

國立交通大學
土木工程學系
碩士論文

支持向量機及 Plausible Neural Network

於水稻田辨識之研究

Rice Paddy Identification Using

The Support Vector Machine and Plausible Neural Network



研究生：陳承昌

指導教授：史天元

中華民國九十五年六月

**支持向量機及 Plausible Neural Network
於水稻田辨識之研究**
**Rice Paddy Identification Using
The Support Vector Machine and Plausible Neural Network**

研 究 生：陳承昌

Student : Cheng - Chang Chen

指 導 教 授：史天元

Advisor : Dr. Tian - Yuan Shih

國 立 交 通 大 學

土 木 工 程 學 系



A Thesis

Submitted to Department of Civil Engineering

College of Engineering

National Chiao Tung University

In Partial Fulfillment of the Requirements

for the Degree of Master

in

Civil Engineering

June 2006

Hsinchu, Taiwan, Republic of China

中華民國九十五年六月

支持向量機及 Plausible Neural Network

於水稻田辨識之研究

學 生：陳承昌

指導教授：史天元

國立交通大學土木工程學系

摘要

水稻是台灣地區重要作物，其種植面積調查是政府每年的重要工作之一，透過該面積調查可用於預估水稻產量，作為政府糧食政策擬定及災害補助之依據。自 1980 年起，台灣地區水稻面積之調查，主要是由糧食署依「台灣地區稻米生產調查改進要點」進行辦理，該作業是採航空照片並經人工判釋方式得水稻田種植面積，需耗費大量人力與物力。倘若能以衛星影像配合分類理論，建立自動化的辨識系統，將能有效減少成本的投入及人為辨識上的主觀差異。

本研究為以支持向量機及 Plausible Neural Network 進行水稻田辨識之研究，採用 Formosat-2（嘉義實驗區）及 SPOT（新竹實驗區）影像為資料來源，並和高斯最大似然分類法、倒傳遞類神經網路、學習向量量化類神經網路、輻狀基底函數類神經網路及粗糙集方法所得之分類成果進行比較。Plausible Neural Network 並採用兩種版本進行分類實驗，V 1.3 為一般化的版本；V 1.0 則加入考量樣本屬性間及鄰近樣本間之資訊。支持向量機會因選用核函數的不同，而對分類成果造成差異，故兩實驗區皆進行支持向量機於不同核函數及各分類理論之辨識作業。研究中，並以嘉義實驗區資料，探討支持向量機與高斯最大似然分類法於不同群聚類別數及訓練樣本集合之穩定性及四種紋理影像生成方式輔助支持向量機分類所得之成果差異。

實驗所得成果以誤差矩陣作展示並進行精度評估。研究成果顯示，在兩個實驗區中，皆以 Plausible Neural Network V1.0 所獲得的分類成果為最佳，在嘉義實

驗區之整體精度達 94%以上；而在新竹實驗區之整體精度達 91%以上。支持向量機之分類成果，在嘉義實驗區僅次於 Plausible Neural Network V1.0；而在新竹實驗區則次於 Plausible Neural Network V1.0 及學習向量量化類神經網路。支持向量機於不同核函數分類實驗，以輻狀基底函數及多項式較線性及兩層式類神經網路適用於本研究，於嘉義實驗區以多項式之成果為最佳；而在新竹實驗區則以輻狀基底函數之成果為最佳。於不同群聚類別數及訓練樣本集合之分類實驗，以支持向量機的穩定性較高斯最大似然分類法為佳，其整體精度變動皆相對較高斯最大似然分類法為小，約在 1%以內；而高斯最大似然分類法之整體精度變動，最大可達 10%以上。紋理影像輔助支持向量機分類實驗，由成果顯示，紋理影像的加入對分類精度提升的成效有限，整體精度最高提升約 0.3%，某些紋理影像的加入，甚至降低原有的分類精度，故紋理特徵的選取及使用必須加以考量。



Rice Paddy Identification Using The Support Vector Machine and Plausible Neural Network

Student : Cheng-Chang Chen Advisor : Dr. Tian-Yuan Shih

Department of Civil Engineering

National Chiao Tung University

Abstract

Rice is the most important crop in Taiwan. Its field planting inventory is a routine government operation. The inventory is used to support decisions and policies related to crop yield estimation, hazard mitigation, and other relevant areas. Starting in 1980, the government has been utilizing aerial photo interpretation as the primary inventory method. This procedure is based on manual interpretation. If an automated classification system can be implemented, both the time and cost required for the inventory can be reduced. The errors caused by subjective interpretation of data by humans can also be avoided.

This study investigates the application of the Support Vector Machine (SVM) and Plausible Neural Network (PNN) for image classification. The images used for the experiment include multi-temporal Formosat-2 images of the Chiayi area and multi-temporal SPOT images of the Hsinchu area. Other classification schemes are used for comparison: Gaussian Maximum Likelihood Classification, error Back-Propagation (BP) neural network, Learning Vector Quantization (LVQ) neural network, Radial Basis Function (RBF) neural network, and Rough Set theory. Two implementations of PNN are adopted. V1.3 is the general version, while V 1.0 takes both spatial and attribute relations into account. On the other hand, there are a number

of kernel functions to be selected with SVM. The stability of SVM and Maximum Likelihood Classification, with respect to the contribution of texture images and the number of clusters and training samples, in the Chiayi dataset are also evaluated.

PNN V1.0 performs the best for both datasets. The Overall Accuracy is higher than 94% for Chiayi and 91% for Hsinchu. SVM performs second-best for Chiayi and third-best for Hsinchu. Among different Kernel functions, RBF and polynomials are shown to be better than linear and two-layer neural networks. The Polynomial Kernel Function is the best for Chiayi and RBF is the best for Hsinchu. SVM has higher stability than Maximum Likelihood Classification with respect to the number of clusters and training samples. The contribution of texture images for classification is not significant. Instead, the influence of some texture images is found to be negative.



誌謝

本論文承蒙吾師史天元教授兩年來在研究領域上的悉心指導，使論文得以順利完成，在此謹向恩師致上最誠摯的謝意。同時感謝組上陳春盛教授、黃金維教授、李振燾教授與郭金運教授在相關課業的啟發與教誨。此外，感謝口試委員陳繼藩教授、曾義星教授及蔡榮得教授不吝提供寶貴的意見，使得本論文更臻完美。

感謝劉進金學長、劉榮寬學長及徐偉城學長在研究上所給予的協助和意見，並感謝蕭國鑫學長提供相關研究經驗，使得研究工作得以順利完成。感謝陳垣洋博士提供 PNN 軟體及對 PNN 相關問題的解惑。同研究室的紹禎及心瑜，感謝你們這兩年來的陪伴和照顧，有了你們的勉勵和打氣，才能順利完成這兩年的學業。

另外並感謝同窗同學子榜、家桂、元俊及建評一起在課業的相互幫助及鼓勵；也感謝學弟妹給我的鼓勵，並陪我一起運動消滅壓力。另外感謝在我人生歷程中，給我鼓勵和支持的老師、學長、同學及朋友們，感謝你們在我困頓無助的時候，給我適時的援助。

最後，感謝栽培養育我的父母，若無您們的奉獻，就無今天的我，同時也感謝一些長輩所給予我的鼓勵和教導。另外，得感謝依婷，妳是我的出氣筒，真的很抱歉，在此感謝妳的包容及支持。

目錄

中文摘要	I
英文摘要	III
誌謝	V
目錄	VI
圖目錄	VIII
表目錄	X
第一章 前言	1
1-1 研究動機與目的	1
1-2 文獻回顧	1
1-3 研究方法	3
1-4 論文架構	4
第二章 分類理論基礎	6
2-1 水稻生長概述	6
2-2 水稻植生變化	6
2-2-1 土地覆蓋變化	6
2-2-2 光譜變化	8
2-3 紋理特徵	9
2-4 分類精度評估	11
第三章 影像分類理論	15
3-1 ISODATA分類法	16
3-2 高斯最大似然分類法	17
3-3 類神經網路	18
3-3-1 倒傳遞類神經網路	19
3-3-2 學習向量量化類神經網路	20
3-3-3 輻狀基底函數類神經網路	22
3-4 粗糙集方法	23
3-5 支持向量機	27
3-5-1 支持向量機分類基本理論	27
3-5-2 多類支持向量機分類法	29
3-6 PLAUSIBLE NEURAL NETWORK	31
3-6-1 PNN之學習演算法	33

第四章 影像資料與分類實驗流程	34
4-1 實驗區及遙測影像	34
4-1-1 嘉義地區	34
4-1-2 新竹地區	36
4-2 訓練樣本選取	39
4-2-1 嘉義實驗區	39
4-2-2 新竹實驗區	42
4-3 分類實驗流程	43
4-3-1 嘉義實驗區	43
4-3-2 新竹實驗區	49
第五章 實驗成果與探討	50
5-1 嘉義實驗區	50
5-1-1 高斯最大似然分類法及支持向量機之穩定性分類成果	50
5-1-2 支持向量機於不同核函數之分類成果	52
5-1-3 各分類理論之分類成果	53
5-1-4 紋理影像輔助支持向量機分類之分類成果	54
5-1-5 成果分析與探討	59
5-2 新竹實驗區	67
5-2-1 支持向量機於不同核函數之分類成果	67
5-2-2 各分類理論之分類成果	68
5-2-3 成果分析與探討	70
第六章 結論與建議	72
參考文獻	75
附錄A 嘉義實驗區各分類成果之誤差矩陣	80
附錄B 新竹實驗區各分類成果之誤差矩陣	103
作者簡歷	109

圖 目 錄

圖 2-1 水稻生育期別及生長日期概略圖	7
圖 2-2 不同地表物之標準光譜反射率曲線	9
圖 2-3 原始影像A	10
圖 2-4 共生矩陣B.....	10
圖 3-1 高斯最大似然分類法處理流程	18
圖 3-2 倒傳遞類神經網路基本架構	19
圖 3-3 選用二層隱藏層之示意圖	20
圖 3-4 學習向量量化類神經網路基本架構	21
圖 3-5 輻狀基底函數類神經網路基本架構	22
圖 3-6 線性可分	29
圖 3-7 線性不可分	29
圖 3-8 支持向量機之產生方式	30
圖 3-9 投票策略說明	30
圖 3-10 DAG METHOD 處理 5 種類別時之二元且無循環的有向圖	31
圖 3-11 PNN之網路架構圖	31
圖 3-12 PNN之學習演算法流程圖	33
圖 4-1 嘉義實驗區之五個時段FORMOSAT-2 影像	36
圖 4-2 嘉義實驗區之檢核影像	36
圖 4-3 新竹實驗區之五個時段SPOT影像	38
圖 4-4 新竹實驗區之檢核影像	39
圖 4-5 嘉義實驗區之訓練樣本選取流程	41
圖 4-6 訓練樣本選取示意圖	42
圖 4-7 新竹實驗區之訓練樣本選取流程	43
圖 4-8 高斯最大似然分類法及支持向量機之穩定性探討分類流程	45
圖 4-9 支持向量機於不同核函數之分類流程	45
圖 4-10 各分類理論之分類流程	46

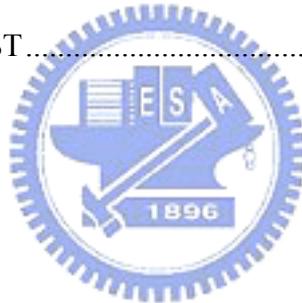
圖 4-11 應用紋理影像輔助支持向量機分類之分類流程	46
圖 4-12 8 月 7 日紅光波段之八種紋理影像	47
圖 4-13 10 月 12 日近紅外光波段之八種紋理影像	47
圖 4-14 以PCA法取前八主軸-全部波段之八種紋理影像	48
圖 4-15 以PCA法取前八主軸-全部波段之五種紋理影像	48
圖 5-1 各分類理論之分類成果影像	55
圖 5-2 整體精度比較	60
圖 5-3 KAPPA指標比較	60
圖 5-4 各分類理論之分類成果影像	69



表目錄

表 2-1 水稻在不同生長時期之土地覆蓋類型	8
表 2-2 誤差矩陣	12
表 3-1 資訊系統	23
表 3-2 縮減後的資訊系統	25
表 3-3 資訊系統二	26
表 4-1 嘉義地區之攝像日期與水稻生育進度對應表	35
表 4-2 FORMOSAT-2 各幅改正影像之線性轉換方程式	35
表 4-3 新竹地區攝像日期與水稻生育進度對應表	37
表 4-4 SPOT各幅改正影像之線性轉換方程式	38
表 4-5 三種訓練樣本集合說明	42
表 4-6 三種群聚類別於三種訓練樣本集合之最小分離度	42
表 4-7 訓練樣本集合說明	43
表 4-8 八種紋理統計量之各主軸資訊量	49
表 4-9 五種紋理統計量之各主軸資訊量	49
表 5-1 2 個群聚類別之分類成果	51
表 5-2 23 個群聚類別之分類成果	52
表 5-3 38 個群聚類別之分類成果	52
表 5-4 輻狀基底函數、線性及兩層式類神經網路為核函數之分類成果	53
表 5-5 1 至 5 階多項式為核函數之分類成果	53
表 5-6 三種類神經網路之網路架構	54
表 5-7 各分類理論之分類成果	54
表 5-8 8 月 7 日紅光波段之八種紋理影像分類成果	56
表 5-9 10 月 12 日近紅光波段之八種紋理影像分類成果	57
表 5-10 全部波段之八種紋理影像並以PCA法取前八主軸之分類成果	58
表 5-11 全部波段之五種紋理影像並以PCA法取前八主軸之分類成果	59
表 5-12 不同群聚類別數於相同分類方法及訓練樣本集合之Z-TEST	61

表 5-13 支持向量機於不同核函數之Z-TEST	62
表 5-14 各分類理論之Z-TEST	63
表 5-15 8月7日紅光波段之各紋理影像間之Z-TEST	65
表 5-16 10月12日近紅外光波段之各紋理影像間之Z-TEST	65
表 5-17 全部波段之八種紋理影像並以PCA法取前八主軸-紋理影像間之Z-TEST	66
表 5-18 全部波段之五種紋理影像並以PCA法取前八主軸-各紋理影像之Z-TEST	66
表 5-19 輻狀基底函數、線性及兩層式類神經網路為核函數之分類成果	67
表 5-20 1至6階多項式為核函數之分類成果	67
表 5-21 三種類神經網路之網路架構	68
表 5-22 各分類理論之分類成果	68
表 5-23 支持向量機於不同核函數之Z-TEST	70
表 5-24 各分類理論之Z-TEST	71



第一章 前言

1-1 研究動機與目的

水稻是台灣地區的重要作物，其種植面積及產量之預估除可提供政府擬定糧食政策之參考，並可作為農民受災後補助之依據。因此稻作之統計作業方式自1980 年起，即由台灣省糧食處（行政組織改隸為農委會農糧署）依行政院核定「台灣地區稻米生產調查改進要點」，逐年分區施行航照稻作面積調查。農糧署依各地區稻作生產資料，規劃出最佳判釋水稻的航照拍攝日期，並委託林務局農林航空測量所拍攝航照，以人工判釋方式製作 50 公尺地面解析度資料，據此計算水稻種植面積及估算產量。航照辨識水稻田雖可得到較佳的判釋精度，但目前國內大部份地區一年可有兩期稻作，拍攝面積約為 180 萬公頃，每期稻作約需 5000 張航空照片，判釋工作每年約需 30 人力，為一種需大量人力、物力及時間投入的作業方式（工研院，2005）。

隨著遙測技術的提升與分類理論的精進，應用衛星影像進行土地覆蓋分類作業技術已越趨成熟，而以此型式進行水稻田辨識作業，國內已有多項研究，如鄧敏松（1997）、陳益鳳（1998）、蕭國鑫（1998）及邵泰璋（1999）等。因此若能以適當的衛星影像配合適當的分類理論，以此建立自動化的辨識系統，將能有效減少成本的支出及人為辨識上的主觀差異。本研究即以近年來在分類理論上較受矚目的支持向量機（Vapnik, 1995）及新提出的 Plausible Neural Network (Chen, 2002) 作為主要的水稻田辨識方法，並和高斯最大似然分類法、倒傳遞類神經網路、學習向量量化類神經網路、輻狀基底函數類神經網路及粗糙集方法作比較。

1-2 文獻回顧

藉由遙測影像及分類理論判釋土地覆蓋或土地利用，至今在國內外仍是一重要的研究方向，亦有諸多參考文獻可供參考。且隨著衛星影像解析度的提升及分

類理論的創新，將有助於提升分類成果的準確性。

水稻田辨識之研究，國內已有諸多成果。鄧敏松（1997）應用多時段 SPOT 衛星影像及耕地坵塊圖，結合水稻生長、時間與空間等領域知識，作為判釋水稻田區塊之依據，並針對不同期別的影像進行差分以凸顯水稻和非水稻之差異，並以萃取出的相關知識建立自動化辨識系統。陳益鳳（1998）採用多時段 SPOT 衛星影像及耕地坵塊圖，以標準化互相關方法（Normalized Cross Correlation, NCC）計算耕地坵塊與標準水稻時間剖面曲線的相關性，以判別是否為水稻田坵塊，並採波峰偵測法（Peak Detecting）比較各坵塊時間剖面曲線波峰與標準水稻時間剖面曲線波峰之特徵，並依約制條件進行辨識作業。

蕭國鑫（1998）以 SPOT 多時段影像、雷達回波強度資料及耕地坵塊圖，分別採逐像元及區塊式分類法辨識水稻田，以探討何種生長期的攝像組合，可求得最佳分類成果。邵泰璋（1999）使用 SPOT 多時段影像，採倒傳遞及學習向量量化類神經網路進行水稻田之辨識作業，文中並增加紋理特徵輔助水稻田辨識。

許晉嘉等（2005）採 Quick Bird 衛星影像，以高斯最大似然分類法及支持向量機進行水稻田辨識之研究，文中並加入方向半變異元（Semivariogram）及主成分分析法之紋理影像輔助辨識作業，其中支持向量機的各分類成果皆較高斯最大似然分類法為佳。施亦良等（2005）應用 Quick Bird 衛星影像，以高斯最大似然分類法及粗糙集方法進行水稻田之辨識作業，其中以粗糙集方法所得之成果為較佳。

分類理論的創新與精進將有助於遙測影像分類時之精度提升，遙測影像所採的分類理論最初是以統計分析方法為主，如高斯最大似然分類法及判別分析方法等。而隨電腦科技的進步及類神經網路理論的復甦，使類神經網路應用於影像分類之研究於現今已非常普遍且有諸多成果。如 Bishof et al. (1992) 以三層式倒傳遞類神經網路進行 Landsat 影像分類之研究，文中並增加紋理影像輔助分類，

其所得的分類成果相較高斯最大似然分類法為佳。

近年來，較受關注的分類理論為支持向量機，該理論應用於光譜影像分類之研究也日益廣泛。Zhu & Blumberg (2002) 分別以多項式及輻狀基底函數為核心的支持向量機，應用於 15 及 30 公尺解析力的 ASTER 影像分類之研究，在 15 公尺影像解析力以 5 階多項式之分類成果較佳；30 公尺影像解析力則以輻狀基底函數之分類成果較佳。

Foody & Mathur (2004) 分別使用判別分析、決策樹、前饋式類神經網路及支持向量機於 ATM 影像分類之研究，其中以支持向量機所得之分類精度為最佳。Melgani & Bruzzone (2004) 分別以 KNN (K-nearest neighbors)、輻狀基底函數類神經網路、支持向量機（分別採線性、多項式及輻狀基底函數之三種核函數）於 AVIRIS 影像分類之研究，其中以輻狀基底函數為核函數之支持向量機所得之分類精度為最佳。

Camps-Valls & Bruzzone (2005) 分別以線性判別分析、正規化輻狀基底函數類神經網路、輻狀基底函數與多項式為核函數之支持向量機、輻狀基底函數之線性判別分析 (Kernel Fisher Discriminant, KFD) 及 Regularized Adaboost 於 AVIRIS 影像分類之研究，其中以多項式為核心的支持向量機所獲得的分類成果為最佳，輻狀基底函數之分類成果次之。黃明哲與李良輝 (2005) 使用 LiDAR 及同步拍攝的光學影像資料，以最小距離分類法、最大似然分類法及支持向量機進行地物分類之研究，其中以支持向量機所獲得的成果為最佳。

1-3 研究方法

本研究以支持向量機及 Plausible Neural Network 於水稻田辨識之研究，並與高斯最大似然分類法、倒傳遞類神經網路、學習向量量化類神經網路、輻狀基底函數類神經網路及粗糙集方法作成果比對，以驗證支持向量機及 Plausible Neural Network 在水稻田辨識上是否優於其它的分類方法。支持向量機若採不同核函

數，其分類所得成果也將有所差異，故於本研究中也將探討不同核函數對支持向量機分類之影響。

在遙測影像方面，分為兩組實驗區，且每組實驗區包含五幅不同時段影像，第一組實驗區為 93 年嘉義地區二期稻作，採用 Level 3 Formosat-2 影像；第二組實驗區為 89 年新竹地區一期稻作，採用 Level 10 SPOT 影像。檢核資料則以農糧署所提供之相同年份和相同稻作期的 1/5000 耕地地籍圖為比對依據。研究中，並以嘉義實驗區資料，探討高斯最大似然分類法及支持向量機於不同群聚類別數及訓練樣本集合之穩定性；並以該區多時段影像生成紋理影像輔助支持向量機分類，以探討紋理特徵的加入是否能有效提升支持向量機的分類精度。

各分類實驗所得之分類成果，以誤差矩陣作展示，並以誤差矩陣元素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，並以 Z-Test 方法檢定各分類方法所得之分類成果是否具有顯著性。透過上述精度評估方式，可作為探討各分類方法優劣之依據。

1-4 論文架構

本論文為採用多時段衛星影像並以支持向量機與 Plausible Neural Network 進行水稻田辨識作業，目的是評估及探討上述兩種分類理論於水稻田辨識所得之成果，是否優於研究中所採用的其它分類理論。論文架構共分為六章，說明如下：

第一章「前言」：說明研究動機與目的，並回顧國內外相關研究及敘述本論文之研究方法。

第二章「分類理論基礎」：對水稻生長作概述，並對影像紋理及精度評估方式作說明。

第三章「影像分類理論」：介紹本研究所採用的分類理論，包括 ISODATA 分類法、高斯最大似然分類法、類神經網路分類法（含倒傳遞類神經網路、學習向量量化類神經網路及輻狀基底函數類神經網路）、支持

向量機、粗糙集方法及 Plausible Neural Network。

第四章「影像資料與分類實驗流程」：介紹兩組實驗區所採用的影像及其
資料前處理，並對兩組實驗區的分類實驗流程作說明。

第五章「實驗成果與探討」：各分類成果以誤差矩陣作展示並計算各分類
成果之精度評估指標。

第六章「結論與建議」：研究成果總結與建議事項。



第二章 分類理論基礎

2-1 水稻生長概述

台灣地區水稻生長情形隨季節、緯度及生長環境不同而具有差異，依農糧署（2000）「台灣地區稻米生產量調查報告」資料，台灣地區依氣候條件每年可有兩期的水稻種植。第一期稻作約在冬末春初插秧，夏季之6到7月時收穫；二期稻作在一期稻作收割後約15-20天開始整田、插秧，秋末冬初之11到12月時收穫。一期稻作因在插秧期的溫度較低，發芽生長較緩，生長週期天數約需110-140天；二期稻作因陽光日照充足，插秧至收割僅需100-110天左右（工研院，2001）。

