表分類錯誤像元。可以明顯看出在類別邊緣部分多分類錯誤，在類別繁雜區域，分類錯誤也就更明顯，尤其是建成及裸露地類別區域，可以看出混合像元情形嚴重，而 ECHO 因有考慮周遭像元光譜性質，再以區塊方式分類，故所得分類成果圖各類別區塊較少有其他類別之零碎像元滲入其中，較為合理，且精度也較高。

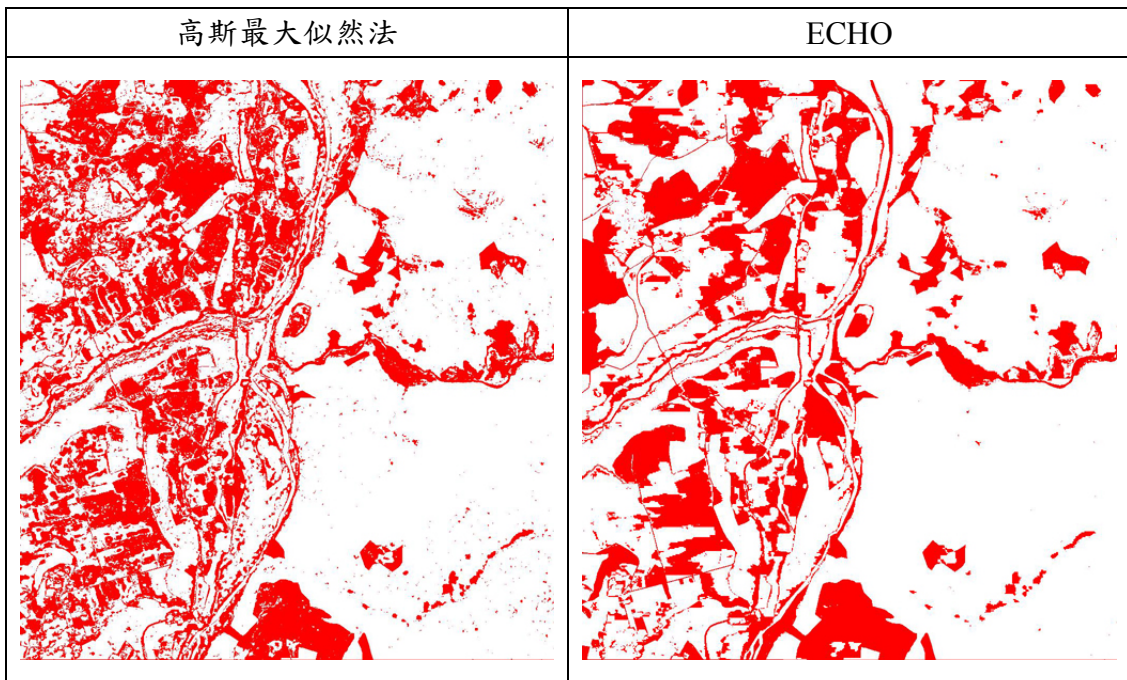


圖 3-18 久美實驗區分類結果與檢核資料之比對成果圖

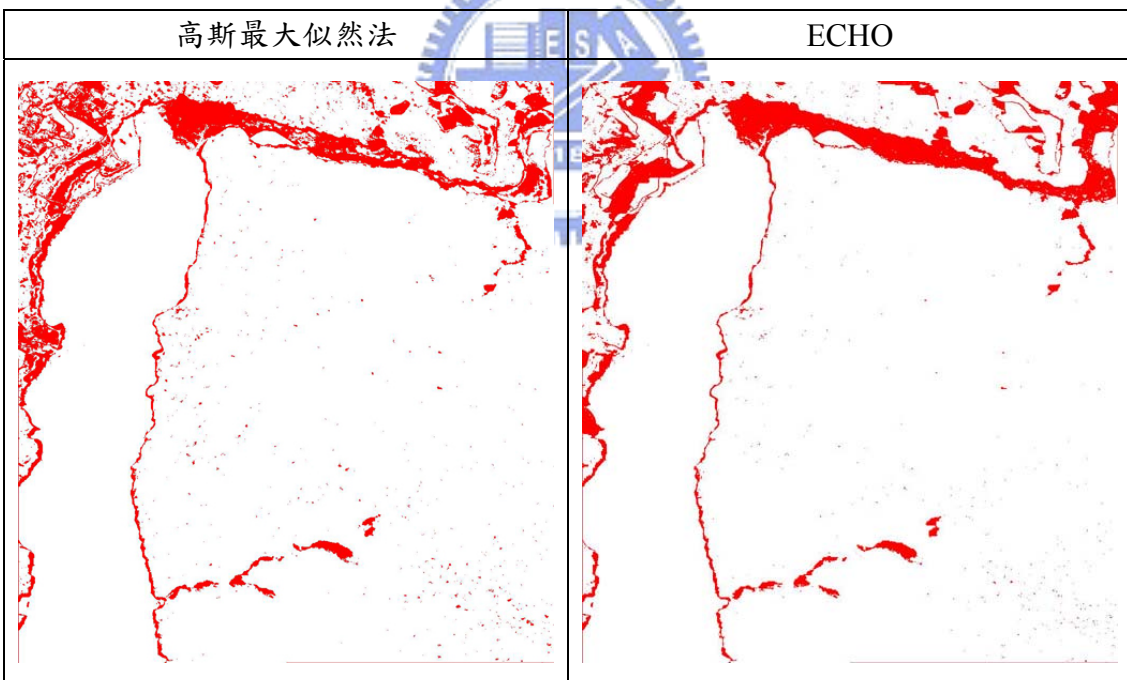


圖 3-19 霧社實驗區分類結果與檢核資料之比對成果圖

(二) 光譜統計量

表 3-14、3-15 為兩實驗區各類別光譜統計量，久美實驗區中，林地類別於紅、綠光之光譜均值和其他類別有明顯區分，農地類別雖然和水體、灘地類別有

區分性，但和建成及裸露地類別光譜均值則相近。

霧社實驗區中，林地類別於紅、綠光之光譜均值，雖和水體類別相近，但和他者有明顯區分，且與水體之紅外光光譜均值差異頗大，農地類別和水體類別於三個波段之光譜均值有明顯區分，和灘地類別、建成及裸露地類別光譜均值則相近，故此三類易產生混淆。

表 3-14 久美實驗區各類別光譜統計量

	Mean			Standard Deviation		
	XS3	XS2	XS1	XS3	XS2	XS1
農地	96.85	68.711	61.394	20.115	21.346	12.121
林地	82.325	47.273	49.806	24.357	13.639	8.7459
建成及裸露地	92.829	90.122	71.756	30.218	38.923	24.502