水稻生長階段則依農復會等（1977）針對稻作生長所作的研究，將其概略分為四個時期，包括（1）秧苗期；（2）營養生長期；（3）生殖生長期；（4）成熟期。上述四個時期並可再細分為九個期別，即（1）成活期；（2）生长期；（3）有效分蘖期；（4）最高分蘖期；（5）幼穗形成期；（6）孕穗期；（7）抽穗期；（8）乳熟期；（9）黃熟期。圖2-1為水稻生育期別及生長日期概略圖。

2-2 水稻植生變化

水稻於不同生長階段其土地覆蓋類型將隨之改變，而土地覆蓋類型的變化將反應於遙測影像上的光譜變化。藉由蕭國鑫（1998）研究得知，結合水稻不同生長階段的遙測影像，將有助於水稻田的辨識作業。

2-2-1 土地覆蓋變化

水稻於稻作期間內，經整地育苗、插秧、生長、分蘖及收割等過程，其土地覆蓋類型會有所改變，表2-1為水稻在不同生長時期之土地覆蓋類型。在整地育苗期，水稻田引水灌溉使土壤風化並進行犁耕整地作業，此時土地覆蓋以水體或含豐富水份的土壤為主；插秧至有效分蘖期，土地覆蓋類型呈水體與植被混合，

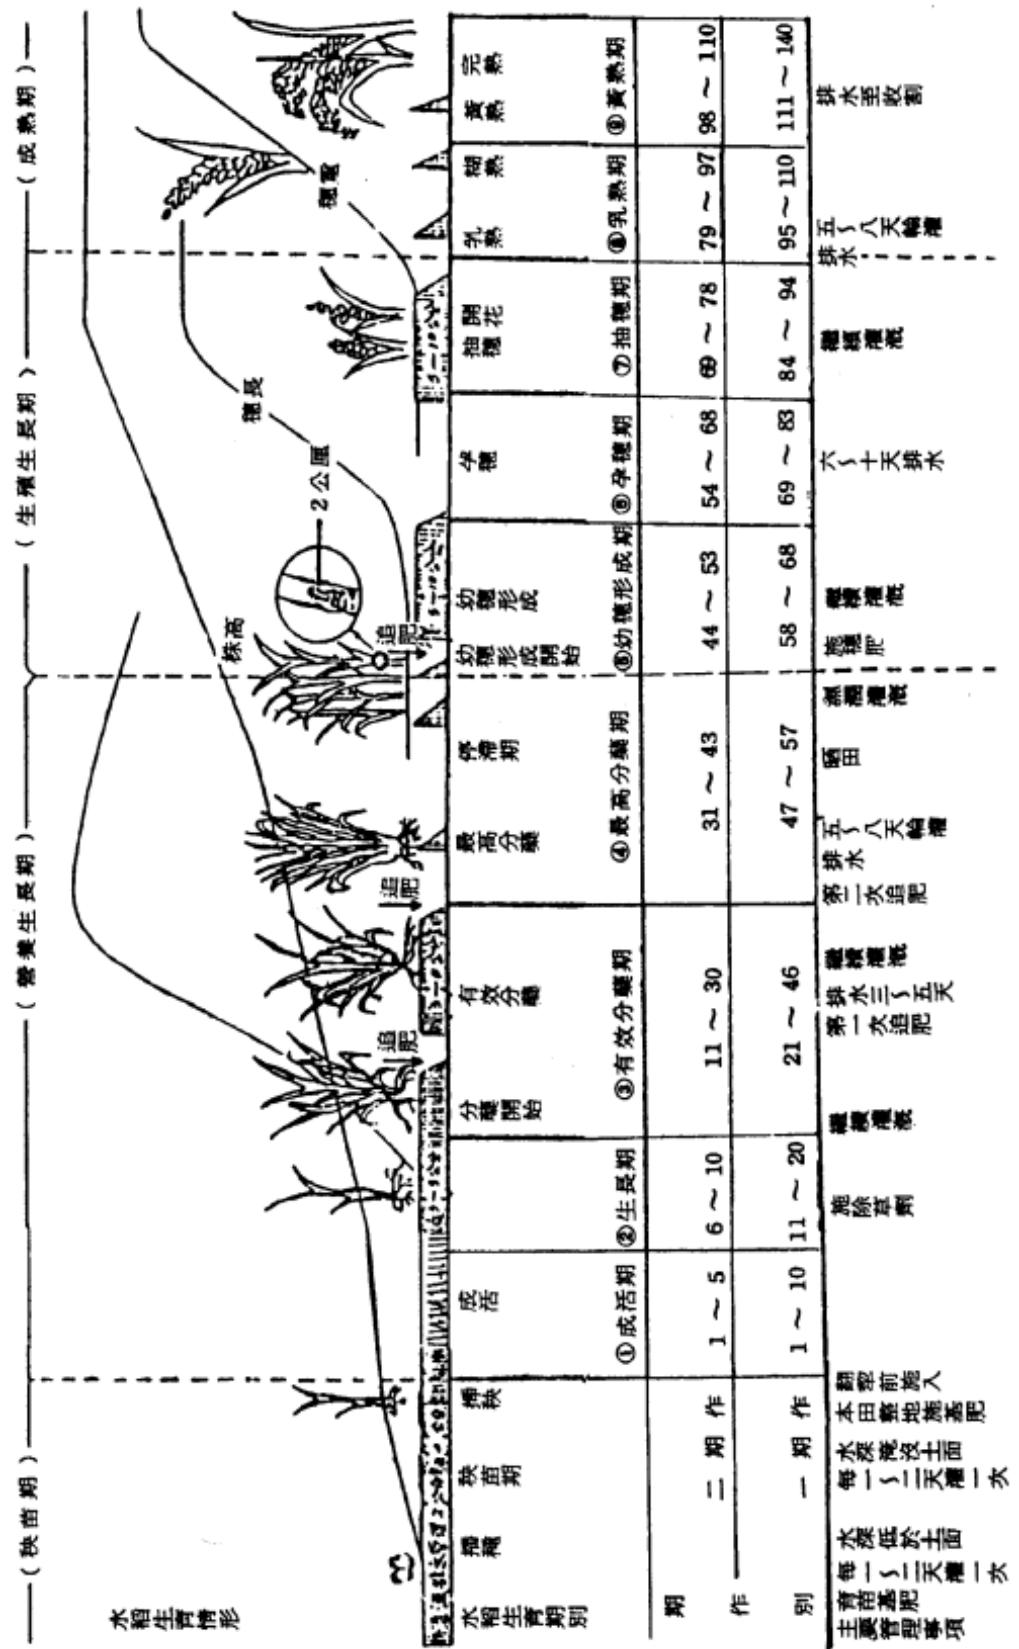


圖 2-1 水稻生育期別及生長日期概略圖(農復會等, 1977)

並隨水稻生長，植被會越茂密而水體則相對減少；水稻從最高分蘖期到結穗成熟採收前，土地覆蓋類型呈完全植被；收穫期，當水稻收割完成後，土地覆蓋類型則呈乾燥裸露土壤（陳益鳳，1998）。

表 2-1 水稻在不同生長時期之土地覆蓋類型

生長時期	土地覆蓋類型
整地育苗期	水體
插秧期-有效分蘖期	水體 + 植被
最高分蘖期-黃熟期	植被
收穫期	乾燥裸露土壤

2-2-2 光譜變化

遙測感測器接收到的光譜反射率會因不同地表物而有所不同，而同一植被在不同季節其光譜反射率也會有所差異，遙測影像分類即是利用地表物光譜反射率的差異進行土地覆蓋之辨識。



圖 2-2 為乾燥裸露土壤、綠色植物及水體三種地表物之標準光譜反射率曲線，縱軸為反射率而橫軸為波長（單位為 μm ）。由圖 2-2 可見，三種地表物在不同波長時的反射率，於近紅外光波段，水體的反射率幾近為零而綠色植物卻有相對其它兩者為強的反射率。倘若遙測感測器具由極高的光譜解析度，則可將波長範圍切割成密集的波段，並依據各波段的反射率，作為土地覆蓋分類作業時所需的有效資訊。

本研究所採用的衛星影像為 Formosat-2 及 SPOT 兩種。Formosat-2 衛星影像為包含四個波段之多光譜影像，各波段的波長範圍分別為：藍光波段（0.45~0.52 μm ）、綠光波段（0.52~0.60 μm ）、紅光波段（0.63~0.69 μm ）和近紅外光波段（0.76~0.90 μm ），光譜解析度約為 $0.1 \mu\text{m}$ ；SPOT 衛星影像則為包含三個波段之多光譜影像，各波段的波長範圍分別為：綠光波段（0.50~0.59 μm ）、紅光波段（0.60~0.68 μm ）和近紅外光波段（0.79~0.89 μm ），光譜解析度約為 $0.1 \mu\text{m}$ 。與圖 2-2 相較，兩衛星影像各波段所包含的波長範圍，僅是圖中左

方一小段波長範圍，若僅想以單一影像細分出各項土地覆蓋類型則具有其困難性。

如 2-2-1 節所述，水稻田土地覆蓋類型會隨不同生長階段而有所變化，包含水體、水體與植被混合、單純植被及裸露土壤，而其土地覆蓋類型的不同將使得遙測影像上的光譜資訊也將不同。本研究即是採用多時段影像，利用水稻在不同生長時期，其光譜反射率會隨之變化的特性，進行水稻田的辨識作業。

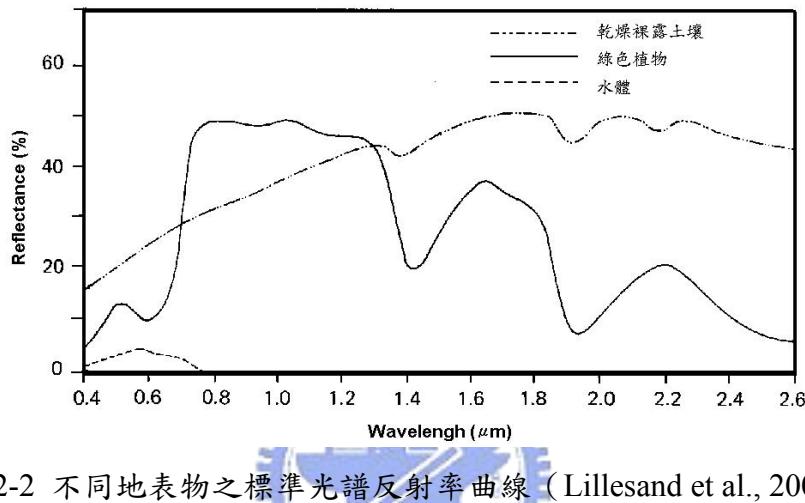


圖 2-2 不同地表物之標準光譜反射率曲線 (Lillesand et al., 2004)

2-3 紋理特徵

遙測影像經由紋理分析可提供影像分類作業時額外的輔助資訊，且具有有益的輔助資訊將能提升分類成果的準確性。紋理分析方法則可分為結構型、統計型與頻譜型，以下將對三種紋理分析方法作說明 (Haralik et al., 1973; Gonzalez & Woods, 2002)：

1. 統計方法 (Statistical Approaches)：藉由像元灰度值及像元間的相對位置關係，得出平滑、粗糙、均勻性及熵等紋理特徵。
2. 結構方法 (Structural Approaches)：藉由影像基本單元 (Primitives) 的排列對紋理特徵作描述。
3. 頻譜方法 (Spectral Approaches)：以傅利葉頻譜性質為基礎，指認出

頻譜中的高能量及窄峰，用於檢測影像整體的週期性。

本研究的紋理分析採用統計方法，並以 Haralik et al. (1973) 的 Gray Level Co-Occurrence Matrix (GLCM) 為依據；該方式為由原始影像得出共生矩陣，再以共生矩陣經各種紋理統計量生成紋理影像。

共生矩陣為一方形矩陣，若為 8 位元編碼的影像，則其共生矩陣為 256×256 大小之方陣。如圖 2-3，若影像 A 僅由 3 個灰度值所構成，以 $\delta=(1, 1)$ 為取樣方向，則其共生矩陣 B，如圖 2-4。以灰度值 $(0, 0)$ 為例，該灰度值的組合有 (A_{12}, A_{23}) 、 (A_{23}, A_{34}) 、 (A_{34}, A_{45}) 及 (A_{45}, A_{54}) 四組，故共生矩陣 B 之 B_{11} 為 4。

0	0	0	1	2
1	1	0	1	1
2	2	1	0	0
1	1	0	2	0
0	0	1	0	1

圖 2-3 原始影像 A

0	1	2
4	2	1
2	3	2
0	2	0

圖 2-4 共生矩陣 B

Haralik et al. (1973) 在其研究中共列舉出十四種紋理統計量，因其中某些紋理統計量具有高相關性，故 Schowengerdt (1997) 列出七種常用的紋理統計量用於取得紋理影像，說明如下：

1. 二階角動量 (Angular Second Moment, ASM)：度量影像紋理的一致性，即

$$\sum_i \sum_j P_{ij}^2 \quad (2-1)$$

2. 對比 (Contrast)：度量影像的對比強烈程度，即

$$\sum_i \sum_j (i - j)^2 P_{ij} \quad (2-2)$$

3. 相關 (Correlation)：度量影像的相關性，即

$$\frac{\sum_i \sum_j ij P_{ij} - \mu_1 \mu_2}{\sigma_1 \sigma_2} \quad (2-3)$$

4. 變方和 (Sum of Squares)：計算取樣視窗中灰階之變方和，即

$$\sum_i \sum_j (i - \mu)^2 P_{ij} \quad (2-4)$$

5. 反差動量 (Inverse Different Moment)：度量影像的均調性，又稱作 Homogeneity，即

$$\sum_i \sum_j \frac{P_{ij}}{1 + (i - j)^2} \quad (2-5)$$

6. 平均和 (Sum Average)：計算取樣視窗之灰階平均值，即

$$\sum_{i=2}^{2^Q+1} iP_{x+y} \quad , \quad P_x = \sum_j P_{ij} \quad , \quad P_y = \sum_i P_{ij} \quad , \quad Q = \text{number of bits/pixel} \quad (2-6)$$

7. 熵 (Entropy)：度量影像紋理的雜亂程度，其意義與二階角動量相反，即

$$-\sum_i \sum_j P_{ij} \log(p_{ij}) \quad (2-7)$$

紋理影像的生成與取樣間距、取樣方向及取樣視窗大小等參數相關。在遙測影像之紋理分析過程，若每張遙測影像具有三個波段，每波段以五種紋理統計量生成紋理影像，則將產生 15 種紋理影像，若採多時段影像，則產生的紋理影像將會倍增。故黎瑋（1998）將得到的紋理影像進行主成分分析法（Principle Component Analysis，PCA），將重要的資訊集中於前幾個主軸中使用。

2-4 分類精度評估

遙測影像經分類方法完成分類後，必須對分類成果進行精度分析，方能評估分類方法之優劣。遙測影像分類作業常採用誤差距陣 (Error Matrix) 展示分類成果與檢核資料間的對應關係 (Lillesand et al., 2004)。

誤差矩陣為一方陣，如表 2-2，行及列數應等於類別數，對角線元素 N_{ii} 為每個類別被正確分類的數目，非對角線元素 N_{ij} ($i \neq j$) 為分類錯誤之元素，而分類錯誤之型態可分為誤授 (Commission Error) 及漏授 (Omission Error) 兩種。

以表 2-2 為例，對漏授及誤授作說明。類別 1 在第一列， N_{11} 為正確分類之像元數， N_{12} 、 N_{13} 及 N_{14} 之各像元數則為將原屬類別 1 之像元判釋為屬類別 2、類別 3 及類別 4，此情形即為漏授；而類別 1 在第一行， N_{11} 仍為正確分類之像元數， N_{21} 、 N_{31} 及 N_{41} 之各像元數則為將不屬類別 1 之像元判釋為屬類別 1，例如將屬類別 2 之像元判釋為屬類別 1 (N_{21})，此情形即為誤授。

表 2-2 誤差矩陣

		分類成果				生產者精度	
檢核資料		類別 1	類別 2	類別 3	類別 4		
	類別 1	N_{11}	N_{12}	N_{13}	N_{14}	N_{1+}	PA_1
	類別 2	N_{21}	N_{22}	N_{23}	N_{24}	N_{2+}	PA_2
	類別 3	N_{31}	N_{32}	N_{33}	N_{34}	N_{3+}	PA_3
	類別 4	N_{41}	N_{42}	N_{43}	N_{44}	N_{4+}	PA_4
	合計	N_{+1}	N_{+2}	N_{+3}	N_{+4}	N	
	使用者精度	UA_1	UA_2	UA_3	UA_4		

透過誤差矩陣之元素將可計算出數種精度評估指標，作為評斷分類成果優劣之依據。本研究所採用精度評估指標分別為單一類別之生產者精度 (Producer's Accuracy, PA) 及使用者精度 (User's Accuracy, UA) 、全體精度 (Overall Accuracy, OA) 、Kappa 指標 (\hat{K} , k) 及 Z-Test。精度評估指標分述如下，並先對各符號作定義：

N_{ii} ：表示在誤差矩陣中位於第 i 列第 i 行的元素。

N_{i+} ：表示第 i 列所有元素之總和。

N_{+i} ：表示第 i 行所有元素之總和。

N ：表示誤差矩陣所有元素之總和。

M ：表示類別數。

1. 生產者精度 (PA)：為某已知類別被正確分類的百分比，即

$$\frac{N_{ii}}{N_{i+}} \times 100\% \quad (2-8)$$

生產者精度的意義同樣可由漏授 (OE) 來表示，漏授為某已知類別被分類錯誤的百分比，與生產者精度之關係為：

$$OE = 1 - PA \quad (2-9)$$

2. 使用者精度 (UA)：為分類後之某類別正確對應土地覆蓋之百分比，即

$$\frac{N_{ii}}{N_{+i}} \times 100\% \quad (2-10)$$

使用者精度的意義同樣可由誤授 (CE) 來表示，誤授為分類後之某類別被分類錯誤之百分比，對應使用者精度之關係為：

$$CE = 1 - UA \quad (2-11)$$

3. 全體精度 (OA)：為誤差矩陣中全部類別正確分類的百分比，即

$$\left(\frac{1}{N} \sum_{i=1}^M N_{ii} \right) \times 100\% \quad (2-12)$$

4. Kappa 指標 (\hat{k})：為表示分類成果與檢核資料相似程度的一個指標，同時考慮漏授與誤授之影響，即

$$\hat{k} = \frac{OA - CA}{1 - CA} = \left[\frac{N \sum_{i=1}^M N_{ii} - \sum_{i=1}^M (N_{i+} N_{+i})}{N^2 - \sum_{i=1}^M (N_{i+} N_{+i})} \right] \times 100\% \quad (2-13)$$

其中

$$OA = \frac{1}{N} \sum_{i=1}^M N_{ii}$$

$$CA = \frac{1}{N^2} \sum_{i=1}^M N_{i+} \cdot N_{+i}$$

5. Z-Test：檢驗不同分類方法間 kappa 指標之顯著性。Z-Test 之公式即

$$Z = \frac{C_1 - C_2}{\sqrt{\sigma_1^2 + \sigma_2^2}} \quad (2-14)$$

C_1 、 C_2 :不同分類方法間之 kappa 指標

σ_1^2 、 σ_2^2 :不同分類方法間之 kappa 指標標準差

以 95% 信心水準為基準，若該 Z 值小於 1.96 代表兩分類方法之分類成果

不具有顯著性；若 Z 值大於 1.96，則代表兩分類方法之分類成果具有顯著性，即分類成果各具有其代表意義。



第三章 影像分類理論

遙測影像分類最初是以統計分析方法為主，如高斯最大似然分類法及判別分析方法等，而這些統計分析方法在早期都可獲得不錯的分類成果。但隨著遙測技術的提升，遙測影像能獲取的波段數增加，若以統計分析方法對影像進行分類，將面臨 Hughes 現象（Hughes, 1968）問題。且某些統計分析方法必須對樣本資料進行假設，如高斯最大似然法需假設樣本資料具有常態分佈之性質，而這些因素都將使得統計分析方法在使用上受到限制。

類神經網路於遙測影像分類之研究至今已非常普遍，其非線性的處理能力優於統計分析方法，但類神經網路模式具有無法對其網路權重進行解釋的能力及所求得的解可能為局部最佳解的缺點。粗糙集方法為以樣本所得的規則對影像進行分類作業，屬規則式的分類方法，該理論並會對屬性進行縮減，將多餘的屬性予以剔除，僅以縮減後的屬性進行規則攫取。

近年來，統計學習理論受到重視，支持向量機即是以其為基礎所發展出的理論，而將支持向量機應用於遙測影像分類，在國外已有多項研究。如 Zhu & Blumberg (2002)、Melgani & Bruzzone (2004)、Camps-Valls & Bruzzone (2005) 等，且上述列舉的各項研究成果皆顯示，支持向量機所獲得的分類成果皆較其所採用的類神經網路方法為佳。Plausible Neural Network 為新提出的類神經網路模式，其結合統計推論及模糊理論，可用於計算樣本的機率及可能性。

故本研究主要是以支持向量機及 Plausible Neural Network 進行水稻田辨識作業，並選取高斯最大似然分類法、三種已用於遙測影像分類的類神經網路模式（倒傳遞類神經網路、學習向量量化類神經網路及輻狀基底函數類神經網路）及粗糙集方法進行比較，以驗證在水稻田辨識作業中，上述兩種主要方法是否優於其它分類方法。以下各節將針對各分類理論進行說明。

3-1 ISODATA 分類法

本研究因實驗區影像上土地覆蓋情形複雜，且受限檢核資料僅提供水稻及非水稻類別之資訊，故先以 ISODATA 分類法對實驗區影像進行群聚分析，並以指定條件所得的群聚類別數代表影像上土地覆蓋之情形。

ISODATA (Iterative Self-Organizing Data Analysis Technique (A)) 為屬最小距離分類法之一種，若某像元與某類別之距離為最小時，則該像元即屬於該類別。距離值之計算採歐基里得距離 (Euclidean Distance)，公式如下 (陳益鳳，1998)：

$$d_k = \sqrt{(x - \mu_k)^T \cdot (x - \mu_k)} \quad (3-1)$$

上式中， d_k 為某像元至第 k 個群聚類別之歐基里得距離； x 為未知點向量； μ_k 為第 k 個群聚類別之平均值向量。上述歐基里得距離僅考慮平均值間的距離，若欲顧及離散度之影響，可藉由標準差將離散度之影響進行正規化處理，得標準歐基里得距離，即

$$d_k = \sqrt{(x - \mu_k)^T \cdot \sigma_k^{-1} \cdot (x - \mu_k)} \quad (3-2)$$

上式中， σ_k 為第 k 個群聚類別之標準差。基本的 ISODATA 分類法包含以下五個步驟 (Duda & Hart, 1973；陳益鳳，1998)：

1. 輸入 N 、 T 與 M 相關參數。
2. 選擇各群聚中心之起始值。
3. 將各像元分別指定給最靠近的群聚中心。
4. 重新計算每個群聚中心的平均值。
5. 若任一群聚中心的平均值有所變動，則回至第 3 步驟，若無則停止運算。

N 、 T 與 M 為使用者需輸入的參數， N 表示欲分類的群聚數； T 為臨界值，若前後兩次疊代運算成果之各群聚中心變化量小於此臨界值，即完成分類作業；

M 為最大疊代次數，超過該次數則分類作業視為完成。

3-2 高斯最大似然分類法

高斯最大似然分類法（Gaussian Maximum Likelihood Classification）為屬監督式的分類法，該法須先指定各類別之訓練樣本區，待訓練完成後，即以訓練樣本區的光譜分佈性質，當作自動判讀之準則，對整幅影像進行分類作業。訓練樣本區資料之分離性對成果有極大影響，故須謹慎選取。

高斯最大似然法對未知像元進行分類時，將同時考慮光譜反應性質中的變異量與協變方，且為便於計算機率值，使用該法時將假設各類別資料的分佈型態具有高斯分佈之性質，即常態分佈。在該前提下，資料的分佈可由中值向量（mean vector）與協變方矩陣（covariance matrix）表示，經由這兩項參數可計算各像元被分類為某一種土地覆蓋類別之機率，並以最大機率作為判斷像元所屬類別之依據（Lillesand et al., 2004）。高斯最大似然分類法處理程序可分為兩個階段，如圖 3-1，如下所述（劉孝恆，1999）：

1. 訓練階段



由使用者界定影像中類別數 m 並選取各類別之訓練樣本區，且由各訓練樣本資料計算各類別在各波段之中值向量與協變方矩陣，公式如下：

$$\mu_c = \frac{\sum_{i=1}^{n_c} x_i}{n_c} \quad 1 \leq c \leq m \quad (3-3)$$

$$\Sigma_c = \frac{\sum_{i=1}^{n_c} (x_i - \mu_c)(x_i - \mu_c)^T}{n_c} \quad (3-4)$$

上兩式中， μ_c 為類別 c 的中值向量； Σ_c 為類別 c 的協變方矩陣； x_i 為像元 i 在多光譜波段中的灰度值； n_c 為類別 c 在訓練樣本區中的像元總數。

2. 分類階段

將訓練階段所得的各類別中值向量及協變方矩陣代入常態分佈之機率密

度函數（Probability Density Function），以求得整幅影像上各像元對各類別之機率，並依據此機率值對各像元進行分類作業，機率密度函數公式如下：

$$P_c(x_i) = (2\pi)^{-N/2} |\Sigma_c|^{-1/2} \exp\left[-\frac{1}{2}(x_i - \mu_c)^T \Sigma_c^{-1} (x_i - \mu_c)\right] \quad (3-5)$$

上式中， $P_c(x_i)$ 為像元 x_i 對類別 c 之最大似然機率（maximum likelihood probability）；N 為影像上的波段數目。

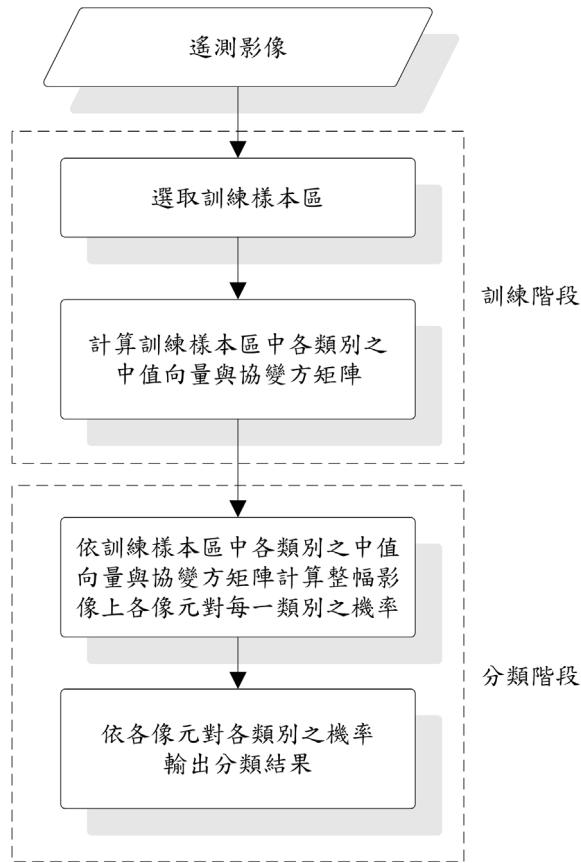


圖 3-1 高斯最大似然分類法處理流程

3-3 類神經網路

類神經網路是一種計算系統，其使用大量相連結的人工神經元（Artificial Neuron）來模擬生物神經網路的能力，當人工神經元受到一組量化的輸入訊號刺激而產生回應，該回應會透過網路權值的作用，傳遞到其它相連的神經元，適當地調整網路權值，以記錄所學的知識訊號，達到生物神經網路的效果（邵泰璋，1999）。在本研究中，也將採用三種相對上較 Plausible Neural Network 為傳統的

類神經網路模式進行水稻田辨識作業，分別為倒傳遞類神經網路、學習向量量化類神經網路及輻狀基底函數類神經網路。

3-3-1 倒傳遞類神經網路

倒傳遞類神經網路（Error Backpropagation，BP）是應用至現今最廣且最具代表性的類神經網路模式。倒傳遞類神經網路相較於感知機模式，多加入隱藏層及使用平滑的轉換函數（雙彎曲函數），以改善感知機模式僅能處理線性問題的缺點。其基本架構，如圖 3-2，包含輸入層、隱藏層及輸出層。

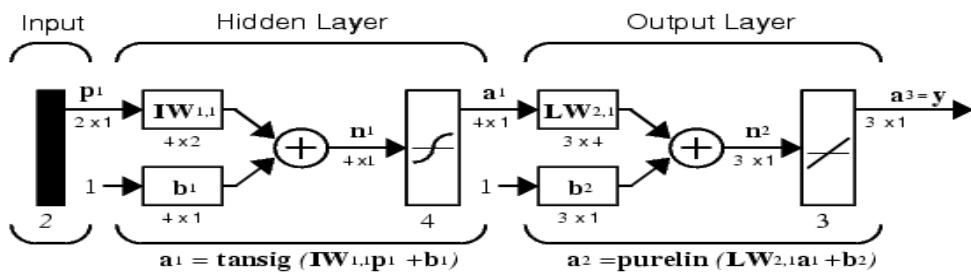


圖 3-2 倒傳遞類神經網路基本架構 (MathWorks, 2001)

倒傳遞類神經網路採用最陡坡降法（The Gradient Steepest Descent Method），將誤差函數最小化，以修正網路權值，說明如下（葉怡成，1998；邵泰璋，1999）：

每個神經元可接收鍊結的輸入訊號，並經轉換函數與閥值的計算，輸出其反應值。以第 n 層之神經元 j 的輸出值 A_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：

$$A_j^n = f(\text{net}_j^n) \quad (3-6)$$

上式中， f 為轉換函數；集成函數 net_j^n 為：

$$\text{net}_j^n = \sum_i W_{ij} A_i^{n-1} - \theta_j \quad (3-7)$$

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 的閥值。

根據神經元連結的關係，以最陡坡降法調整神經元間之連結加權值，以期達到誤差函數為最小。誤差函數 E 為：

$$E = \frac{1}{2} \sum_j (T_j - A_j)^2 \quad (3-8)$$

上式中， T_j 為目標輸出值； A_j 為推論輸出值。

若未達到設定之誤差量，則網路權值需修正，修正方法為：

$$\Delta W_{ij} = -\eta \cdot \frac{\partial E}{\partial W_{ij}} \quad (3-9)$$

上式中， ΔW_{ij} 為神經元 i 與神經元 j 間的連結加權值修正量； η 為學習速率（Learning Ratio）。

本研究中的倒傳遞類神經網路模式將採兩層隱藏層，其意義以圖 3-3 作說明。圖 3-3 (1) 為有兩個類別需找出其分類界線；圖 3-3 (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 3-3 (3) 經第二個隱藏層，相關的線性界線經由一次合併，成為封閉的矩形區塊；圖 3-3 (4) 最後至輸出層，則各個矩形區塊再經一次合併，得到適當的分類界線。

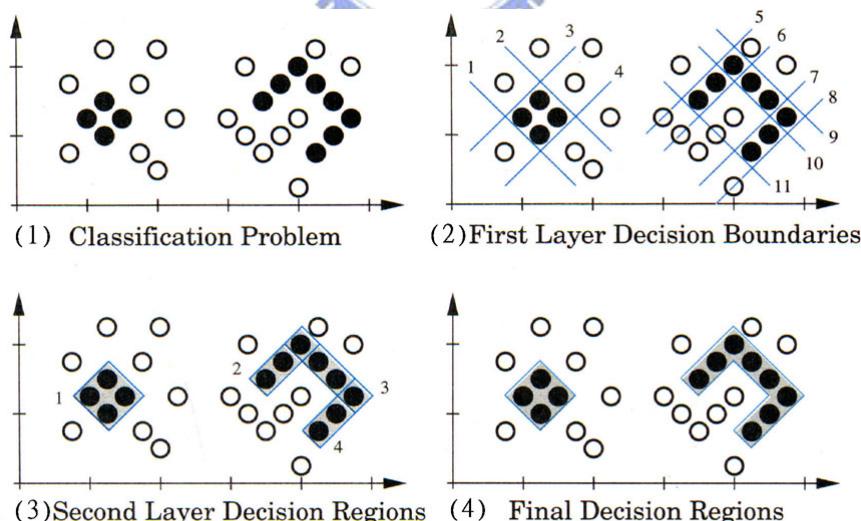


圖 3-3 選用二層隱藏層之示意圖 (Hagan et al., 1995)

3-3-2 學習向量量化類神經網路

學習向量量化類神經網路 (Learning Vector Quantization Network, LVQ) 為

由 Kohonen (1990) 所提出，屬結合監督式與非監督式的混合網路架構，該網路模式於隱藏層中因需較多的處理單元，故在學習速度上較倒傳遞類神經網路為慢，但其回想速度則較快，應用於分類作業將可節省作業時間。

學習向量量化類神經網路的基本原理，為將一群 N 維輸入向量的訓練樣本，視為分佈在 N 維空間中的樣本點，且各類別之樣本點可能散佈成數群，各有各的形心，學習向量量化類神經網路即藉由樣本點來估計各類別中各群的形心位置，待訓練完成後，即可利用各群的形心位置，進行分類作業（邵泰璋，1999）。

學習向量量化類神經網路其基本架構，如圖 3-4，第一層為非監督式的競爭層，其每個神經元代表一個獨立的類別；第二層則為監督式的線性層，為將優勝神經元的類別與輸入向量所屬的類別進行比對，以修正網路權值。修正方式如下所述（邵泰璋，1999）：

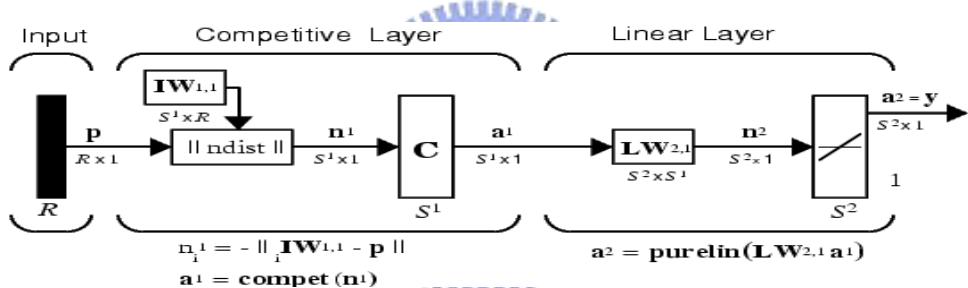


圖 3-4 學習向量量化類神經網路基本架構（MathWorks, 2001）

將訓練樣本點輸入至競爭層，計算樣本點與各類別間的距離，尋求最適合的類別作為歸屬：

$$d(x, m_c) = \min_i \{d(x, m_i)\} \quad (3-10)$$

上式中， $d(x, m_i)$ 為樣本點 x 與各類別 m_i 的距離； m_c 為競爭優勝類別。

競爭層優勝者的訊息將傳入線性層，做監督式的分類作業，故將產生學習為正確或錯誤之結果。並依據該結果用以修正競爭層的網路權重值，以找尋正確的形心位置，而線性層的權重值則為固定值。權重值調整方式如下：

$$m_c(t+1) = m_c(t) + \alpha(t)[x(t) - m_c(t)], \text{ 分類結果正確} \quad (3-11)$$

$$m_c(t+1) = m_c(t) - \alpha(t)[x(t) - m_c(t)], \text{ 分類結果錯誤} \quad (3-12)$$

$$m_i(t+1) = m_i(t), i \neq c \quad (3-13)$$

上述式子中， $\alpha(t)$ 為學習速率，數值介於 0 與 1 之間，具有抑制網路權重值趨近於無限大的作用；(3-11) 式表示類別形心受樣本點的吸引，而往樣本點移動；(3-12) 式表示類別形心受到樣本點的排斥，而遠離樣本點。

3-3-3 輻狀基底函數類神經網路

輻狀基底函數 (Radial Basis Function, RBF) 類神經網路為屬前饋式的類神經網路，其架構與倒傳遞類神經網路相似，如圖 3-5，包含了輸入層、輻狀基底函數隱藏層及輸出層。輻狀基底函數類神經網路主要概念是建構出許多輻狀基底函數神經元，並以函數逼近法 (curve fitting) 找出輸入與輸出間的映射關係 (張斐章等，2004)。

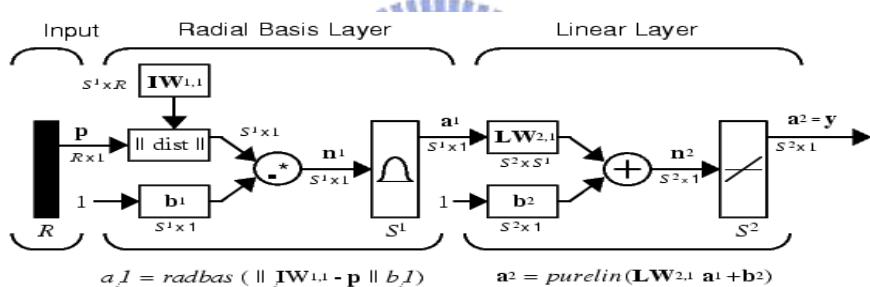


圖 3-5 輻狀基底函數類神經網路基本架構 (MathWorks, 2001)

倘若有 N 個維度的輸入值、M 個神經元的隱藏層與 1 個輸出值，當訓練樣本輸入輸入層後，則輸入向量即傳給隱藏層中每個輻狀基底函數神經元，計算輸入向量與各神經元中心點的距離，並經由函數轉換得隱藏層中各神經元的輸出：

$$z_j(x) = R(\|x - c_j\|) \quad j = 1, 2, K, M \quad (3-14)$$

上式中， R 為輻狀基底函數； c_j 為隱藏層中神經元 j 的中心點； $\|x - c_j\|$ 為 x 與 c_j 間的歐氏距離。將隱藏層的輸出值經加權傳至輸出層，即可求得網路輸出值：

$$y = \sum_{j=1}^M w_j \cdot z_j(x) \quad (3-15)$$

上式中， y 為輸出層的輸出值； w_j 為隱藏層中神經元 j 至輸出層的權重值；

z_j 為隱藏層中神經元 j 的輸出值。將式 (3-14) 代入式 (3-15) 可寫成：

$$y = \sum_{j=1}^M w_j \cdot R(\|x - c_j\|) + w_0 \quad (3-16)$$

本研究的輻狀基底函數將採用高斯函數 $R(\|x - c_j\|) = \exp\left(-\frac{\|x - c_j\|^2}{2\sigma^2}\right)$ ，並以最小平

方法修正線性輸出層之權重值。

3-4 粗糙集方法

粗糙集方法 (Rough Set) 其目的在於處理含糊 (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，而這些規則將可應用於後續的分類作業 (Pawlak, 1991; Pawlak et al., 1995; Komorowski et al., 1999)。

資訊系統 (資訊表)，如表 3-1，可表示為 Λ (Information System) = ($U, A \cup \{d\}$)， U 為有限非空的樣本全集， A 為有限非空的屬性集；其中 $d \notin A$ ， d 稱為決策屬性 (decision attributes)， A 稱為條件屬性 (condition attributes)。以下將藉由表 3-1 資訊系統為例，對粗糙集方法的重點作說明。

表 3-1 資訊系統 (Pawlak, 1995)

	Attributes			Desicion
	Headache	Muscle_pain	Temperature	
e1	yes	yes	normal	no
e2	yes	yes	high	yes
e3	yes	yes	very_high	yes
e4	no	yes	normal	no
e5	no	no	high	no
e6	no	yes	very_high	yes

1. 不可分辨關係

不可分辨關係 (indiscernibility relation) 是粗糙集方法的基礎。從知識的角度而言，若不同樣本可由相同知識所描述，則這些樣本稱為不可分辨。對屬性集中的任一子集 $B \subseteq A$ ，不可分辨關係 $IND_{\Lambda}(B)$ ：

$$IND_{\Lambda}(B) = \{(x, x') \in U^2 \mid \forall a \in B \quad a(x) = a(x')\} \quad (3-17)$$

上式中，若 $(x, x') \in IND_{\Lambda}(B)$ ，則稱 x 與 x' 在 B 上為不可分辨。若透過 B 之不可分辨關係， U 被分割為等價類 (equivalence classes)，則該分割記為 $[x]_B$ ，而不可分辨關係之集合稱為 elementary sets。

以表 3-1 為例，e1、e2 與 e3 其屬性值在 Headache 及 Muscle_pain 兩屬性上皆相同，故 e1、e2 與 e3 在此兩屬性上具有不可分辨關係；而 Headache 屬性所構成的 elementary sets 為 $\{\{e1, e2, e3\}, \{e4, e5, e6\}\}$ 。

2. 縮減

資訊系統中可能包含對樣本分類無益的屬性，因此在找尋規則前，必須對資訊系統進行簡化，此程序稱為屬性的縮減 (Reduction of Attributes)。在資訊系統 $\Lambda = (U, A \cup \{d\})$ 中，令 $R \subseteq P \subseteq A$ ，若 R 為獨立且 $IND_{\Lambda}(R) = IND_{\Lambda}(P)$ ，則稱 R 為 P 的縮減集 (RED(P))。對 P 中的任意縮減集 R 而言，其代表的意義為 R 對樣本的分類能力與 P 對樣本的分類能力一致，因此對樣本分類無益的屬性應從資訊系統中刪除。若屬性 P 有多個縮減，則 P 所有縮減集的交集稱為核集 (CORE(P))：

$$CORE(P) = \cap RED(P) \quad (3-18)$$

核集為資訊系統中最重要的集合，故在進行知識化約時不能將其刪除。以表 3-1 資訊系統為例，三種屬性所構成的 elementary sets，如 (3-19) 式；Muscle_pain 與 Temperature 所構的 elementary sets，如 (3-20) 式；Headache 與 Temperature 所構的 elementary sets，如 (3-21) 式。其中 (3-19) 式與 (3-21) 式之 elementary

sets 相同，故 Muscle_pain 為多餘的屬性，縮減後的資訊系統，如表 3-2。

$$\{\text{Headache}, \text{Muscle_pain}, \text{Temperature}\} = \{\{e1\}, \{e2\}, \{e3\}, \{e4\}, \{e5\}, \{e6\}\} \quad (3-19)$$

$$\{\text{Muscle_pain}, \text{Temperature}\} = \{\{e1, e4\}, \{e2\}, \{e3, e6\}, \{e5\}\} \quad (3-20)$$

$$\{\text{Headache}, \text{Temperature}\} = \{\{e1\}, \{e2\}, \{e3\}, \{e4\}, \{e5\}, \{e6\}\} \quad (3-21)$$

表 3-2 縮減後的資訊系統

	Attributes		Desicion
	Headache	Temperature	Flu
e1	yes	normal	no
e2	yes	high	yes
e3	yes	Very_high	yes
e4	no	normal	no
e5	no	high	no
e6	no	Very_high	yes

3. 規則生成

由表 3-2，可得出下列之規則 (rules)，若資訊系統較為複雜，則可採相關演算法進行規則的攫取，如 LEM2 演算法 (Predki et al., 1998)。

$$(\text{Temperature, normal}) \rightarrow (\text{Flu, no})$$

$$(\text{Headache, no}) \text{ and } (\text{Temperature, high}) \rightarrow (\text{Flu, no})$$

$$(\text{Headache, yes}) \text{ and } (\text{Temperature, high}) \rightarrow (\text{Flu, yes})$$

$$(\text{Temperature, very_high}) \rightarrow (\text{Flu, yes})$$

4. 概似集合

概似集合 (approximation set) 為粗糙集方法的另一重要概念。資訊系統 $\Lambda = (U, A \cup \{d\})$ 中，令 $B \subseteq A$ 及 $X \subseteq U$ ， B 對 X 的下概似記為 \underline{BX} ，其定義如 (3-22) 式； B 對 X 的上概似記為 \overline{BX} ，其定義如 (3-23) 式：

$$\underline{BX} = \{x | [x]_B \subseteq X\} \quad (3-22)$$

$$\overline{BX} = \{x | [x]_B \cap X \neq \emptyset\} \quad (3-23)$$

以表 3-3 為例，對 $x=\{e2, e3, e5, e7\}$ (得到感冒患者的集合) 而言，Headache 及 Temperature 屬性所構成的 elementary sets 如(3-24)式。則下概似 \underline{BX} 如(3-25)式；上概似 \overline{BX} 如 (3-26) 式：

$$\{\text{Headache, Temperature}\}=\{\{e1, e7\}, \{e2\}, \{e3\}, \{e4\}, \{e5, e8\}, \{e6\}\} \quad (3-24)$$

$$\underline{BX} = \{\{e2\}, \{e3\}\} \quad (3-25)$$

$$\overline{BX}=\{\{e1, e7\}, \{e2\}, \{e3\}, \{e5, e8\}\} \quad (3-26)$$

表 3-3 資訊系統二

	Attributes		Desicion
	Headache	Temperature	Flu
e1	yes	normal	no
e2	yes	high	yes
e3	yes	very_high	yes
e4	no	normal	no
e5	no	high	yes
e6	no	very_high	no
e7	yes	normal	yes
e8	no	high	no

同樣由 $x=\{e1, e4, e6, e8\}$ (未得到感冒患者的集合) 也可求得一組上概似與下概似的集合。由下概似所得到的規則為確定的規則 (certain rules)，上概似所得的規則為可能的規則 (possible rules)，以表 3-3 為例：