水體	71.192	101.76	81.324	15.538	18.339	12.243
灘地	79.52	112.57	86.6	14.378	21.766	13.252

表 3-15 霧社實驗區各類別光譜統計量

	Mean			Standard Deviation		
	XS3	XS2	XS1	XS3	XS2	XS1
農地	99.126	70.257	60.839	19.578	23.308	12.253
林地	89.066	42.472	46.026	20.357	7.3558	5.0996
建成及裸露地	96.83	87.679	68.8	31.322	39.173	23.086
水體	20.197	42.64	51.95	15.337	14.001	7.0014
灘地	76.653	92.298	72.186	20.422	21.141	11.555

(三) 分離度

依分離度來評估兩實驗區各類別間光譜特徵之區分程度，主要以 Jeffries-Mastusuta Distance 進行分離度分析，而 Jeffries-Mastusuta Distance 定義為 (Schowengerdt, 1997)：

$$B = \frac{1}{8}MH + \frac{1}{2} \ln \left[\frac{|(C_a - C_b)/2|}{(|C_a||C_b|)^{1/2}} \right]$$

$$JM = \left[2(1 - e^{-B}) \right]^{1/2}$$

其中，

$$MH = \left[(\mu_a - \mu_b)^T \left(\frac{C_a + C_b}{2} \right)^{-1} (\mu_a - \mu_b) \right]^{1/2}$$

所計求出的分離度值，為值域為 0 至 2 之間的實數值，0 代表兩個類別特徵 (signature) 相互重疊，而 2 即代表可以完全分離，其值域所代表的意義細分如下：

- 0.0 to 1.0 (非常低的分離度) — 表示兩個特徵值在統計上十分接近。
- 1.0 to 1.9 (低分離度) — 表示兩個特徵值之間有些許距離。
- 1.9 to 2.0 (良好分離度)

由表 3-16、表 3-17 可以明顯看出，兩實驗區各類別之分離度皆不佳。

表 3-16 久美實驗區各類別之分離度

久美實驗區	農地	林地	建成及裸露地	水體	灘地
農地	0	0.76662	0.79392	1.0071	0.89196
林地	0.76662	0	1.0858	1.0881	1.0361
建成及裸露地	0.79392	1.0858	0	1.0776	0.98412
水體	1.0071	1.0881	1.0776	0	0.62266
灘地	0.89196	1.0361	0.98412	0.62266	0

表 3-17 霧社實驗區各類別之分離度

霧社實驗區	農地	林地	建成及裸露地	水體	灘地
農地	0	1.0411	0.72762	1.1331	0.77324
林地	1.0411	0	1.2166	1.2032	1.1703
建成及裸露地	0.72762	1.2166	0	1.2085	0.84895
水體	1.1331	1.2032	1.2085	0	0.96806
灘地	0.77324	1.1703	0.84895	0.96806	0

由上述所得，分類錯誤原因除了多發生於各類別邊界部分外，按各類別光譜統計量及特徵分離度觀之，影像本身之光譜性質在某些類別的辨別上，似乎也難以明顯區分。



3-3 大幅影像之軟體執行效能

本節主要是探討大幅影像於不同分類演算法之執行效能，採用二種不同影像尺寸進行測試，而所測試之電腦配備為下：

- Intel (R) Xeon (TM) CPU 3 GHz 雙處理器
- RAM：3.5 GB
- Hard Disk：50 GB、500 GB

經測試後，得到下表，由表 3-18 可得，利用物件導向分類之演算法，在分類大幅影像的過程中，需要大量的記憶體，以儲存分割影像所產生的物件，因此，當影像過大時，則易發生記憶體空間不足情形。而最大似然法為逐像元方式計算每一像元為特定分類的統計機率，以最大機率來判斷類別歸屬，故過程中不需過大的記憶體。

表 3-18 不同影像尺寸於不同分類演算法之執行效能

影像大小為 2700 x 3700 pixels			
	可否運行	執行時間	附註
最大似然法	O	10 sec	MultiSpec 軟體
ECHO	O	8 sec	MultiSpec 軟體
SVM	O	約二星期	
Definiens Professional	O	2.5 min (segmentation) + 5 sec (分類)	

影像大小為 17000 x 20000 pixels			
	可否運行	執行時間	附註
最大似然法	O	3.8 min	MultiSpec 軟體
ECHO	X		MultiSpec 軟體
Definiens Professional	X		

第四章 結論與建議

在不同分類演算法之分類成果，得出物件導向分類方法於土地覆蓋複雜之分類成果為佳，而且物件導向分類所分類之類別區域較為合理，不會有歸屬為其他類別的零碎像元參雜其中，但加入紋理資訊後，物件導向分類方法。於土地覆蓋簡單之分類成果，高斯最大似然法和 ECHO 之分類模式不具顯著差異，可能原因在於 ECHO 主要是將影像分割成許多不相交的方形區域，再以二階最大似然法進行分類，本質上與高斯最大似然法分類模式十分相似，故於瑪谷溪實驗區進行分類，因實驗區土地覆蓋類別僅分兩類，類別光譜值分佈可能接近常態分佈，使得兩者分類成果相近。