確定的規則為：

$$(\text{Headache, yes}) \text{ and } (\text{Temperature, high}) \rightarrow (\text{Flu, yes})$$

$$(\text{Headache, yes}) \text{ and } (\text{Temperature, very_high}) \rightarrow (\text{Flu, yes})$$

$$(\text{Headache, yes}) \rightarrow (\text{Flu, yes})$$

可能的規則為：

$$(\text{Headache, yes}) \text{ and } (\text{Temperature, normal}) \rightarrow (\text{Flu, no})$$

$$(\text{Headache, yes}) \text{ and } (\text{Temperature, high}) \rightarrow (\text{Flu, yes})$$

(Headache, yes) and (Temperature, very_high) -> (Flu, yes)
 (Headache, no) and (Temperature, high) -> (Flu, yes)
 (Headache, yes) and (Temperature, normal) -> (Flu, yes)
 (Headache, no) and (Temperature, high) -> (Flu, no)
 (Temperature, high) -> (Flu, yes)
 (Headache, yes) -> (Flu, yes)

3-5 支持向量機

3-5-1 支持向量機分類基本理論

支持向量機 (Support Vector Machine, SVM) 為依統計學習理論為基礎，所建構出的機器學習系統，其主要原理是在特徵空間中尋求具最大邊界的區分超平面以區分不同的二元類別。支持向量機可分為線性及非線性，倘若訓練樣本在空間中的分佈呈非線性，則採非線性支持向量機；反之則採線性支持向量機，而線性支持向量機又可分為線性可分或線性不可分之情況。以下將分別針對線性及非線性支持向量機作說明 (Vapnik, 1995 ; Burges, 1998 ; Cristianini & Shawe-Taylor, 2000) 。

1. 線性支持向量機

在線性可分的情況，如圖 3-6，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。求解區分超平面過程可視為求解二次規劃 (quadratic programming) 問題。線性可分為求解下式的最小值：

$$\Phi(w) = \frac{1}{2}(w \cdot w) \quad (3-27)$$

上式限制條件為 $y_i[(x_i \cdot w) + b] \geq 1$ 、 $i = 1, 2, \dots, l$ 。

透過拉格朗日 (Lagrangian) 轉換，可將 (3-27) 式轉換為：

$$L(w, b, \alpha) = \frac{1}{2}(w \cdot w) - \sum_{i=1}^l \alpha_i \{[(x_i \cdot w) + b]y_i - 1\} \quad (3-28)$$

上式 α_i 為拉格朗日乘子 (Lagrange multipliers)，且 $\alpha_i \geq 0$ 。

將 (3-28) 式對 w 及 b 作偏微，使上述最佳化問題轉為求對偶問題 (dual problem)：

$$\frac{\partial L(w, b, \alpha)}{\partial w} = w - \sum_{i=1}^l y_i \alpha_i x_i = 0 \rightarrow w = \sum_{i=1}^l y_i \alpha_i x_i \quad (3-29)$$

$$\frac{\partial L(w, b, \alpha)}{\partial b} = \sum_{i=1}^l y_i \alpha_i = 0 \rightarrow 0 = \sum_{i=1}^l y_i \alpha_i \quad (3-30)$$

將偏微所得的 (3-29) 和 (3-30) 式代入 (3-28) 式並考慮 Karush-Kuhn-Tucker 條件，可將 (3-28) 式轉換為求解下式的最大值：

$$W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (3-31)$$

上限制條件為 $\alpha_i \geq 0$ 、 $\sum_{i=1}^l \alpha_i y_i = 0$ 、 $i = 1, 2, \dots, l$ 。

透過 (3-31) 式的求解，可求得一分類函數：

$$f(x) = sign \left(\sum_{\text{support vectors}} y_i \alpha_i (x_i \cdot x) - b \right) \quad (3-32)$$

上式中， x_i 為支持向量； α_i 為相應 x_i 之拉格朗日乘子； 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 3-7，(3-27) 式可改寫成 (3-33) 式，其目標為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：

$$\Phi(w, \xi) = \frac{1}{2}(w \cdot w) + C \left(\sum_{i=1}^l \xi_i \right) \quad (3-33)$$

上式限制條件為 $y_i [(w \cdot x_i) + b] \geq 1 - \xi_i$ 、 $\xi_i \geq 0$ 、 $i = 1, 2, \dots, l$ 。C 為懲罰參數 (penalty parameter)、 ξ_i 為沉滯變數 (slack variable)。

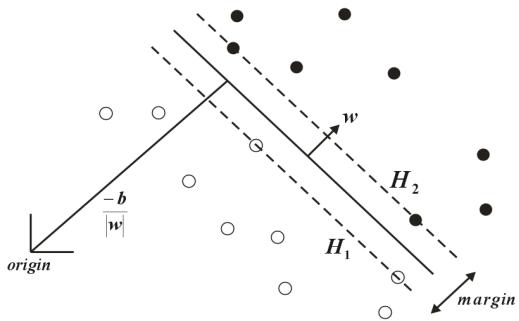


圖 3-6 線性可分

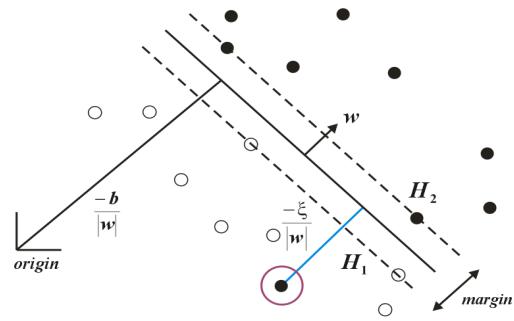


圖 3-7 線性不可分

2. 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：

$$f(x) = \text{sign} \left[\sum_{\text{support vectors}} y_i \alpha_i K(x_i, x) - b \right] \quad (3-34)$$

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)，

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

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

$K(x_i, x) = \tanh(\kappa x_i \cdot x - \delta)$ 。本研究將採上述核函數進行支持向量機於不同核函數之分類實驗。

3-5-2 多類支持向量機分類法

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 (Melgani & Bruzzon, 2004；王景南, 2002)：

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。在此舉一例作說明：假若有三種類別，則 1 和 2 類別、1 和 3 類別及 2 和 3 類別皆各會產生一個支持向量機，如圖 3-8。倘若現今有一個欲分類的樣本，並假定其為類別 2，則該樣本會分別代入三個支持向量機中，且每個支持向量機會決定該樣本的類別並在該類別的票數加 1，最終將以具有最多票數的類別為該樣本的所屬類別，如圖 3-9。

	1	2	3
1		1 2	1 3
2			2 3
3			

圖 3-8 支持向量機之產生方式

	1	2	3
1 2		1	
1 3			1
2 3		1	
Vote	0	2	1

圖 3-9 投票策略說明

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。不同之處是此方法會建立一個二元且無循環的有向圖，如圖 3-10。圖中共有 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。

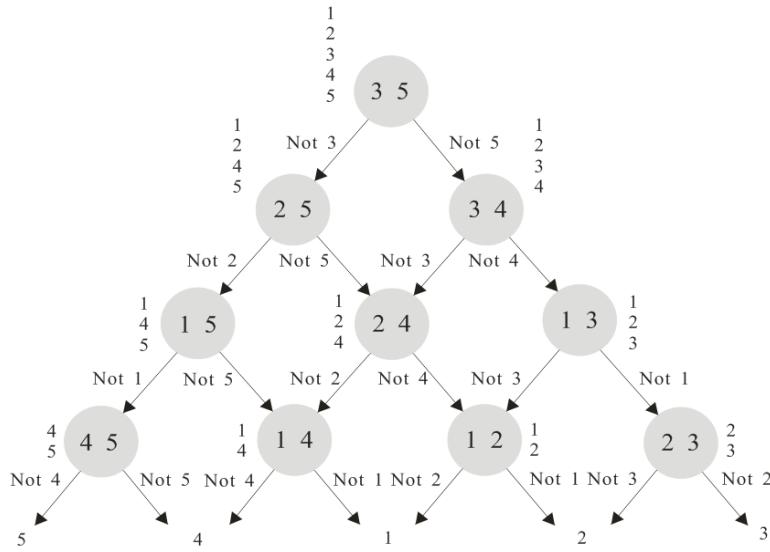


圖 3-10 DAG method 處理 5 種類別時之二元且無循環的有向圖

3-6 Plausible Neural Network

Plausible Neural Network (PNN) 為新提出的的類神經網路模式 (Chen, 2002；Chen & Chen, 2004；Chen, 2005)，該模式結合統計理論及模糊理論，可用於計算樣本的機率 (Probability) 及可能性 (Possibility)。PNN 可進行群聚 (Clustering) 及分類 (Classification) 之分析，但其分類仍為非監督式分類 (unsupervised classification)，因在該模式中所加入樣本之類別資訊，僅用於指定分類後群聚 (clusters) 之所屬類別，並未對網路權重造成影響。其網路架構如圖 3-11，包含輸入層及隱藏層。

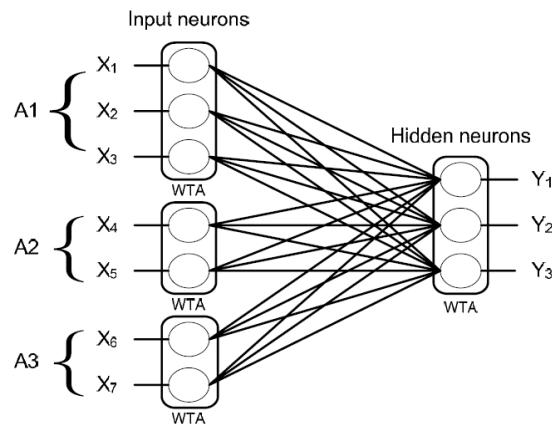


圖 3-11 PNN 之網路架構圖 (Chen, 2005)

PNN 模式是以最大概似估計 (maximum likelihood estimate) 及活化函數 (activation function) 做為學習演算之依據，說明如下：

任兩個神經元在 PNN 的連結權重可由 mutual information content 求得：

$$\omega_{12} = \ln(P(X, Y) / P(X)P(Y)) \quad (3-35)$$

上式中，X 和 Y 為在[0,1]間的連續變數，用於表示神經元的狀態。而 ω_{12} 之最大概似估計為：

$$\hat{\omega}_{12} = \log(n \sum_i x_i y_i / \sum_i x_i \sum_i y_i) \quad (3-36)$$

上式中 x_i 及 y_i 為神經元狀態的過往紀錄。

PNN 的活化函數是以贏者全拿 (winner-take-all, WTA) 函數為依據。經由正規化 (normalization)，神經元整體的觸發形式 (firing pattern) 可以模糊集的 α -cut 運算作說明。而神經元整體的活化，如下式：



$$y_j = s\left(\sum_i \omega_{ij} x_i\right), \forall j, e^{\beta \sum_i \omega_{ij} x_i / \sup_j e^{\beta \sum_i \omega_{ij} x_i}} > \alpha \\ y_j = 0, \text{otherwise}, \quad (3-37)$$

上式中 $s(t_j) = e^{\beta t_j} / \sum_j e^{\beta t_j}$ 。

在較高階的類神經處理，假如 y_1 和 y_2 為兩個競爭神經元並接收從 x_1, x_2, \dots, x_n 之輸入，其動作電位 (action potential) 為：

$$\sum_i \omega_{ij} x_i = \sum_i \ln(p(x_i | y_j)) - \sum_i \ln(p(x_i)) \quad (3-38)$$

透過對動作電位作微分，(3-38) 式中的第二項可消去，並由獨立之假設條件可得：

$$\ln(p(x_1, x_2, \dots, x_n | y_1)) / \ln(p(x_1, x_2, \dots, x_n | y_2)) \quad (3-39)$$

假若 y_1 之權重大於 y_2 甚多，則 y_2 可由 (3-37) 式的 threshold cut 去除，則得：

$$p(y_1 | x_1, x_2, \dots, x_n) = Bel(y_1 | x_1, x_2, \dots, x_n) = 1 \quad (3-40)$$

上式中 Bel 為 belief measure，因此網路的計算如同布林邏輯（ Boolean logic ）之計算。

PNN 在本研究中將採用兩種版本，V 1.3 為一般化的版本；V1.0 則在模式中加入考量樣本屬性間及鄰近樣本點間之關聯資訊。

3-6-1 PNN 之學習演算法

在 PNN 中，假若變數為連續數值，則資料必須編碼為模糊集合（ fuzzy set ）。 PNN 之學習演算法本質上為 E-M 演算法，圖 3-12 即為 PNN 之學習演算法流程圖，演算步驟如下所述：

1. 隨機觸發隱藏神經元。
2. M-step：估量輸入神經元與隱藏神經元間之連結權重。
3. E-step：計算隱藏神經元之動作電位並正規化至 [0,1] 。若神經元的活化程度大於門檻值 α 則觸發。
4. 若神經元之觸發有所改變則更新突觸（ synaptic ）權重。
5. 重覆至整個網路穩定即停止。

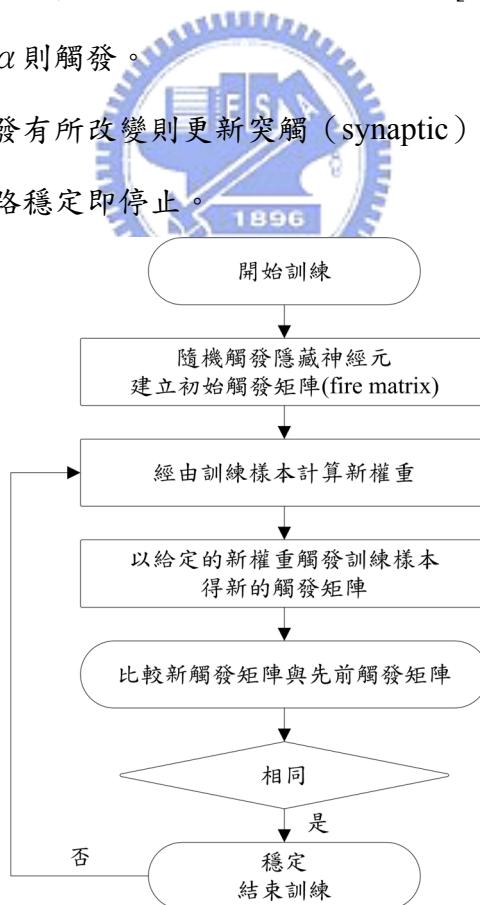


圖 3-12 PNN 之學習演算法流程圖

第四章 影像資料與分類實驗流程

4-1 實驗區及遙測影像

本研究使用兩組實驗數據進行水稻田辨識作業，第一組實驗數據為 93 年嘉義地區二期稻作，採用 Formosat-2 影像；第二組實驗數據為 89 年新竹地區一期稻作，採用 SPOT 影像，且每組實驗數據包含五幅不同時段影像。

不同時段衛星影像會受到衛星感測器及大氣條件等因素的影響 (Smith & Milton, 1999 ; Yuan & Elvidge, 1995) ，而使得地表不變物的光譜反射值在不同時段具有明顯的差異。故在研究中，以經驗線法對實驗區的衛星影像進行相對輻射改正，經驗線法的樣本點選取以光譜反射不隨時間變動的地表覆蓋物為原則。

檢核資料以農糧署所提供之相同年份和相同稻作期的 1/5000 耕地地籍圖為依據，該資料是以航空照片經人工判釋方式而得。耕地地籍圖原屬向量格式，為配合網格式的遙測影像，故須將向量格式轉換至影像格式，實驗中採優勢法進行轉換作業，優勢法亦即將網格內較具優勢的特徵值作為網格的所屬值。

4-1-1 嘉義地區

嘉義地區二期稻作之水稻辨識採用五幅 Formosat-2 衛星影像，各幅影像之攝像日期與對應水稻生育進度，如表 4-1。衛星影像等級皆為 Level 3 (經軌道參數及地面控制點改正) 及像元解析力為 8 公尺。在多時段 Formosat-2 影像中，切割 600×500 像元作為嘉義實驗區，地理上該實驗區位於嘉義縣溪口鄉及民雄鄉間（實驗區左上角 2° TM 坐標為 N=2610388m、E=186272m；右下角 2° TM 坐標為 N=2605588m、E=190272m）。實驗區的切割範圍僅 600×500 像元，主要是為了在多時段影像中，皆能有完整地表覆蓋影像涵蓋整個實驗區，避免因雲的遮蔽而影響分類成果。

1. 相對輻射改正

本實驗區以 12 月 17 日所拍攝的影像作為基準影像，並在各幅影像間選定 12 個位於相同位置之樣本點。經線性迴歸後，查看各幅改正影像之樣本點分佈性，並從中剔除 3 個分佈性較差的樣本點，以此建立各幅改正影像之線性轉換方程式，如表 4-2。圖 4-1（以 adaptive 法（PCI, 1997）對影像進行增揚）為五幅經輻射改正後之影像。

表 4-1 嘉義地區之攝像日期與水稻生育進度對應表

攝像日期	對應之水稻生育進度
93 年 08 月 07 日	插秧~生長期
93 年 09 月 29 日	分蘖~幼穗形成
93 年 10 月 12 日	幼穗~抽穗開花
93 年 11 月 08 日	乳熟~黃熟
93 年 12 月 17 日	收割後或其他植生

表 4-2 Formosat-2 各幅改正影像之線性轉換方程式

	線性轉換方程式	迴歸係數 (R^2)
2004/08/07	1.2465XS1-48.05	0.9481
	1.4915XS2-65.05	0.9528
	1.7389XS3-106.89	0.9572
2004/09/29	1.1775XS1-59.763	0.9433
	1.2468XS2-35.009	0.9595
	1.3500XS3-56.495	0.9789
2004/10/12	1.0359XS1-38.319	0.9680
	1.1875XS2-27.523	0.9893
	1.333XS3-48.3000	0.9868
2004/11/08	1.1262XS1-33.639	0.9620
	1.2371XS2-26.868	0.9665
	1.3776XS3-46.712	0.9937

XS1:近紅外光 XS2:紅光 XS3:綠光

2. 檢核資料

該實驗區的檢核資料包含四張 1/5000 圖幅範圍（9420-II-066 ~ 067 及

9420-II-076 ~ 077），各圖幅經向量轉網格格式後，需進行影像鑲嵌並切割至與多時段影像相同圖幅大小及區域，該區檢核影像如圖 4-2。

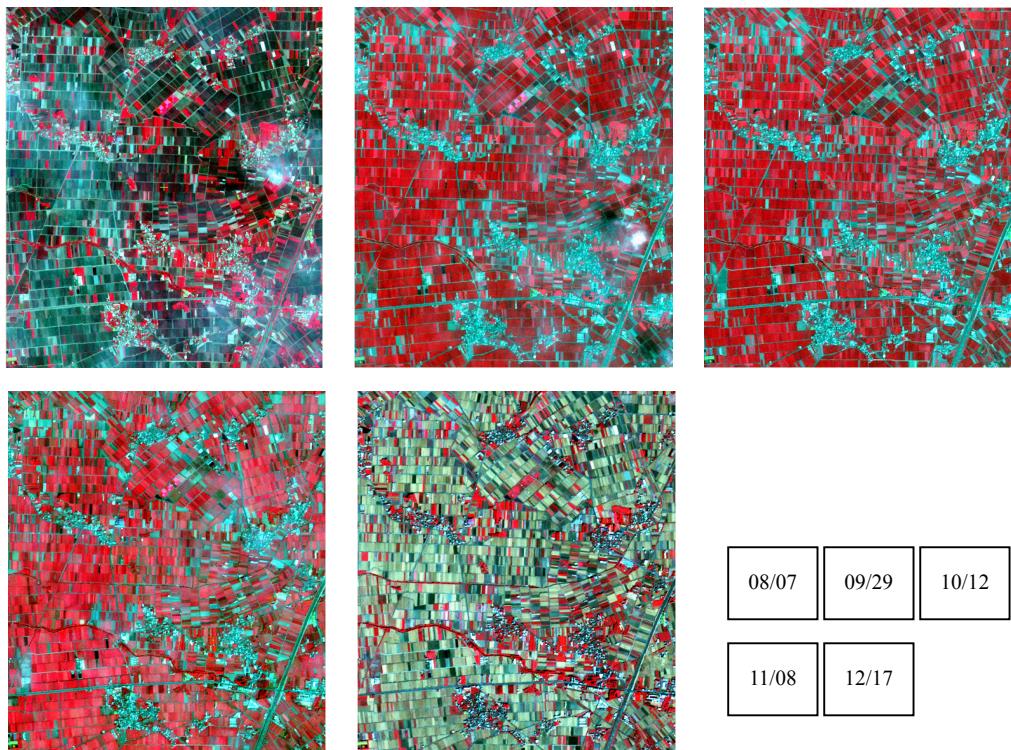


圖 4-1 嘉義實驗區之五個時段 Formosat-2 影像

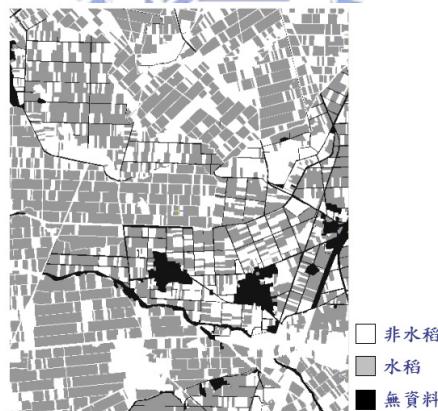


圖 4-2 嘉義實驗區之檢核影像

4-1-2 新竹地區

新竹地區一期稻作之水稻辨識採用五幅 SPOT 衛星影像，各幅影像之攝像日期與對應水稻生育進度，如表 4-3。其中 89 年稻作在插秧至生長期階段無法獲取具良好品質的衛星影像，故以 88 年同生長階段的影像取代。各時段衛星影像等

級皆為 Level 10 及像元解析力為 12.5 公尺。在多時段 SPOT 影像中，切割 440×600 像元作為新竹實驗區，地理上該實驗區位於新竹市北區及新竹縣竹北市間（實驗區左上角 2° TM 坐標為 N=2751943.75m、E=242456.25m；右下角 2° TM 坐標為 N=2746443.75m、E=249956.25m）。該實驗區的切割範圍僅 440×600 像元，其原因相同於嘉義實驗區。

表 4-3 新竹地區攝像日期與水稻生育進度對應表

攝像日期	對應之水稻生育進度
88 年 03 月 05 日	插秧~生長期
89 年 04 月 18 日	分蘖~幼穗形成
89 年 05 月 09 日	幼穗~抽穗開花
89 年 06 月 04 日	乳熟~黃熟
89 年 07 月 25 日	收割後或其他植生

1. 相對輻射改正

本實驗區則以 7 月 25 日所拍攝的影像作為基準影像，並在各幅影像間選取 12 個位於相同位置的樣本點。經線性迴歸後，查看各幅改正影像之樣本點分佈性，其中 4 個分佈性較差的樣本點予以剔除，以此建立各幅改正影像之線性轉換方程式，如表 4-4。圖 4-3（各影像以 adaptive 方法對影像進行增揚）為五幅經輻射改正後之影像。

2. 檢核資料

本實驗區的檢核資料則包含六張 1/5000 圖幅範圍（9522-I-058 ~ 060 及 9522-I-068 ~ 070），各圖幅經向量轉網格格式後，相同於嘉義實驗區需進行影像鑲嵌並切割至與多時段影像相同圖幅大小及區域，該區檢核影像如圖 4-4。

表 4-4 SPOT 各幅改正影像之線性轉換方程式

	線性轉換方程式	迴歸係數 (R^2)
1999/03/05	0.8562XS1-3.9894	0.9461
	1.0029XS2-18.519	0.9533
	1.7695XS3-87.755	0.9167
2000/04/18	0.7487XS1+6.6622	0.9722
	0.8137XS2+9.7727	0.9767
	1.1203XS3-41.960	0.9632
2000/05/09	0.7408XS1+19.853	0.9764
	0.8249XS2+12.418	0.9881
	1.0403XS3-4.294	0.9815
2000/06/04	0.7802XS1+6.0333	0.9453
	0.7898XS2+21.84	0.9846
	1.0099XS3-7.1463	0.9877

XS1:近紅外光 XS2:紅光 XS3:綠光

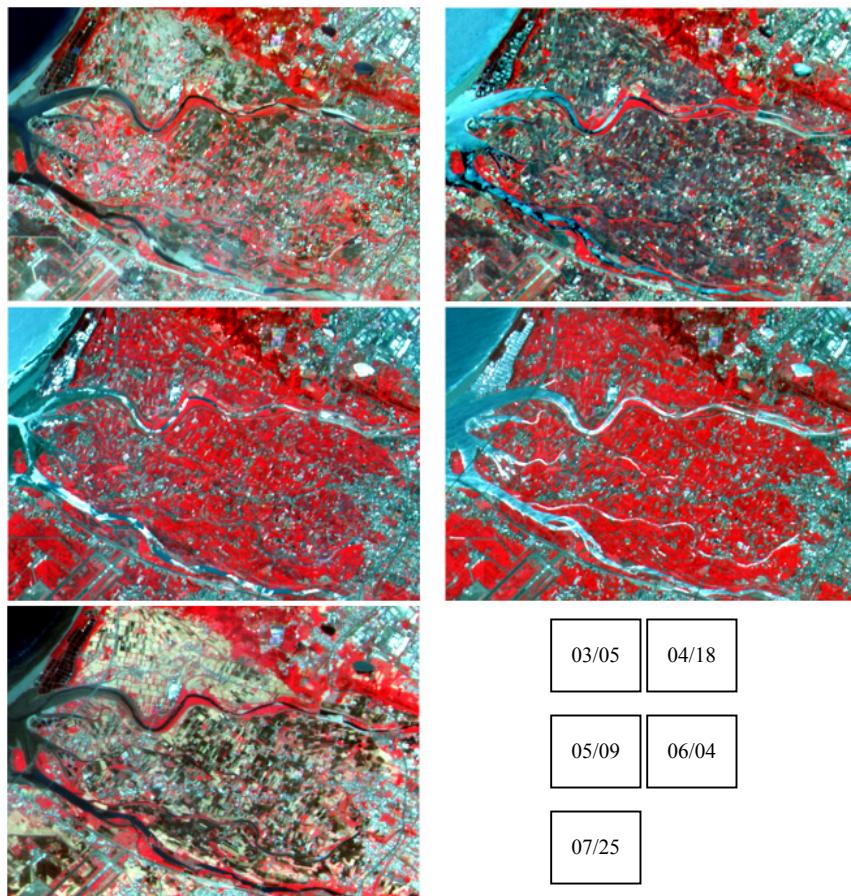


圖 4-3 新竹實驗區之五個時段 SPOT 影像

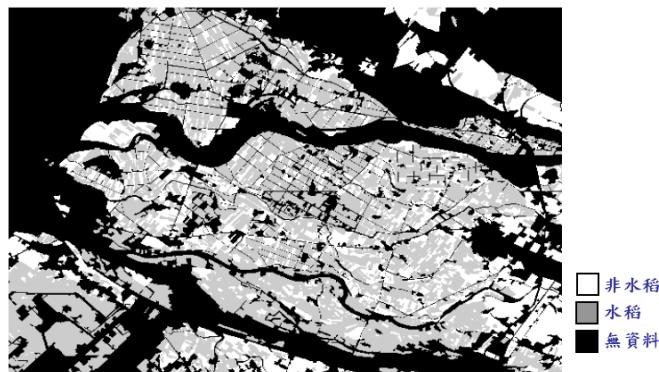


圖 4-4 新竹實驗區之檢核影像

4-2 訓練樣本選取

嘉義及新竹實驗區在衛星影像上，土地覆蓋種類繁雜，且受限檢核資料僅提供水稻及非水稻類別之資訊，故在影像上不易選取具代表性的訓練樣本。因此，兩組實驗區之訓練樣本選取，皆先以 ISODATA 分類法將實驗區分為多個群聚類別，再於各群聚類別上選取訓練樣本。

研究中，因以嘉義實驗區資料進行高斯最大似然分類法及支持向量機於不同群聚類別數及訓練樣本集合之穩定性探討，故於嘉義實驗區的訓練樣本選取流程，加入不同群聚類別數及訓練樣本集合之選定方式。新竹實驗區則採單一群聚類別數及訓練樣本集合作為各分類理論之依據。

4-2-1 嘉義實驗區

嘉義實驗區之訓練樣本選取流程，如圖 4-5。ISODATA 群聚分析所設定的相關參數分別為：初始群聚類別數為 40、收斂條件為 98%（當 98%像元不再改變其群聚類別則停止該法）、群聚類別最小像元數為 10，由該參數設定得 38 個群聚類別。群聚分析完成後，則將流程分為群聚類別是否進行合併處理之兩個部份。

若不進行群聚類別合併，38 個群聚類別依地面檢核資料及多時段衛星影像重新歸屬為 38 個群聚類別（1-27 群聚類別屬非水稻類別；28-38 群聚類別屬水稻類別）。上述重新歸屬群聚類別作業主要是使屬水稻或非水稻的群聚類別有連

續編號，易於和後續檢核資料作比對。

若進行群聚類別合併，則採兩種方式：1.直接將各群聚類別依據檢核資料及參考多時段衛星影像，合併為水稻及非水稻 2 個群聚類別（1 群聚類別屬非水稻類別；2 群聚類別屬水稻類別）；2.計算各群聚類別間的 Bhattachayya 距離值，並依據該距離值、參考檢核資料和多時段衛星影像將各群聚類別合併為 23 個群聚類別（1-18 群聚類別屬非水稻類別；19-23 群聚類別屬水稻類別）。

訓練樣本仍是在 38 個群聚類別上選取，唯需考量群聚類別是否合併，若某些群聚類別合併成一個新的群聚類別，則其訓練樣本也將合併。訓練樣本的選取方式是以矩形區塊為依據，位置主要是選在群聚類別內部區域並避免選取直接與其它群聚類別相鄰的區域，如圖 4-6。

過程中並探討三種訓練樣本集合，分別為初始選取樣本、初始選取樣本增加水稻樣本及初始選取樣本增加非水稻樣本。初始選取樣本是最初在各群聚類別上所選取的樣本；增加水稻樣本則是增加選取屬於水稻之各群聚類別的樣本；而增加非水稻樣本則是增加選取屬於非水稻之各群聚類別的樣本。

三種訓練樣本集合之水稻及非水稻像元數，如表 4-5。表 4-6 為三種群聚類別於三種訓練樣本集合之最小分離度（Minimum Separability），分離度是採用是 Bhattacharyya Distance 以 PCI 軟體計算，若該值大於 1.9 (PCI, 1997)，則表示各群聚類別間具有良好的分離度。由表 4-6 可見，各最小分離度值皆大於 1.9，故各具有良好的分離度。

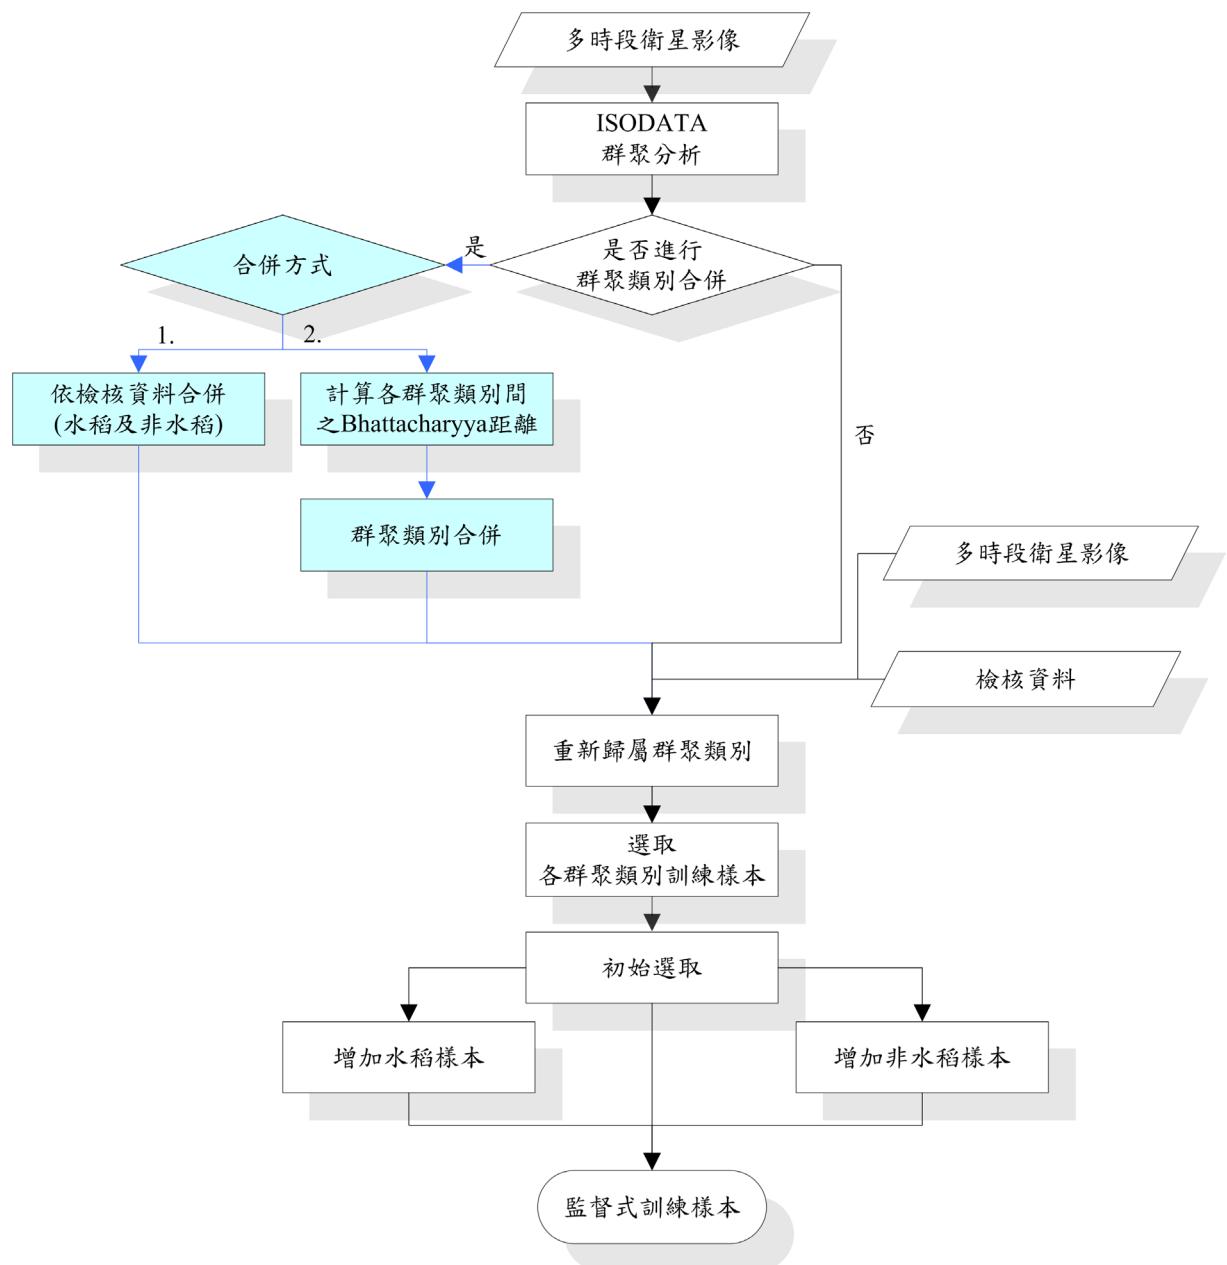


圖 4-5 嘉義實驗區之訓練樣本選取流程



圖 4-6 訓練樣本選取示意圖

表 4-5 三種訓練樣本集合說明

初始選取樣本增加水稻樣本					
水稻	374	非水稻	602	總像元數	976
初始選取樣本					
水稻	310	非水稻	602	總像元數	912
初始選取樣本增加非水稻樣本					
水稻	310	非水稻	850	總像元數	1160

表 4-6 三種群聚類別於三種訓練樣本集合之最小分離度

	2 個群聚類別	23 個群聚類別	38 個群聚類別
增加水稻樣本	1.968399	1.995662	1.999778
初始選取樣本	1.983883	1.997810	1.999973
增加非水稻樣本	1.970022	1.989696	1.999934

4-2-2 新竹實驗區

新竹實驗區訓練樣本選取流程，如圖 4-7，其訓練樣本的選取方式除僅考慮單一群聚類別數及訓練樣本集合之外，其餘皆相同於嘉義實驗區。該流程中，ISODATA 群聚分析所設定的相關參數皆相同於嘉義實驗區，唯該參數設定得 40 個群聚類別。

群聚分析完成後，將 40 個群聚類別合併為水稻及非水稻 2 個群聚類別（1 群聚類別屬非水稻類別；2 群聚類別屬水稻類別）。訓練樣本集合之水稻及非水稻像元數，如表 4-7。該區所選取的訓練樣本其最小分離度值為 1.999142，該值

大於 1.9，故具有良好的分離度，分離度的計算方式相同於嘉義實驗區。

表 4-7 訓練樣本集合說明

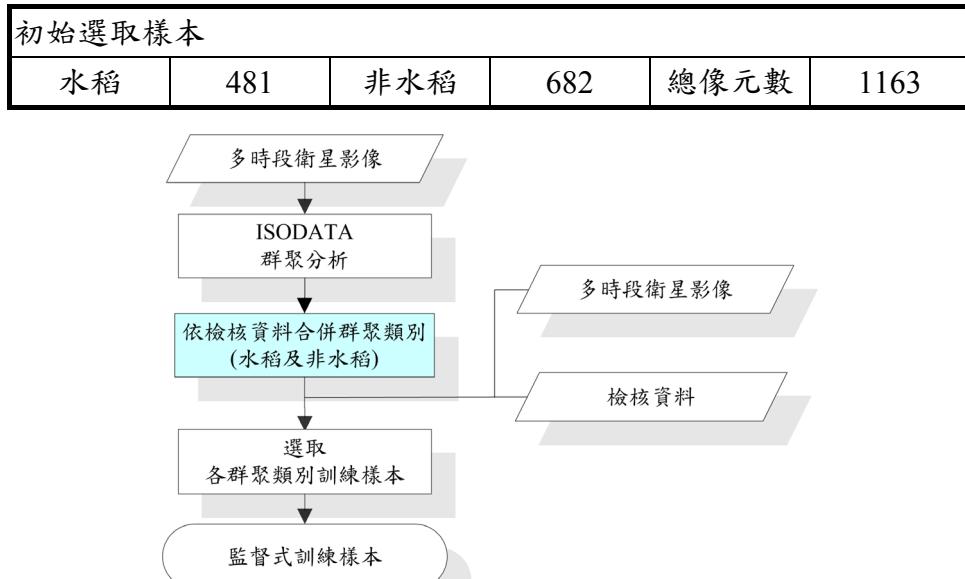


圖 4-7 新竹實驗區之訓練樣本選取流程

4-3 分類實驗流程

在嘉義及新竹實驗區皆進行不同核函數的支持向量機及各分類理論之分類實驗。兩實驗區在分類實驗流程之差異，為嘉義實驗區增加兩部份之實驗流程，分別為高斯最大似然分類法及支持向量機之穩定性實驗；及以該區多時段影像生成紋理影像輔助支持向量機分類之實驗。以下將針對各實驗區之實驗流程作說明。

4-3-1 嘉義實驗區

嘉義實驗區的分類實驗流程可分為四個部分，如下所述：

1. 第一部分為以高斯最大似然分類法及支持向量機於不同群聚類別數及訓練樣本集合進行分類實驗，以探討兩分類方法之穩定性，流程如圖 4-8。流程中以不同群聚類別數及訓練樣本集合建立高斯最大似然分類法及支持向量機的分類模式，以對全實驗區域影像進行分類作業，分類後所得之群聚類別必須更新分類為水稻及非水稻類別，再依據檢核資料進行精度分

析。此階段的支持向量機採用輻狀基底函數為核函數。第二及第三部份的訓練樣本，則以此部份實驗中，支持向量機分類精度為最佳的群聚類別數及訓練樣本集合作為依據。第四部份的訓練樣本則是以相同於第二及三部份的訓練樣本再加上紋理影像資訊所組成。

2. 第二部分為支持向量機於不同核函數之分類流程，如圖 4-9。
3. 第三部份為各分類理論之分類流程，如圖 4-10。
4. 第四部份為應用紋理影像輔助支持向量機分類之分類流程，如圖 4-11。紋理影像之生成與取樣視窗大小、取樣方向、灰階範圍及選用的紋理統計量等參數相關，故本研究以紋理統計量之選用作為變量，並固定其它參數，以探討加入不同紋理統計量對分類成果之影響。實驗中以四種方式建立紋理影像，各方式之取樣視窗大小為 3×3 、取樣方向為 $\delta=(1, 1)$ 及灰階範圍皆為 64 階。四種建立紋理影像之方式，如下所述：
 - (1) 以 8 月 7 日紅光波段取八種紋理統計量，紋理統計量分別為 Mean、Variance、Homogeneity、Contrast、Dissimilarity、Entropy、ASM 及 Correlation，如圖 4-12。
 - (2) 以 10 月 12 日近紅外光波段取八種紋理統計量，紋理統計量的採用與方式 (1) 相同，如圖 4-13。
 - (3) 針對全部波段取八種紋理統計量，紋理統計量分別為 Mean、Variance、Homogeneity、Contrast、Dissimilarity、Entropy、ASM 及 Correlation。該方式可得 96 種紋理影像，因資訊量過於繁雜，故以主成分分析法取前八個主軸波段，如圖 4-14。表 4-8 為各主軸資訊量。
 - (4) 針對全部波段取五種紋理統計量，紋理統計量的選用與黎瑋 (1998) 研究中所採用的相同，分別為 Homogeneity、Contrast、Dissimilarity、Entropy 及 ASM。該方式可得 60 種紋理影像，同方式 (3) 以主成分