支持向量機在三個實驗區的分類成果非為最佳，主要是因為支持向量機在求取最佳參數組合時，因土地覆蓋類型過於複雜，故無法模擬出最適超平面以區分類別，而使其分類成果較倒傳遞神經網路不佳。

在加入空間相關性之分類成果，顯示不同紋理統計量於同一類別上的貢獻和取樣視窗尺寸相關，若取樣視窗過大，則六個紋理統計量所得成果，差異並不大，但對於紋理特徵相異之類別，紋理統計量的加入帶來的效益便有明顯區分。而且，紋理影像的加入多均無法有效提升精度，原因可能是紋理統計量在計算上十分敏感，而所採用的實驗影像為融合影像，影像本身的空間及光譜資訊，相較原始影像而言皆有所損失，故紋理特徵不明顯，因此除了建議可以採用原始影像自動分類外，也可利用其他紋理特徵萃取的方法，像是半變異量、小波等，探討是否能增加分類成果精度，並增加不同實驗區以了解不同紋理萃取對不同類別的貢獻程度。

相較於高斯最大似然法，紋理的加入對於 ECHO 助益不大，可能原因在於物件導向分類法於影像分割階段，紋理的加入，導致所分割出的影像區塊更加零碎，故在影像分類上，近似逐像元分類法，降低 ECHO 分類法以影像區塊方式進行分類的長處，建議可以採用其他物件導向分類法深入探討，加入紋理後，對

物件導向分類之影響。

利用 PCA 與 Rough Set 進行紋理資訊萃取前處理，兩者的加入於不同分類演算法所建立之分類模式具有顯著差異，而且透過 Rough Set 之紋理資訊萃取前處理，相較於主成份分析法，能有效的提昇高斯最大似然法與 SVM 之分類精度，主要是因 PCA 雖然降低資料維度，但可能在剔除資訊含量過少的影像同時，也剔除了足以區分不同類別的波段，造成分類精度下降，反之，Rough Set 所擷取的是足以描述樣本類別屬性的波段，除了可以達到資料維度的減少，也可以得到具代表性的波段。

而不論採用低解析度或高解析衛星影像，皆屬於二維空間資料，有些光譜性質相近地物無法僅靠二維空間的資訊判釋、區分，像是建地和崩塌地等，若加入高程資料進行判釋，便可計求坡度因子等，設定區分類別門檻值，因此可有效劃分光譜難以區分類別，如建地和崩塌地等，因此，建議未來可加入三維空間資訊於影像自動判釋作業。

對大幅影像分類而言，物件導向分類演算法，相較於逐像元方式於大幅影像進行分類，軟體執行效能差，須提防記憶體不足情形。

參考文獻

- 何裕琨、曾建昌，2003。使用小波係數具抗旋轉性之顏色紋理影像檢索系統。國立成功大學電機工程研究所
- 李瑞陽、莊佳文，2006。運用影像方塊方法於高解析衛星影像土地利用判釋精度之研究。航測及遙測學刊，2006年12月，11(4):403-415。
- 林榮章，1999。都會區多解像力遙測影像之紋理分析，國立中興大學土木工程學系碩士論文。
- 林金樹，2002。高光譜影像辨識土地利用型最適主軸數之決定，台灣林業科學17(4): 471-81, 2002。
- 周明中，2005。紋理輔助高解析度衛星影像分析應用於偵測入侵性植物分布之研究，國立中央大學土木工程學系碩士論文。
- 邵泰璋，1999。類神經網路於多光譜影像分類之應用，國立交通大學土木工程學系碩士論文。
- 洪蜜琪，2007。整合光譜與空間資訊於影像分類—應用於覆蓋與管理因子（值）之研究。國立中興大學土木工程學系碩士論文。
- 莊雲翰，2002。結合影像區塊及知識庫分類之研究—以 IKONOS 衛星影像為例。國立中央大學土木工程學系碩士論文
- 陳承昌，2006。支持向量機及 Plausible Neural Network 於水稻田辨識之研究，國立交通大學土木工程學系碩士論文。
- 張智星，2005/2。資料分群與樣式辨認，URL:
<http://140.114.76.148/jang/books/dcpr/index.asp>，Roger Jang's Home Page
- 黃國矩，2006。自組映射網路整合群集與識別分析應用於遙測影像分類之研究，國立中華大學土木與工程資訊學系碩士論文。
- 黎璋，1998，紋理分析於遙測影像分類之研究，國立中央大學土木工程學系碩士論文。

- Bezdek, James C., 1981. *Pattern Recognition with Fuzzy Objective Function Algorithms*. Plenum, New York.
- Carleer, A., Debeir, O., and Wolff, E., 2004. Comparison of very high spatial resolution satellite image segmentations, Proceedings of SPIE Image and Signal Processing for Remote Sensing IX, Vol. 5238, ed. Lorenzo Buzzzone, pp. 532-542.
- Huagn, Xin, Zhang, Liangpei, and Li, Pingxiang, 2007. Classification and Extraction of Spatial Features in Urban Areas Using High-Resolution Multispectral Imagery, IEEE Transactions on geoscience and remote sensing, April ,4(2), 2007.
- Kartikeyan, B., Majumder, K L., Dasgupta, A R., 1995. An expert system for land cover classification [J]. IEEE Transactions on geoscience and remote sensing, 1995,33(1): 59~66.
- Kettig, R. L. and Landgrebe, D. A., 1976. Classification of Multispectral Image Data by Extraction and Classification of Homogeneous Objects, IEEE Transactions on geoscience electronics, vol. GE-14, No. 1, pp. 19-26, Jan 1976.
- Kressler, F.P., Kim, Y.S., Steinnocher, K.T., 2003. Object-oriented land cover classification of panchromatic KOMPSAT-1 and SPOT-5 data, Geoscience and Remote Sensing Symposium, 2003 IEEE International 2003/7, 6(6): 3471- 3473.
- Lillesand, T. M. and Kiefer, R. W., 1994. *Remote Sensing and Image Interpretation*, Third Edition, John Wiley & Sons, Inc
- Marceau, D.J., Howarth, J.-M.M. Dubois, and D.J. Gratton, 1990. Evaluation of the grey-level co-occurrence matrix method for land-cover classification using SPOT imagery, IEEE Trans. on Geosci. and Remote Sensing, Vol. 28, No. 4, pp. 513-519
- Oruc, M., Marangoz, A. M., and Buyuksalih, G. 2004. Comparison of pixel-based and object-oriented classification approaches using LANDSAT-7 ETM spectral bands, Proceeding of the ISPRS 2004 Annual Conference, Istanbul, Turkey, July 19-23.

- Pal, Mahesh and Mather, Paul M., 2001. Decision tree based classification of remotely sensed data, ACRS 2001 - 22nd Asian Conference on Remote Sensing, 5-9 November 2001, Singapore. Vol. 1, pp. 245-248.
- Robertson, T. V., 1973. Extraction and classification of objects in multispectral images, Proceedings of the Conference on Machine Processing of Remotely Sensed Data, Purdue University, West Lafayette, pp. 3B-27 to 3B-34. Oct. 1973.
- Wang, Ruye, 1996. pattern classification, Home Page for Professor Ruye Wang, URL: <http://fourier.eng.hmc.edu/e161/lectures/classification/index.html>, Harvey Mudd College, (last date accessed: 22 Nov 2004)
- Wei, Wenxia, Chen, Xiuwan, and Ma, Ainai, 2005. Object-oriented information extraction and application in high-resolution remote sensing image, Proceeding of the IGARSS 2005 Symposium, Seoul, Korea, July 25-29, 2005.