分析法取前八個主軸波段，如圖 4-15。表 4-9 為各主軸資訊量。

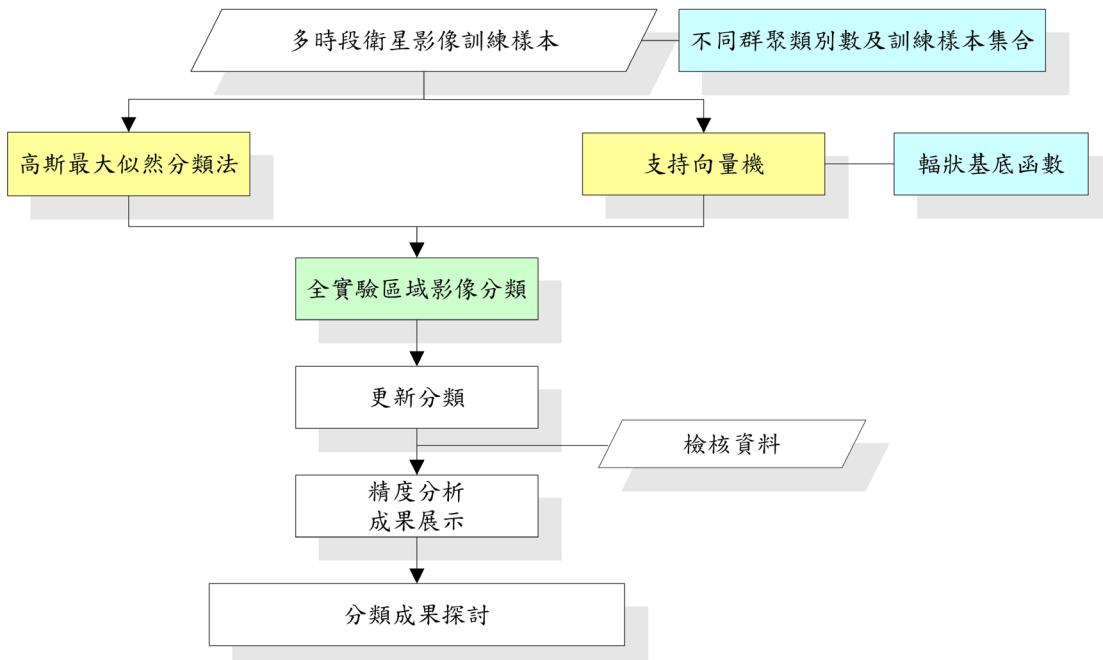


圖 4-8 高斯最大似然分類法及支持向量機之穩定性探討分類流程

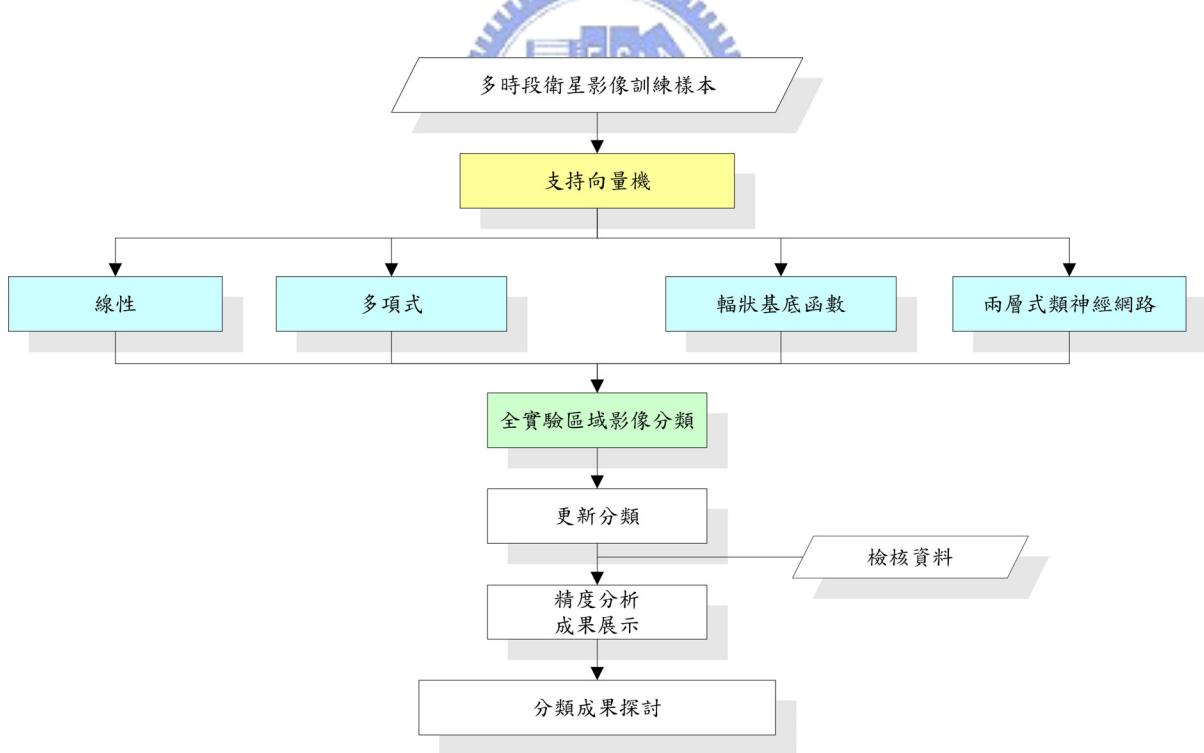


圖 4-9 支持向量機於不同核函數之分類流程

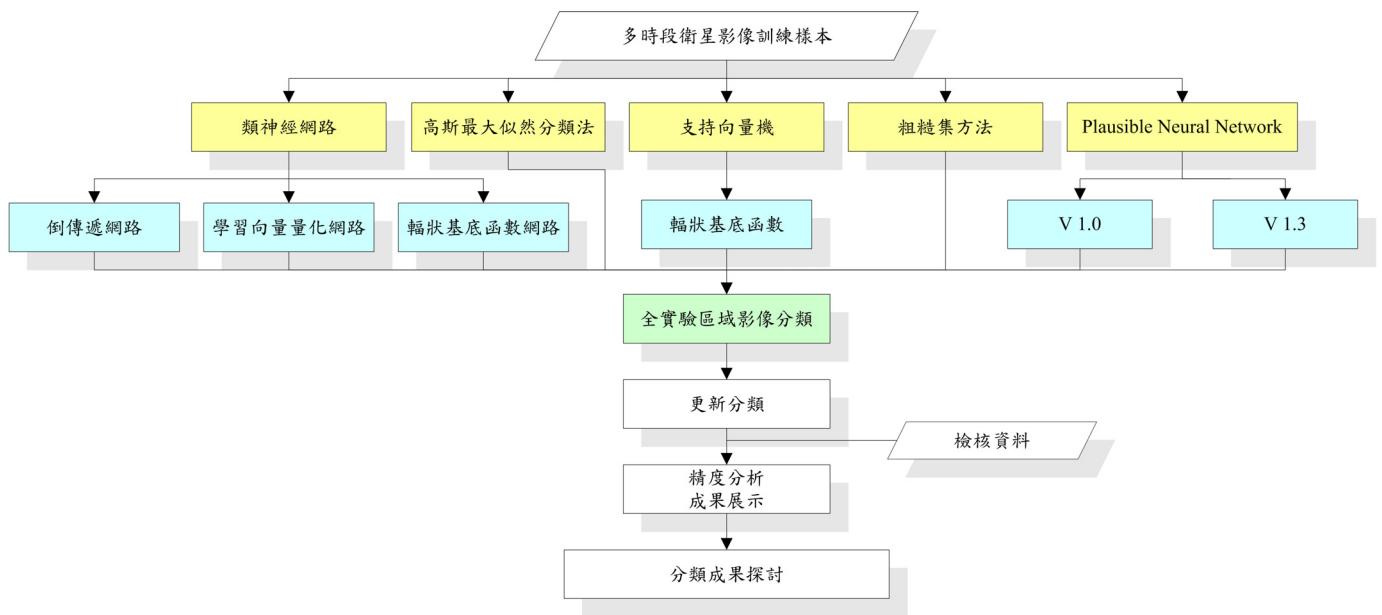


圖 4-10 各分類理論之分類流程

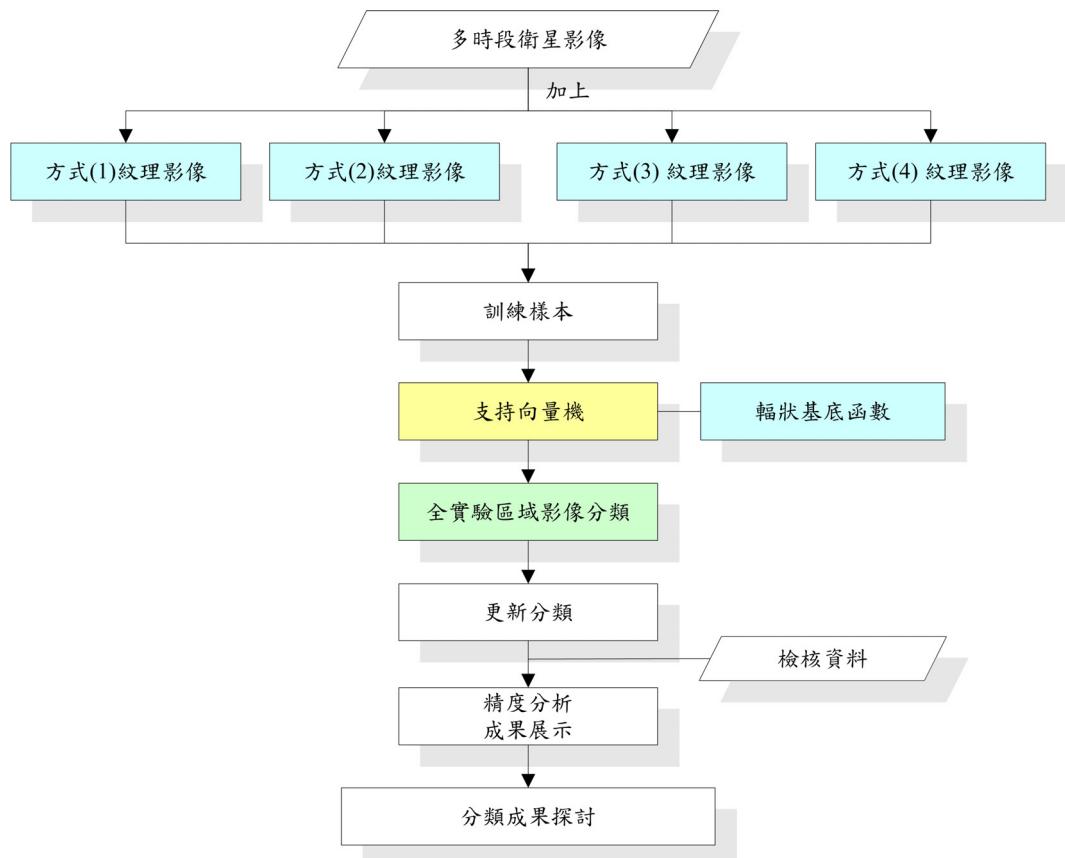


圖 4-11 應用紋理影像輔助支持向量機分類之分類流程

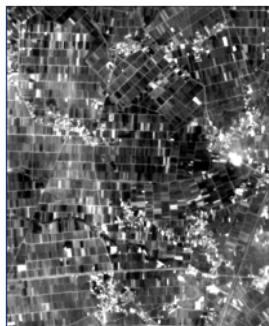
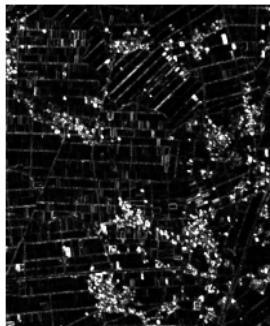
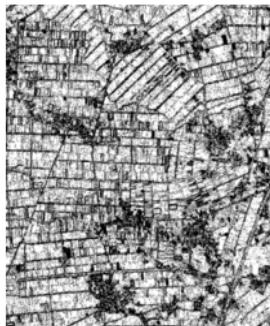
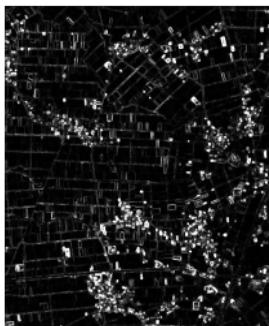
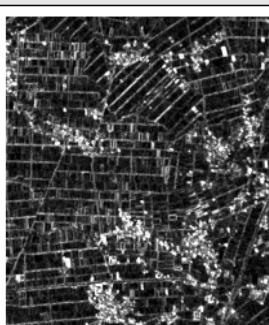
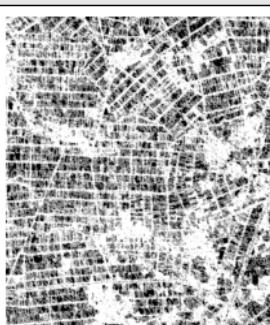
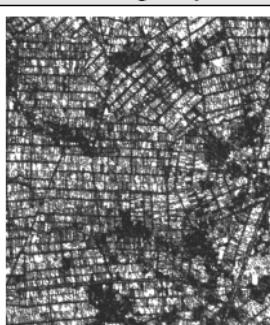
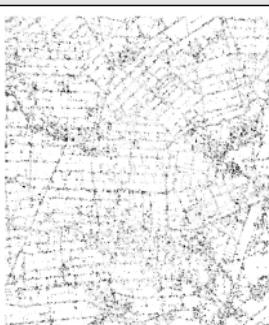
			
Mean	Variance	Homogeneity	Contrast
			
Dissimilarity	Entropy	ASM	Correlation

圖 4-12 8 月 7 日紅光波段之八種紋理影像



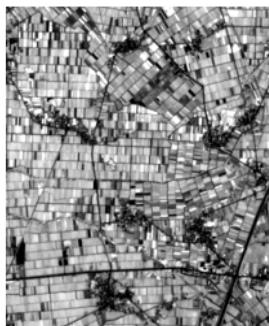
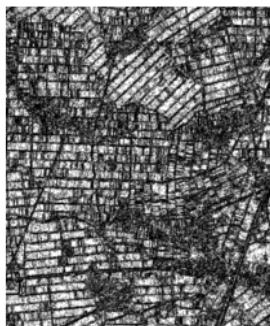
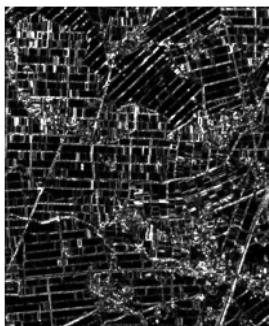
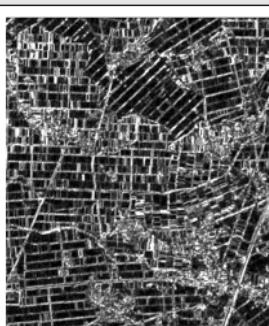
			
Mean	Variance	Homogeneity	Contrast
			
Dissimilarity	Entropy	ASM	Correlation

圖 4-13 10 月 12 日近紅外光波段之八種紋理影像

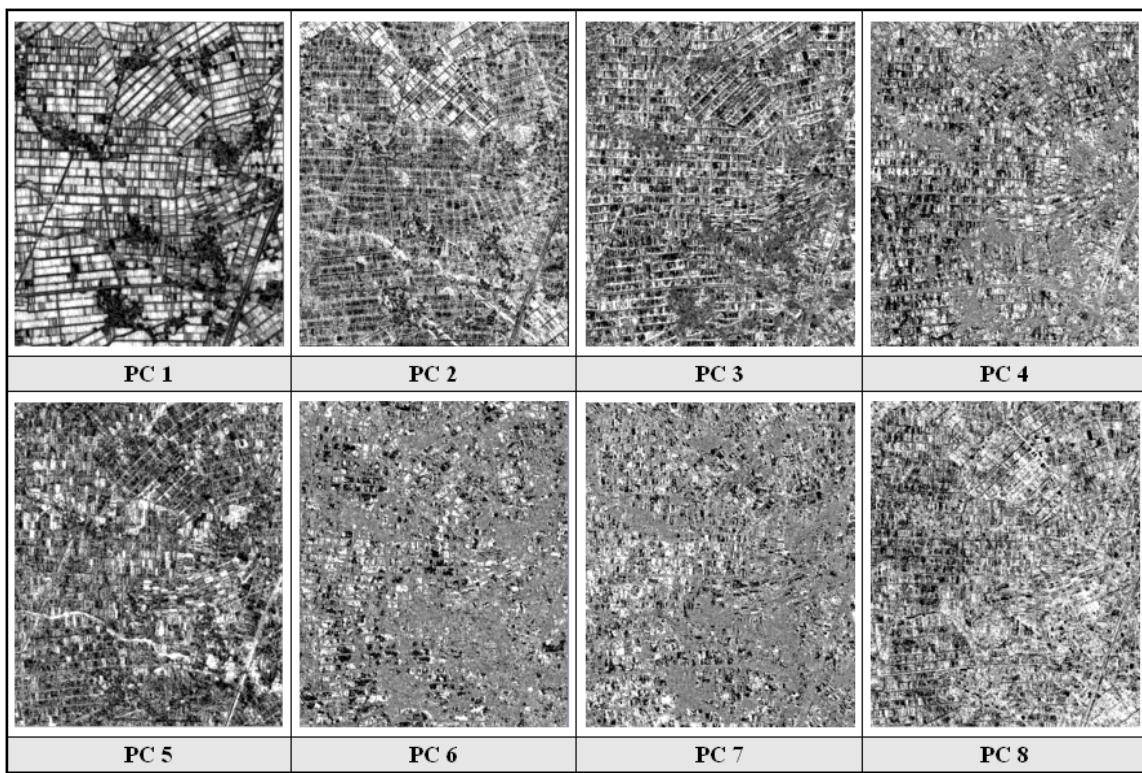


圖 4-14 以 PCA 法取前八主軸-全部波段之八種紋理影像

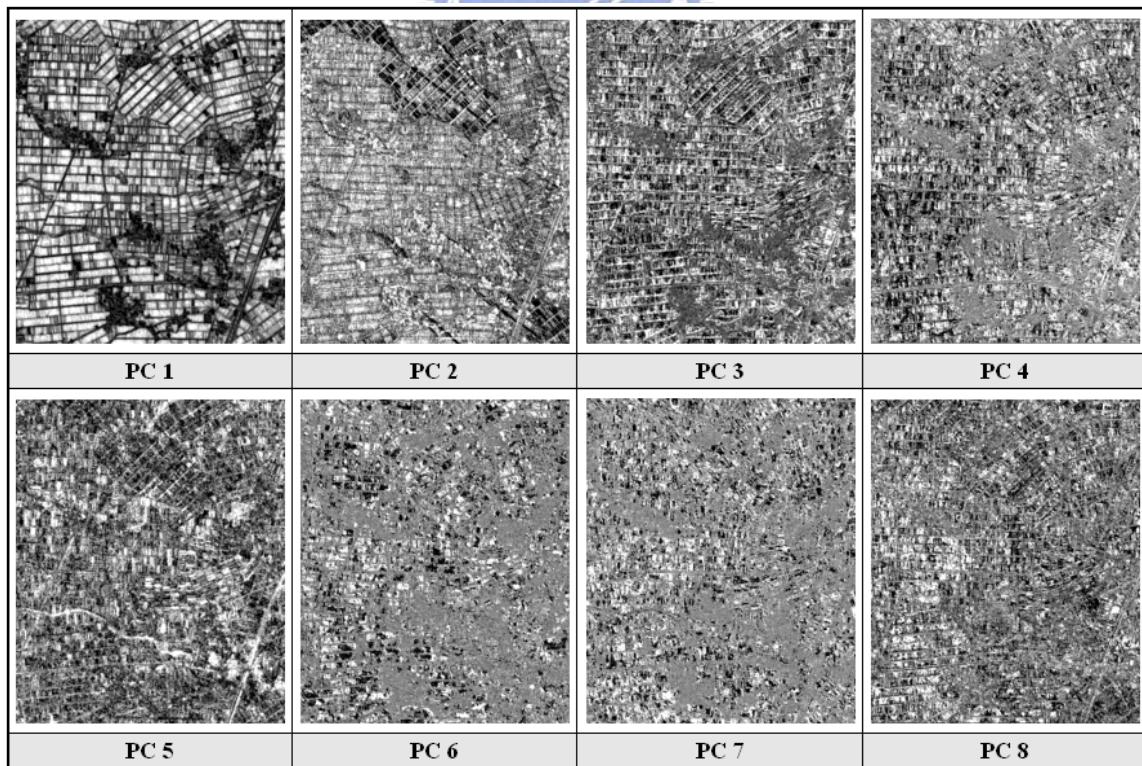


圖 4-15 以 PCA 法取前八主軸-全部波段之五種紋理影像

表 4-8 八種紋理統計量之各主軸資訊量

主軸波段	Eigenvalue
PC 1	62479.784520
PC 2	9755.251681
PC 3	6873.089721
PC 4	6338.230127
PC 5	5060.888723
PC 6	4336.628033
PC 7	4008.042289
PC 8	3955.507640

表 4-9 五種紋理統計量之各主軸資訊量

主軸波段	Eigenvalue
PC 1	60039.359038
PC 2	9108.010864
PC 3	6688.188706
PC 4	6289.828172
PC 5	4572.087939
PC 6	4322.342905
PC 7	3993.163498
PC 8	3672.196023

4-3-2 新竹實驗區

新竹實驗區之分類實驗流程則分為兩個部份，第一部份為以選取的訓練樣本進行不同核函數之支持向量機分類作業，流程同圖 4-9；第二部份則為各分類理論之分類流程，流程同圖 4-10。

第五章 實驗成果與探討

5-1 嘉義實驗區

嘉義實驗區為使用 Formosat-2 多時段影像進行水稻田辨識實驗，而多時段影像中的 12 月 17 日影像，因屬水稻收成後之影像，其地表覆蓋可能為裸土或改種其它作物，為避免影響整體的分類精度，故在本實驗中不採用該時段影像。Formosat-2 影像，因藍光波段散射能力相較其它波段為強，且不常用於多光譜影像分類作業，故本分類實驗僅使用綠光、紅光及近紅外光波段。嘉義實驗區依各分類實驗流程所得之分類成果及探討，如以下各節所述。各分類實驗所得之誤差矩陣如附錄 A 所示。

5-1-1 高斯最大似然分類法及支持向量機之穩定性分類成果

此分類實驗的支持向量機以輻狀基底函數為核函數，並以數據正規化及參數優化建立分類模式。正規化 (scaling) 亦即將各屬性值依其最小值及最大值按比例縮放至 0-1 間，其優點是益於支持向量的選取及避免數值上的計算問題。參數優化則是以交叉驗證 (Cross-Validation) 的方式選取最佳參數。該項分類成果說明如下：

1. 進行群聚類別合併之分類成果：合併為 2 個群聚類別之分類成果，如表 5-1，於三種訓練樣本集合，皆以支持向量機的分類精度為較佳。合併為 23 個群聚類別之分類成果，如表 5-2，除在增加水稻樣本以高斯最大似然分類法的分類精度較佳外，其餘皆以支持向量機的分類精度為較佳。且由表 5-2 可見，在增加非水稻樣本之實驗中，高斯最大似然分類法之分類精度相對於初始選取樣本之分類精度明顯降低。
2. 未進行群聚類別合併之分類成果：分類成果如表 5-3，38 個群聚類別於三種訓練樣本集合，皆以支持向量機的分類精度為較佳。高斯最大似然分類法之

分類精度於增加非水稻樣本實驗中，相對於初始選取樣本之分類精度同樣明顯降低。

由表 5-1 至 5-3 可見，支持向量機所得最佳分類精度的群聚類別數及訓練樣本集合，為 2 個群聚類別及增加非水稻樣本集合。故於第二部份及第三部份的分類實驗，則採用該群聚類別數及訓練樣本集合作為訓練樣本。第四部份應用紋理影像輔助支持向量機分類的訓練樣本，則以此訓練樣本再加上紋理影像資訊為依據。

表 5-1 2 個群聚類別之分類成果

	增加水稻樣本				初始選取樣本				增加非水稻樣本			
	ML		SVM		ML		SVM		ML		SVM	
C			8					8				8
γ			0.5					0.5				0.5
	PA%	UA%										
水稻	80.876	94.452	91.589	89.032	75.692	95.803	91.607	89.361	74.593	95.922	91.346	90.423
非水稻	93.839	79.096	85.367	88.671	95.700	75.222	85.856	88.749	95.887	74.426	87.454	88.626
交叉 驗證%			100					100				100
OA%	86.520		88.880		84.403		89.103		83.864		89.651	
Kappa	0.73154		0.77286		0.69234		0.77752		0.68228		0.78919	
OA (Overall Accuracy) : 整體精度 PA (Producer's Accuracy) : 生產者精度 UA (User's Accuracy) : 使用者精度												

表 5-2 23 個群聚類別之分類成果

	增加水稻樣本				初始選取樣本				增加非水稻樣本			
	ML		SVM		ML		SVM		ML		SVM	
C			32				32				2	
γ			0.5				0.5				8	
	PA%	UA%										
水稻	88.567	90.790	92.707	87.506	82.749	94.063	92.638	87.669	66.077	96.450	91.333	89.5
非水稻	88.349	85.630	82.834	89.752	93.227	80.647	83.103	89.696	96.846	68.764	86.105	88.454
交叉 驗證%			100				100				100	
OA%	88.472		88.409		87.311		88.487		79.473		89.057	
Kappa	0.76637		0.76214		0.74643		0.76383		0.60114		0.77674	

表 5-3 38 個群聚類別之分類成果

	增加水稻樣本點				初始選取樣本點				增加非水稻樣本點			
	ML		SVM		ML		SVM		ML		SVM	
C			32				8				8	
γ			0.5				0.5				8	
	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%
水稻	87.738	89.881	92.952	86.777	76.810	94.504	93.336	86.870	50.715	97.164	91.080	89.604
非水稻	87.190	84.576	81.631	89.931	94.207	75.802	81.706	90.434	98.081	60.546	86.296	88.180
交叉 驗證%			100				99.8904				100	
OA%	87.500		88.023		84.384		88.272		71.337		88.997	
Kappa	0.74664		0.75379		0.69097		0.75879		0.45563		0.77566	

5-1-2 支持向量機於不同核函數之分類成果

多項式之核函數會因階數的選取，而對分類成果造成影響，故在實驗中從 1 階試驗至 5 階，並以分類成果為最佳的階數作為多項式之階數代表。表 5-4 是以輻狀基底函數、線性及兩層式類神經網路為核函數之分類成果。表 5-5 則是以 1 至 5 階多項式為核函數之分類成果。由表 5-4 及表 5-5 的成果顯示，以 2 階多項式為核函數的支持向量機所得的分類精度為最佳、輻狀基底函數次之，且多項