附錄 A 各實驗區不同分類方法之誤差矩陣

(一) 久美實驗區

表 A-1 高斯最大似然法於久美實驗區之分類結果

		分類結果					
檢核資料		農地	林地	建成及裸露地	水體	灘地	PA
	農地	241277	53398	38679	3212	1340	71.40%
	林地	141940	447021	29693	3538	835	71.75%
	建成及裸露地	28134	7853	31998	1425	1869	44.89%
	水體	122	12	3401	6193	2375	51.17%
	灘地	3840	701	17553	7067	48107	62.26%
	UA	58.10%	87.83%	26.37%	28.89%	88.23%	

整體精度 OA = 69.063%

Kappa 值為 0.50573



表 A-2 ECHO 於久美實驗區之分類結果

		分類結果					
檢核資料		農地	林地	建成及裸露地	水體	灘地	PA
	農地	269427	28463	39085	2651	1142	79.06%
	林地	136916	462689	23069	3387	559	73.84%
	建成及裸露地	26856	7426	37130	713	1461	50.46%
	水體	96	13	3071	6442	2481	53.23%
	灘地	3433	918	18571	6653	47737	61.75%
	UA	61.69%	92.63%	30.70%	32.46%	89.43%	

整體精度 OA = 72.844 %

Kappa 值為 0.56772

表 A-3 SVM 於久美實驗區之分類結果

		分類結果					
檢核資料		農地	林地	建成及裸露地	水體	灘地	PA
	農地	209094	93020	33652	2539	2463	61.36%
	林地	87290	524219	10976	2550	1585	83.66%
	建成及裸露地	26984	11694	30350	1403	3155	41.24%
	水體	196	149	2658	5556	3544	45.91%
	灘地	4042	2566	12530	4543	53631	69.37%
	UA	63.82%	82.99%	33.66%	33.49%	83.31%	

整體精度 OA = 72.794%

Kappa 值為 0.54169

表 A-4 BP 於久美實驗區之分類結果

		分類結果					
檢核資料		農地	林地	建成及裸露地	水體	灘地	PA
	農地	219111	82595	34252	1738	3072	64.30%
	林地	103277	508441	10825	2043	2034	81.14%
	建成及裸露地	27965	10810	30452	1328	3031	41.38%
	水體	226	110	1976	4638	5153	38.32%
	灘地	4297	2169	12663	3304	54879	70.98%
	UA	61.74%	84.16%	33.77%	35.54%	80.50%	

整體精度 OA = 72.322%

Kappa 值為 0.53844

表 A-5 Definiens Professional 於久美實驗區之分類結果

		分類結果						
檢核資料		農地	林地	建成及 裸露地	水體	灘地	無法 分類	PA
	農地	262074	55536	15768	1481	5188	721	76.91%
	林地	88257	527389	5064	3699	2066	145	84.16%
	建成及 裸露地	33835	12147	21033	2840	2889	842	28.58%
	水體	313	315	76	5682	5717	0	46.95%
	灘地	4535	4346	1363	4436	62632	0	81.01%
	UA	67.37%	87.94%	48.57%	31.33%	79.79%		

整體精度 OA = 77.744%

Kappa 值為 0.62678



(二) 霧社實驗區

表 A-6 高斯最大似然法於霧社實驗區之分類結果

		分類結果					
檢核資料		農地	林地	建成及裸露地	水體	灘地	PA
	農地	19775	4698	1251	42	1302	73.06%
	林地	74235	728296	484	3235	1032	90.22%
	建成及裸露地	10833	1515	3889	112	1605	21.67%
	水體	17422	1182	328	232970	11134	88.57%
	灘地	4994	73	796	370	5049	44.75%
	UA	15.54%	98.99%	57.63%	98.41%	25.09%	

整體精度 OA=87.871 %

Kappa 值為 0.74732

表 A-7 ECHO 於霧社實驗區之分類結果

		分類結果					
檢核資料		農地	林地	建成及裸露地	水體	灘地	PA
	農地	22173	3301	871	46	677	81.92%
	林地	61851	741067	370	3528	466	91.80%
	建成及裸露地	11727	1288	3833	123	983	21.35%
	水體	17122	1458	314	234266	9876	89.06%
	灘地	7373	63	428	416	3002	26.61%
	UA	18.44%	99.18%	65.90%	98.27%	20.01%	