之分類精度至 2 階後隨階數增加而遞減。

表 5-4 輻狀基底函數、線性及兩層式類神經網路為核函數之分類成果

	RBF-SVM		Linear-SVM		tanh-SVM	
C	8		32768		32768	
γ	0.5				0.001953125	
	PA%	UA%	PA%	UA%	PA%	UA%
水稻	91.346	90.423	84.331	93.530	83.014	94.750
非水稻	87.454	88.626	92.435	81.978	94.035	81.021
交叉驗證%	100		95.6897		95.5172	
OA%	89.651		87.859		87.813	
Kappa	0.78919		0.75661		0.75659	

RBF-SVM：輻狀基底函數為核函數之支持向量機
 Linear-SVM：線性為核函數之支持向量機
 tanh-SVM：兩層式類神經網路為核函數之支持向量機

表 5-5 1 至 5 階多項式為核函數之分類成果

	Poly1-SVM		Poly2-SVM		Poly3-SVM		Poly4-SVM		Poly5-SVM	
C	8192		128		8		2		0.5	
γ	2		0.5		0.5		0.5		0.5	
	PA%	UA%								
水稻	84.296	93.550	91.174	90.846	91.233	90.770	91.315	90.633	91.065	90.805
非水稻	92.463	81.950	88.086	88.500	87.969	88.555	87.761	88.626	88.041	88.370
交叉驗證%	95.8621		100		100		100		100	
OA%	87.852		89.830		89.812		89.768		89.748	
Kappa	0.75649		0.79303		0.79262		0.79165		0.79140	

5-1-3 各分類理論之分類成果

三種類神經網路之網路架構，如表 5-6。粗糙集方法採 Entropy-Based 方法對各屬性數值作離散化，並以 LEM2 演算法求得影像分類時所需的規則。PNN 分為 V1.0 及 V1.3 版本，兩版本皆採用 10 個隱藏神經元及對各屬性值以其最大值及最小值作 5 Triangle bins 模糊化的處理。各分類理論所得之分類成果，如表 5-7，其中以 PNN V1.0 所得之分類精度為最佳，整體精度高達 94%以上；而支

持向量機之分類精度次之，整體精度達 89%以上。圖 5-1 為將各分類理論之分類成果以影像作展示，由各影像可見，誤授及漏授易發生於水稻田坵塊邊緣處。

表 5-6 三種類神經網路之網路架構

	輸入層節點	隱藏層節點	輸出層節點
倒傳遞類神經網路 (BP)	12	25&25	2
學習向量量化類神經網路 (LVQ)	12	20	2
輻狀基底函數類神經網路 (RBF)	12	636	2

表 5-7 各分類理論之分類成果

	BP-NN		LVQ-NN		RBF-NN	
\	PA%	UA%	PA%	UA%	PA%	UA%
水稻	90.424	91.139	93.750	86.623	89.943	90.940
非水稻	88.599	87.707	81.225	90.927	88.379	87.140
OA%	89.629		88.297		89.262	
Kappa	0.78931		0.75903		0.78195	

	ML		RBF-SVM		Rough Set		PNN V1.0		PNN V1.3	
\	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%
水稻	74.593	95.922	91.346	90.423	83.600	92.561	94.236	95.416	90.153	91.010
非水稻	95.887	74.426	87.454	88.626	91.287	81.104	94.129	92.643	88.452	87.384
OA%	83.864		89.651		86.947		94.189		89.412	
Kappa	0.68228		0.78919		0.73826		0.88203		0.78495	

5-1-4 紋理影像輔助支持向量機分類之分類成果

本研究應用紋理影像輔助支持向量機分類共探討四種方式。各方式的支持向量機皆以輻狀基底函數、數據正規化及參數優化建立分類模式。各方式所得之分類成果如下所述：

1. 8月7日紅光波段之八種紋理影像分類成果

分類成果如表 5-8，該波段所生成的八種紋理影像，以加入 ASM 紹理影像對分類精度的提升為最佳，其它具有提升分類精度的紹理影像分別為 Variance、Contrast、Dissimilarity 及 Correlation。

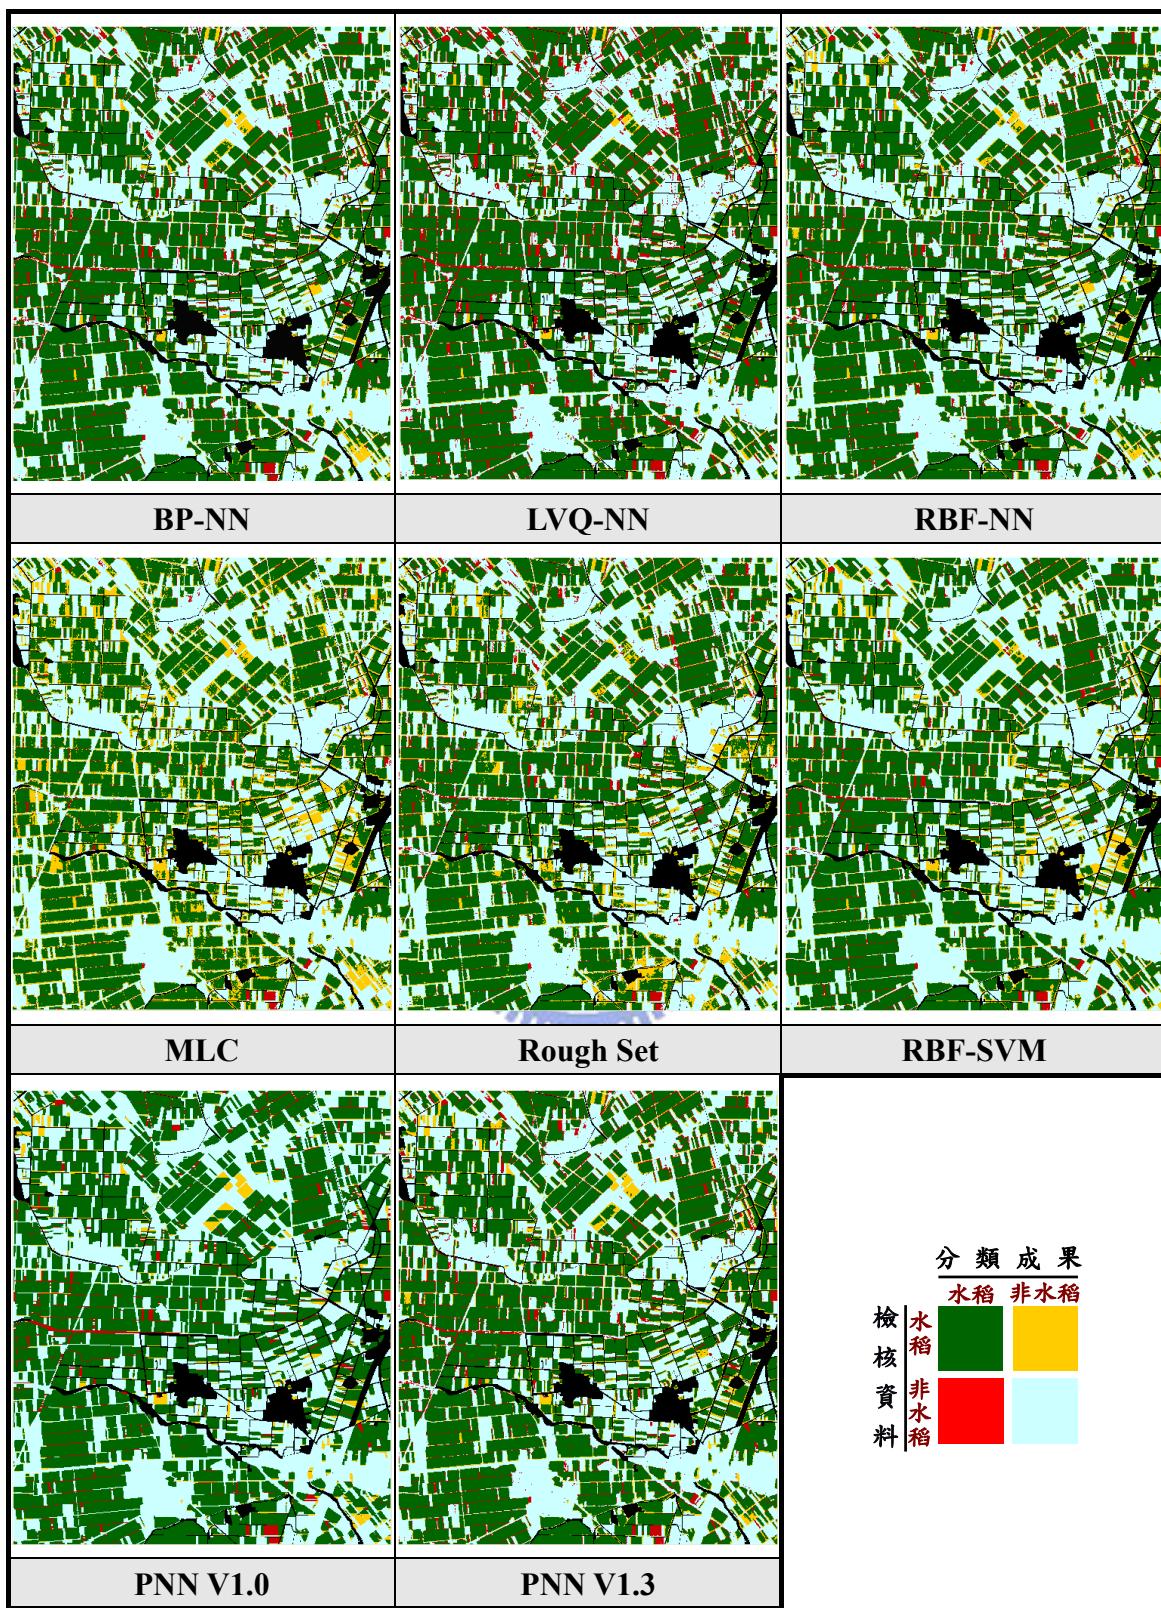


圖 5-1 各分類理論之分類成果影像

表 5-8 8 月 7 日紅光波段之八種紋理影像分類成果

	Original		Original+ All Texture		Original+ Mean		Original+ Variance		Original+ Homogeneity	
C	8		8192		8		8		32	
γ	0.5		0.03125		0.5		0.5		0.5	
	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%
水稻	91.346	90.423	88.305	91.073	91.339	90.356	91.334	90.456	89.705	91.253
非水稻	87.454	88.626	88.774	85.408	87.358	88.607	87.504	88.618	88.849	86.937
交叉 驗證%	100		100		100		100		100	
OA%	89.651		88.509		89.605		89.666		89.332	
Kappa	0.78919		0.76733		0.78824		0.78951		0.78357	

	Original+ Contrast		Original+ Dissimilarity		Original+ Entropy		Original+ ASM		Original+ Correlation	
C	8		8		32		8		8	
γ	0.5		0.5		0.5		0.5		0.5	
	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%
水稻	91.316	90.472	90.984	90.737	92.559	89.285	91.701	90.233	90.905	90.864
非水稻	87.529	88.600	87.954	88.267	85.596	89.868	87.127	89.005	88.147	88.199
交叉 驗證%	100		100		100		100		100	
OA%	89.667		89.665		89.527		89.710		89.705	
Kappa	0.78954		0.78970		0.78582		0.79019		0.79058	

2. 10 月 12 日近紅外光波段之八種紋理影像分類成果

該實驗分類成果如表 5-9，其中該波段所生成的八種紋理影像，以加入 Variance 紋理影像對分類精度的提升為最佳，其它具有提升分類精度的紋理影像分別為 Contrast 及 ASM。

表 5-9 10 月 12 日近紅光波段之八種紋理影像分類成果

	Original		Original+ All Texture		Original+ Mean		Original+ Variance		Original+ Homogeneity	
C	8		128		8		8		32	
γ	0.5		0.5		0.5		0.5		0.5	
	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%
水稻	91.346	90.423	85.369	93.022	90.879	89.946	89.997	91.832	85.650	93.804
非水稻	87.454	88.626	91.695	82.855	86.826	88.011	89.619	87.355	92.664	83.276
交叉 驗證%	100		100		100		100		100	
OA%	89.651		88.123		89.115		89.832		88.704	
Kappa	0.78919		0.76134		0.77825		0.79381		0.77316	

	Original+ Contrast		Original+ Dissimilarity		Original+ Entropy		Original+ ASM		Original+ Correlation	
C	8		8		8		8		8	
γ	0.5		0.5		0.5		0.5		0.5	
	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%
水稻	89.904	91.658	82.438	94.161	88.840	92.524	89.625	91.878	91.201	90.377
非水稻	89.388	87.224	93.370	80.391	90.691	86.238	89.725	86.960	87.406	88.453
交叉 驗證%	100		100		100		100		100	
OA%	89.679		89.197		89.646		89.669		89.549	
Kappa	0.79068		0.74432		0.79064		0.79062		0.78714	

3. 全部波段之八種紋理影像並以 PCA 法取前八主軸波段之分類成果

分類成果如表 5-10，該方式所選取的前八主軸紋理影像，以加入 PC5 紋理影像對分類精度的提升為最佳，其它具有提升分類精度的紋理影像分別為 PC4、PC7 及 PC8。

表 5-10 全部波段之八種紋理影像並以 PCA 法取前八主軸之分類成果

	Original		Original+ All PC		Original+ PC1		Original+ PC2		Original+ PC3	
C	8		8		8		32		32	
γ	0.5		0.5		0.5		0.5		0.5	
	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%
水稻	91.346	90.423	69.861	97.192	78.443	95.765	90.410	90.404	91.691	89.886
非水稻	87.454	88.626	97.382	71.359	95.501	77.356	87.555	87.562	86.621	88.937
交叉 驗證%	100		100		100		100		100	
OA%	89.651		81.843		85.870		89.167		89.484	
Kappa	0.78919		0.64549		0.72011		0.77965		0.78546	

	Original+ PC4		Original+ PC5		Original+ PC6		Original+ PC7		Original+ PC8	
C	8		8		32		8		8192	
γ	0.5		0.5		0.5		0.5		0.03125	
	PA%	UA%								
水稻	91.378	90.563	91.301	90.933	91.304	90.427	91.479	90.342	91.333	90.520
非水稻	87.651	88.686	88.193	88.660	87.465	88.579	87.318	88.767	87.596	88.628
交叉 驗證%	100		100		100		100		99.9138	
OA%	89.755		89.948		89.632		89.668		89.706	
Kappa	0.79135		0.79543		0.78882		0.78945		0.79034	

4. 全部波段之五種紋理影像並以 PCA 法取前八主軸波段之分類成果

分類成果如表 5-11，該方式所選取之前八主軸紋理影像，以加入 PC5 紋理影像對分類精度的提升為最佳，其它具有提升分類精度的紋理影像分別為 PC4、PC7 及 PC8。

表 5-11 全部波段之五種紋理影像並以 PCA 法取前八主軸之分類成果

	Original		Original+ All PC		Original+ PC1		Original+ PC2		Original+ PC3	
C	8		2		8		32		8	
γ	0.5		2		0.5		0.5		0.5	
	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%
水稻	91.346	90.423	70.595	97.111	77.303	95.942	90.567	90.250	91.840	89.821
非水稻	87.454	88.626	97.277	71.838	95.760	76.489	87.312	87.711	86.503	89.100
交叉 驗證%	100		100		100		100		100	
OA%	89.651		82.212		85.339		89.150		89.517	
Kappa	0.78919		0.65228		0.71015		0.77920		0.78606	

	Original+ PC4		Original+ PC5		Original+ PC6		Original+ PC7		Original+ PC8	
C	8		8		32		8		32	
γ	0.5		0.5		0.5		0.5		0.5	
	PA%	UA%								
水稻	91.351	90.558	91.635	90.525	91.317	90.435	91.540	90.282	90.495	91.328
非水稻	87.649	88.655	87.561	88.976	87.475	88.596	87.222	88.827	88.857	87.818
交叉 驗證%	100		100		100		100		100	
OA%	89.739		89.861		89.644		89.660		89.782	
Kappa	0.79102		0.79340		0.78906		0.78925		0.79245	

5-1-5 成果分析與探討

1. 高斯最大似然分類法及支持向量機之穩定性探討

以 Z-Test 檢定不同群聚類別數在相同分類方法及訓練樣本集合，是否具有顯著性，以 95%為信心水準，若兩模式間 Z 值大於 1.96，則代表兩者間具有顯著性，各模式間的 Z 值，如表 5-12。於高斯最大似然分類法，2 個群聚類別和 38 個群聚類別在初始選取訓練樣本集合，其 Z 值小於 1.96，故兩者間不具有顯著性；而於支持向量機，23 個群聚類別和 38 個群聚類別在增加非水稻訓練樣本

集合，兩者間也不具有顯著性。

若以整體精度及 Kappa 指標比較兩分類方法之差異，如圖 5-2 及圖 5-3。支持向量機於不同群聚類別數及訓練樣本集合，其分類成果變動皆較高斯最大似然分類法為小，並不因群聚類別數或訓練樣本集合之改變而有大幅的變化，變動約在 1% 以內，故支持向量機的穩定性較佳。

支持向量機較為穩定的原因，為不同群聚類別數或訓練樣本集合，皆會影響高斯最大似然分類法之各群聚類別的機率密度函數計算；而支持向量機的分類原理，則是尋求各群聚類別間具有最大邊界的區分超平面，唯有在區分超平面上的支持向量才會進入模式中作運算，而非採用所有的訓練樣本。故群聚類別合併與否及不同訓練樣本集合對支持向量機的影響較小。訓練樣本是否符合常態分佈之假設，也是造成高斯最大似然分類法之分類成果變動較大的原因之一。

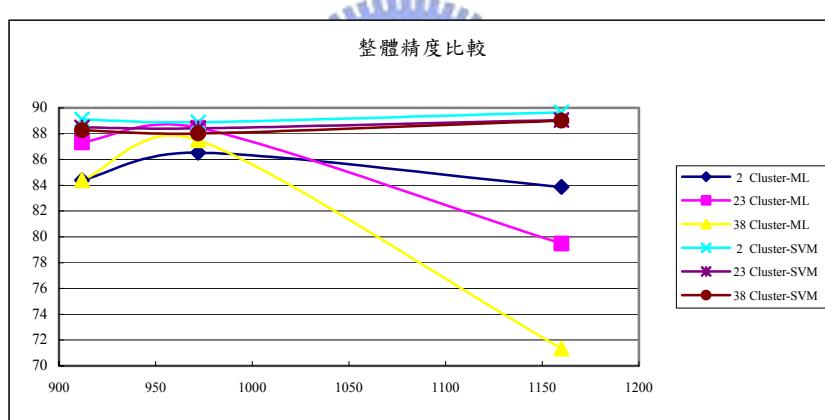


圖 5-2 整體精度比較

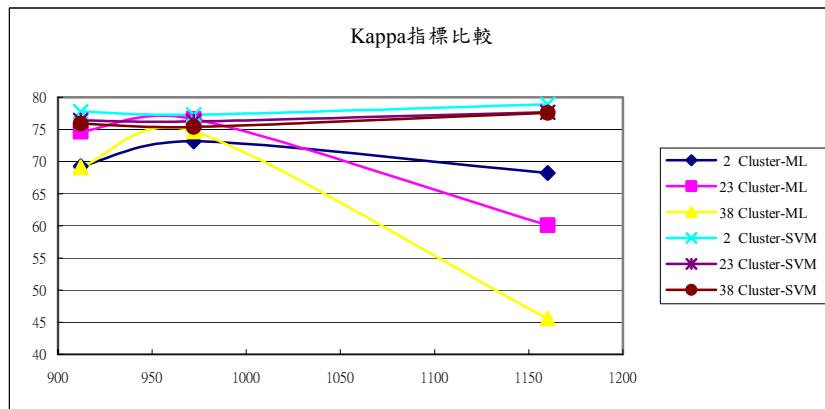


圖 5-3 Kappa 指標比較

表 5-12 不同群聚類別數於相同分類方法及訓練樣本集合之 Z-Test

2. 支持向量機於不同核函數之分類成果探討

以 Z-Test 檢定不同核函數之支持向量機的分類成果是否具有顯著性，各模式間的 Z 值，如表 5-13。其中，線性、兩層式類神經網路及 1 階多項式，各兩者間不具有顯著性；輻狀基底函數、4 階多項式及 5 階多項式，各兩者間不具有

顯著性；2 階多項式、3 階多項式、4 階多項式及 5 階多項式，各兩者間並不具有顯著性。

由表 5-4 及表 5-5 可知，以採用二階多項式為核函數的支持向量機，所得的分類成果為最佳，輻狀基底函數次之，且由 Z-test 檢定，兩者間是具有顯著性的。在本研究中，較不適合以線性及兩層式類神經網路之核函數，將訓練樣本映射至高維度的空間，因其兩者分類精度相較多項式及輻狀基底函數為差。

表 5-13 支持向量機於不同核函數之 Z-Test

	RBF-SVM	Linear-SVM	tanh-SVM	Poly1-SVM	Poly2-SVM	Poly3-SVM	Poly4-SVM	Poly5-SVM
RBF-SVM		19.033	19.045	19.104	2.311	2.064	1.480	1.330
Linear-SVM			0.011	0.068	21.363	21.122	20.553	20.407
tanh-SVM				0.057	21.374	21.134	20.565	20.418
Poly1-SVM					21.433	21.193	20.624	20.477
Poly2-SVM						0.248	0.834	0.985
Poly3-SVM							0.586	0.737
Poly4-SVM								0.151
Poly5-SVM								

3. 各分類理論之分類成果探討

以 Z-Test 檢定各分類理論所建立的分類模式是否具有顯著性，各模式間的 Z 值，如表 5-14。其中，倒傳遞類神經網路與輻狀基底函數為核心的支持向量機，兩者間不具有顯著性；輻狀基底函數類神經網路與 PNN V1.3，兩者間不具有顯著性。

由表 5-7 得知，PNN V1.0 所得的分類精度為最佳，整體達 94%以上，高出精度次佳的支持向量機約 4%以上，且以 Z-Test 檢定，其和各分類方法間具有顯著性。PNN V1.0 相較 V1.3，其整體精度也高出約 4%以上，由此可見樣本屬性間及其鄰近樣本間所包含的資訊，對影像辨識上有極大的助益。因分類實驗是以多時段影像為資料來源，故樣本各屬性間有其關聯性存在，而群聚類別的訓練樣本是以矩形區塊作選取，故鄰近樣本間也具有某些資訊存在，因此若考量這些關

聯及資訊將有助於辨識作業。

支持向量機、三種類神經網路模式及 PNN V1.3，各分類所得之整體精度差約在 1.5% 以內，因類神經網路若能謹慎的選取網路架構，其分類能力將能相似於支持向量機，但類神經網路具有無法對其網路權重進行解釋的缺點。粗糙集方法所得的分類成果僅優於高斯最大似然分類法，可能的原因為訓練樣本的取樣不足以代表實驗區的整體情形，而導致攫取的規則不完全，故無法獲取良好的分類成果。高斯最大似然分類法的分類成果為最差，可能的原因為選取的訓練樣本不符合常態分佈假設，故以下將對訓練樣本進行常態分佈檢定。