整體精度 OA=89.146 %

Kappa 值為 0.77034

表 A-8 SVM 於霧社實驗區之分類結果

		分類結果					
檢核資料		農地	林地	建成及裸露地	水體	灘地	PA
	農地	11813	13052	1085	177	941	43.64%
	林地	11432	791453	365	3381	651	98.04%
	建成及裸露地	7417	5552	3130	542	1313	17.43%
	水體	10109	3288	227	247599	1813	94.13%
	灘地	4523	323	438	2347	3651	32.36%
	UA	26.08%	97.27%	59.68%	97.46%	43.63%	

整體精度 OA=93.878%

Kappa 值為 0.8572

表 A-9 BP 於霧社實驗區之分類結果

		分類結果					
檢核資料		農地	林地	建成及裸露地	水體	灘地	PA
	農地	15035	9542	504	182	1805	55.55%
	林地	17400	783430	197	5373	882	97.05%
	建成及裸露地	8007	3843	2794	854	2456	15.56%
	水體	5477	3534	265	251803	1957	95.73%
	灘地	4325	200	352	2006	4399	38.99%
	UA	29.92%	97.86%	67.95%	96.77%	38.26%	

整體精度 OA=93.861%

Kappa 值為 0.8591

表 A-10 Definiens Professional 於霧社實驗區之分類結果

		分類結果						
檢核資料		農地	林地	建成及 裸露地	水體	灘地	無法 分類	PA
	農地	10505	11658	4716	67	63	59	66.17%
	林地	14000	785971	3642	2327	1342	0	94.01%
	建成及裸 露地	4146	4411	8695	24	233	332	50.21%
	水體	3727	8148	2615	247504	1042	0	95.12%
	灘地	2690	291	3051	1805	3445	0	30.54%
	UA	25.12%	97.88%	49.84%	97.78%	61.74%		

整體精度 OA=92.266%

Kappa 值為 0.8289

(三) 瑪谷溪實驗區

表 A-11 高斯最大似然法於瑪谷溪實驗區之分類結果

		分類結果		
檢核資料		無植被地	植被地	PA
	無植被地	119582	35820	76.95%
	植被地	17097	954877	98.24%
	UA	87.49%	96.38%	

整體精度 OA=95.306 %

Kappa 值為 0.79199

表 A-12 ECHO 法於瑪谷溪實驗區之分類結果

		分類結果		
		無植被地	植被地	PA
檢核資料	無植被地	117991	37411	75.93%
	植被地	18846	953128	98.06%
	UA	86.23%	96.22%	0

整體精度 OA=95.31 %

Kappa 值為 0.79215

表 A-13 SVM 法於瑪谷溪實驗區之分類結果

		分類結果		
		無植被地	植被地	PA
檢核資料	無植被地	119591	35811	76.96%
	植被地	17063	954911	98.24%
	UA	87.51%	96.39%	

整體精度 OA=95.01 %

Kappa 值為 0.77896

表 A-14 BP 法於瑪谷溪實驗區之分類結果

		分類結果		
檢核資料		無植被地	植被地	PA
	無植被地	117922	37480	75.88%
	植被地	15682	956292	98.39%
	UA	88.26%	96.23%	

整體精度 OA=95.284 %

Kappa 值為 0.78918

表 A-15 Definiens Professional 法於瑪谷溪實驗區之分類結果

		分類結果			
檢核資料		無植被地	植被地	無法分類	PA
	無植被地	122295	30277	2830	78.70%
	植被地	19470	945995	6509	97.33%
UA		86.27%	96.90%		

整體精度 OA=94.759%

Kappa 值為 0.77799

附錄 B 研究軟體

演算法	軟體名
高斯最大似然法	MultiSpec
ECHO	MultiSpec
倒傳遞神經網路	Matlab
SVM	LIBSVM
主成份分析法	PCI
粗糙集	RSES