訓練樣本以 K-S (Kolmogorov-Smirnov) 法作常態分佈檢定，K-S 檢定法說明如下：

$$\begin{cases} H_0 : \text{資料服從常態分佈} \\ H_1 : \text{資料不服從常態分佈} \end{cases}$$

在顯著水準為 0.05 情況下，若 p 值小於 0.05，則 H_0 為顯著，故拒絕 H_0 ，即訓練樣本不服從常態分佈。檢定結果，訓練樣本於各波段的 P 值皆為零，故訓練樣本不服從常態分佈。

表 5-14 各分類理論之 Z-Test

	ML	BP-NN	LVQ-NN	RBF-NN	RBF-SVM	Rough Set	PNN V1.0	PNN V1.3
ML		59.408	41.384	54.925	59.128	29.857	121.860	56.783
BP-NN			17.686	4.410	0.072	29.438	62.814	2.624
LVQ-NN				13.280	17.545	11.609	79.855	15.079
RBF-NN					4.320	24.998	67.077	1.790
RBF-SVM						29.255	62.559	2.541
Rough Set							91.881	26.819
PNN V1.0								65.416
PNN V1.3								

4. 紋理影像輔助支持向量機分類之成果探討

先以 Z-Test 檢定各紋理影像的加入是否對分類精度的提升具有顯著性，說

明如下：

(1) 8月7日紅光波段之八種紋理影像：各紋理影像間的Z值，如表5-15。

與表5-8作比對，加入8月7日紅光波段之各紋理統計量對分類精度的提升不具有顯著性。

(2) 10月12日近紅外光波段之八種紋理影像：各紋理影像間的Z值，如表5-16。與表5-9作比對，以加入Variance紋理統計量對分類精度的提升具有顯著性。

(3) 全部波段之八種紋理影像並以PCA法取前八主軸波段影像：各紋理影像間的Z值，如表5-17。與表5-10作比對，加入PC5紋理影像對分類精度的提升具有顯著性。

(4) 全部波段之五種紋理影像並以PCA法取前八主軸波段影像：各紋理影像間的Z值，如表5-18。與表5-11作比對，加入PC5及PC8紋理影像對分類精度的提升具有顯著性。

由表5-8至表5-11及上述Z-test檢定結果可見，以加入第(3)方式的PC5紋理影像所能提升的分類精度為最高，但相對於原始光譜影像其整體精度僅提高約0.3%，提升成效相當有限。紋理影像的生成方式除與選取的紋理統計量相關外，還受到取樣視窗大小、取樣方向及灰階範圍之因素影響，故選取對辨識作業具有助益的紋理影像是有相當困難性存在。

由表5-8和表5-9得知，能提升分類精度的紋理統計量於不同波段中皆不相同。故第(3)及(4)方式即針對全部波段取紋理統計量，差異為第(3)方式取8種紋理統計量，第(4)方式取5種，兩方式並以主成份分析法取前八主軸波段影像。且由表5-10和表5-11得，含有最多資訊量的第一主軸，其分類精度反較其它主軸為差，由此得知，含有最多資訊量的主軸並非能提供最有效的資訊於辨識作業。

表 5-15 8 月 7 日紅光波段之各紋理影像間之 Z-Test

	1	2	3	4	5	6	7	8	9	10
1		12.879	0.569	0.192	3.354	0.210	0.307	2.011	0.602	0.836
2			12.320	13.068	9.529	13.086	13.234	10.849	13.524	13.755
3				0.761	2.787	0.779	0.879	1.444	1.173	1.408
4					3.544	0.018	0.114	2.202	0.409	0.644
5						3.562	3.673	1.337	3.967	4.201
6							0.096	2.220	0.391	0.626
7								2.325	0.296	0.532
8									2.619	2.852
9										0.236
10										

1:Original 2:Original+ All Texture 3:Original+Mean 4:Original+Variance

5:Original+Homogeneity 6: Original+Contrast 7: Original+Dissimilarity

8: Original+Entropy 9: Original+ASM 10: Original+Correlation

表 5-16 10 月 12 日近紅外光波段之各紋理影像間之 Z-Test

	1	2	3	4	5	6	7	8	9	10
1		16.339	6.500	2.792	9.525	0.897	25.992	0.873	0.861	1.228
2			9.841	19.205	6.878	17.283	9.666	17.260	17.248	15.136
3				9.323	2.999	7.417	19.500	7.393	7.381	5.282
4					12.373	1.900	28.897	1.924	1.936	4.031
5						10.454	16.575	10.430	10.418	8.307
6							26.962	0.024	0.036	2.130
7								26.939	26.927	24.805
8									0.012	2.106
9										2.094
10										

1:Original 2:Original+ All Texture 3:Original+Mean 4:Original+Variance

5:Original+Homogeneity 6: Original+Contrast 7: Original+Dissimilarity

8: Original+Entropy 9: Original+ASM 10: Original+Correlation

表 5-17 全部波段之八種紋理影像並以 PCA 法取前八主軸-紋理影像間之 Z-Test

	1	2	3	4	5	6	7	8	9	10
1		77.508	39.181	5.669	2.226	1.300	3.771	0.222	0.156	0.692
2			38.477	71.867	75.237	78.944	81.430	77.309	77.649	78.397
3				33.515	36.925	40.560	43.046	38.971	39.329	39.985
4					3.438	6.981	9.455	5.449	5.823	6.378
5						3.529	5.999	2.005	2.381	2.924
6							2.476	1.523	1.143	0.610
7								3.995	3.614	3.089
8									0.378	0.915
9										0.536
10										

1:Original 2:Original+ All PC 3:Original+ PC1 4:Original+ PC2
 5:Original+ PC3 6:Original+ PC4 7:Original+ PC5
 8:Original+ PC6 9:Original+ PC7 10:Original+ PC8

表 5-18 全部波段之五種紋理影像並以 PCA 法取前八主軸-各紋理影像之 Z-Test

	1	2	3	4	5	6	7	8	9	10
1		74.154	44.454	5.936	1.868	1.101	2.534	0.078	0.036	1.962
2			29.744	68.268	72.208	75.406	76.699	74.084	74.186	76.183
3				38.547	42.535	45.654	46.997	44.381	44.488	46.461
4					4.059	7.053	8.473	5.859	5.972	7.906
5						2.972	4.398	1.790	1.904	3.829
6							1.438	1.180	1.065	0.864
7								2.612	2.497	0.574
8									0.114	2.040
9										1.926
10										

1:Original 2:Original+ All PC 3:Original+ PC1 4:Original+ PC2
 5:Original+ PC3 6:Original+ PC4 7:Original+ PC5
 8:Original+ PC6 9:Original+ PC7 10:Original+ PC8

5-2 新竹實驗區

新竹實驗區採用 SPOT 多時段影像進行辨識作業，多時段影像中的 7 月 25 日影像因屬水稻收成後之影像，故相同於嘉義實驗區不採用該時段影像。新竹實驗區所得之分類成果及探討如下所述。各分類實驗之誤差矩陣如附錄 B 所示。

5-2-1 支持向量機於不同核函數之分類成果

表 5-19 分別是以輻狀基底函數、線性及兩層式類神經網路為核函數之分類成果。多項式為核函數之支持向量機從 1 階試驗至 6 階後，其整體精度才開始往下下降，如表 5-20。由表 5-19 及表 5-20 成果顯示，以輻狀基底函數為核函數的分類精度為最佳、5 階多項式次之。

表 5-19 輻狀基底函數、線性及兩層式類神經網路為核函數之分類成果

	RBF-SVM		Linear-SVM		tanh-SVM	
C	128		128		2048	
γ	0.5				0.03125	
	PA%	UA%	PA%	UA%	PA%	UA%
水稻	85.259	90.595	76.726	92.985	77.107	93.118
非水稻	84.516	76.621	89.874	68.821	90.031	69.212
交叉驗證%	100		99.4841		99.4841	
OA%	84.989		81.508		81.808	
Kappa	0.68269		0.62504		0.63074	

表 5-20 1 至 6 階多項式為核函數之分類成果

	Poly1-SVM		Poly2-SVM		Poly3-SVM		Poly4-SVM		Poly5-SVM		Poly6-SVM	
C	32768		512		128		32		32		512	
γ	0.0078125		0.5		0.5		0.5		0.5		0.125	
	PA%	UA%										
水稻	76.263	92.881	82.272	91.309	83.711	91.089	82.692	91.349	83.134	91.253	82.677	91.331
非水稻	89.775	68.373	86.300	73.563	85.674	75.040	86.298	74.024	86.060	74.468	86.272	74.005
交叉 驗證%	99.5701		100		100		100		100		100	
OA%	81.177		83.737		84.004		84.198		84.425		83.985	
Kappa	0.61889		0.66120		0.66624		0.66961		0.67341		0.00207	

5-2-2 各分類理論之分類成果

三種類神經網路之網路架構，如表 5-21。粗糙集方法同嘉義實驗區採用 Entropy-Based 方法對各屬性值作離散化，並以 LEM2 演算法求得分類時所需的規則。PNN 在兩版本中皆採用 10 個隱藏神經元及對各屬性值以其最大值及最小值作 5 Triangle bins 模糊化的處理。

各分類理論所得的分類成果，如表 5-22。其中，以 PNN V1.0 所得的分類精度為最佳，整體精度高達 91%以上；而學習向量量化類神經網路在本實驗區中，其分類精度較支持向量機為佳。圖 5-4 為將各分類理論之分類成果以影像作展示。

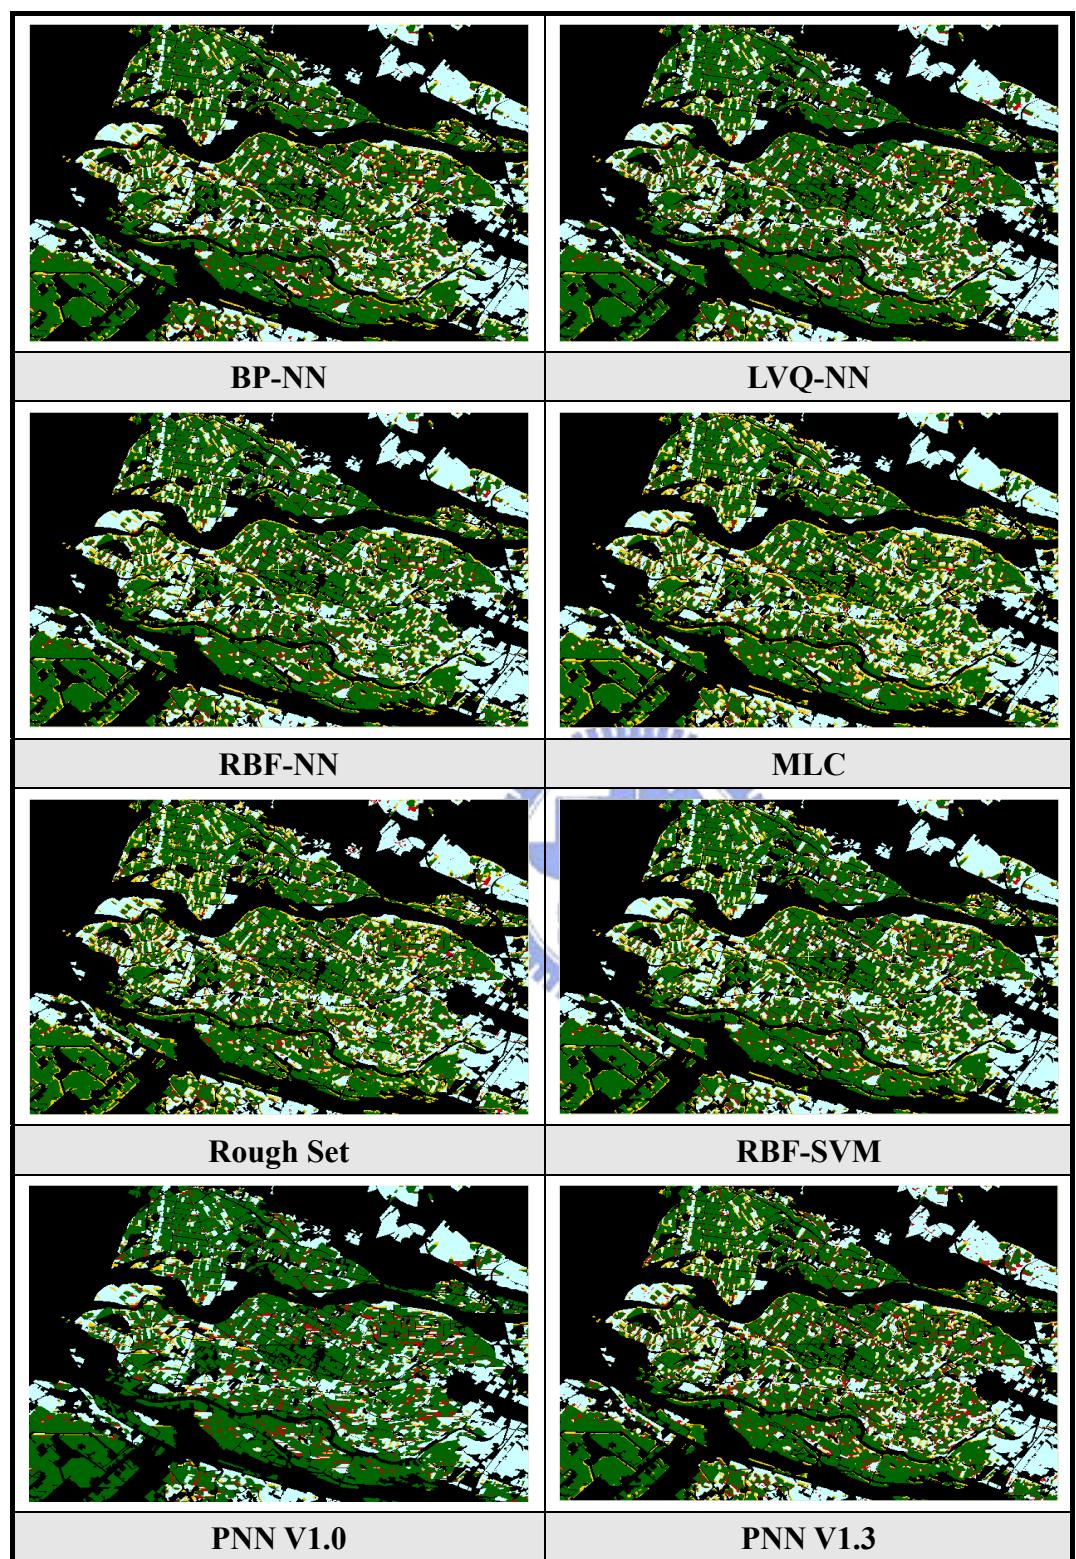
表 5-21 三種類神經網路之網路架構

	輸入層節點	隱藏層節點	輸出層節點
倒傳遞類神經網路 (BP)	12	30&30	2
學習向量量化類神經網路 (LVQ)	12	35	2
輻狀基底函數類神經網路 (RBF)	12	672	2

表 5-22 各分類理論之分類成果

	BP-NN		LVQ-NN		RBF-NN	
	PA%	UA%	PA%	UA%	PA%	UA%
水稻	84.729	89.842	87.925	84.729	89.842	87.925
非水稻	83.240	75.704	81.420	83.240	75.704	81.420
OA%	84.188		85.925		84.321	
Kappa	0.6655		0.68969		0.67190	

	ML		RBF-SVM		Rough Set		PNN V1.0		PNN V1.3	
	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%	PA%	UA%
水稻	76.129	80.059	85.259	90.595	80.059	89.665	95.391	0.963	87.484	88.000
非水稻	87.714	83.856	84.516	76.621	83.856	70.620	83.422	1.185	79.129	78.327
OA%	80.343		84.989		81.440		91.037		84.4445	
Kappa	0.60052		0.68269		0.61448		0.80276		0.66468	



分類成果		
	水稻	非水稻
檢核資料	水稻	非水稻
	非水稻	水稻

圖 5-4 各分類理論之分類成果影像

5-2-3 成果分析與探討

1. 支持向量機於不同核函數之分類成果探討

以 Z-Test 檢定不同核函數之支持向量機的分類成果是否具有顯著性，各模式間的 Z 值，如表 5-23。其中，線性及兩層式類神經網路，兩者間不具有顯著性；2 階多項式、3 階多項式及 6 階多項式，各兩者間不具有顯著性；3 階多項式、4 階多項式及 6 階多項式，各兩者間不具有顯著性；4 階多項式及 5 階多項式，兩者間不具有顯著性。

多項式之階數實驗，相對於嘉義實驗區，新竹實驗區需試驗至 5 階才具有最佳成果，而嘉義實驗區僅 2 階就獲致最佳成果，由此可見，新竹實驗區的土地覆蓋複雜度較嘉義實驗區為高。線性及兩層式類神經網路之核函數，由成果可見，相同於嘉義實驗區，較不適用於水稻田辨識之研究。

表 5-23 支持向量機於不同核函數之 Z-Test

	RBF-SVM	Linear-SVM	tanh-SVM	Poly1-SVM	Poly2-SVM	Poly3-SVM	Poly4-SVM	Poly5-SVM	Poly6-SVM
RBF-SVM		19.501	17.616	21.476	7.359	5.646	4.490	3.193	5.780
Linear-SVM			1.897	2.032	12.146	13.871	15.006	16.324	13.740
tanh-SVM				3.925	10.256	11.981	13.119	14.435	11.850
Poly1-SVM					14.144	15.865	16.994	18.310	15.734
Poly2-SVM						1.717	2.866	4.171	1.585
Poly3-SVM							1.151	2.455	0.133
Poly4-SVM								1.301	1.284
Poly5-SVM									2.589
Poly6-SVM									

2. 各分類理論之分類成果探討

以 Z-Test 檢定各分類理論所建立的分類模式是否具有顯著性，各模式間的 Z 值，如表 5-24。表中，倒傳遞類神經網路與 PNN V1.3，兩者間不具有顯著性。

相同於嘉義實驗區，以 PNN V1.0 所得的分類精度為最佳，整體精度達 91% 以上，高出精度次佳的學習向量量化類神經網路約 6% 以上，且由 Z-Test 檢定結

果得知，其和各分類理論間具有顯著性。同樣是因考量樣本屬性間及鄰近樣本間之資訊，而使得 PNN V1.0 相對於其它分類理論具有較高的分類精度。

新竹實驗區同樣反應支持向量機與類神經網路之分類成果近似，且學習向量量化類神經網路所得的成果相較支持向量機為佳，但兩者差距在 1% 以內，很難界定其原因為何。在此，相同於嘉義實驗區對訓練樣本作常態分佈檢定，檢定結果為訓練樣本在各波段中皆不符合常態分佈，故高斯最大似然分類法所得之分類成果較不佳。粗糙集方法所得之分類成果也僅優於高斯最大似然分類法，可能與選取的訓練樣本及所採用的模式有關。

表 5-24 各分類理論之 Z-Test

	ML	BP-NN	LVQ-NN	RBF-NN	RBF-SVM	Rough Set	PNN V1.0	PNN V1.3
ML		21.465	29.726	23.741	27.392	4.507	72.948	21.050
BP-NN			8.263	2.181	5.872	16.854	50.949	0.275
LVQ-NN				6.121	2.415	25.072	42.457	8.481
RBF-NN					3.713	19.098	48.995	2.442
RBF-SVM						22.738	45.085	6.107
Rough Set							67.913	16.470
PNN V1.0								50.813
PNN V1.3								

第六章 結論與建議

本研究主要是以支持向量機及 Plausible Neural Network 對多時段影像進行水稻田辨識作業，並和高斯最大似然分類法、倒傳遞類神經網路、學習向量量化類神經網路、輻狀基底函數類神經網路及粗糙集方法所得之分類成果作比對。經由兩組實驗數據之實驗成果與分析探討，得出以下的結論與建議：

1. 支持向量機於分類模式的建立，主要是以區分超平面上的支持向量為依據，並非對所有的訓練樣本進行運算，且區分超平面必須滿足具最大邊界的限制，故不同群聚類別數及訓練樣本集合對其影響較小。高斯最大似然分類法則會以所有訓練樣本進行機率密度函數計算，造成其分類精度的變動較大，且訓練樣本是否為常態分佈，也會對其分類成果造成影響。故支持向量機的穩定性較高斯最大似然分類法為佳。
2. 支持向量機於不同核函數之分類成果，在嘉義實驗區以 2 階多項式之分類成果為最佳，輻狀基底函數次之；新竹實驗區則以輻狀基底函數之分類成果為最佳，5 階多項式次之。線性及兩層式類神經網路則相對於前述兩者較不適用於本研究。在多項式之階數試驗中，新竹實驗區需試驗至 5 階才具有最佳成果，而嘉義實驗區僅 2 階即可求得，故以此推斷新竹實驗區之地表覆蓋較嘉義實驗區為複雜。可藉由比對兩實驗區之影像得到驗證。
3. PNN V1.0 於兩實驗區中，皆具有最佳的分類成果，在嘉義實驗區其整體精度達 94% 以上，比成果次之的支持向量機高出 4% 以上；在新竹實驗區其整體精度達 91% 以上；比成果次之的學習向量量化類神經網路高出 6% 以上。其 Kappa 指標在兩實驗區皆高達 0.8 以上，為不錯的分類器。PNN V 1.0 能優於其它分類方法為多加考量訓練樣本縱向及橫向間的關聯性，縱向即是鄰近樣本間的關係，橫向則是樣本屬性間的關係。遙測影像的訓練樣本選取是以矩形區塊為依據，故縱向關係存在；而樣本的屬性為多時段影像上的波段，波段間具有水稻

於不同生育階段的資訊，故橫向關係也存在，而這些因素將使其具有較佳的分類成果。相對未考量這些因素的 PNN V 1.3，其所獲得的分類成果則相近於支持向量機、倒傳遞類神經網路、學習向量量化類神經網路及輻狀基底函數類神經網路。

4. 紋理影像輔助支持向量機分類，由成果得知，加入四種方式所生成的紋理影像，皆對分類精度的提升成效有限，且某些紋理影像的加入，甚至降低原有的分類精度。分類精度的提升成效有限，可能是因紋理影像之參數選用不適當而導致，因紋理影像的生成與取樣視窗大小、取樣方向、灰階範圍及選用的紋理統計量相關，故不易選出具有助益的紋理影像；亦可能是因衛星影像的像元解析度較大，而導致萃取的紋理特徵效果不佳。
5. 新竹實驗區所採用的多時段影像為 SPOT 影像，其影像解析力為 12.5 公尺，相較 Formosat-2 影像之 8 公尺解析力為大，且由影像可見，新竹實驗區的土地覆蓋類型較嘉義實驗區為複雜且其水稻田坵塊也較不規則。上述有可能是造成該區分類成果相較嘉義實驗區為差的原因，而訓練樣本的選取優劣，也可能是造成該區分類精度較差的成因之一。
6. 類神經網路模式於兩實驗區所得之分類成果與支持向量機近似，原因為類神經網路若能謹慎的選取網路架構，其分類能力將能相似於支持向量機，但類神經具有無法對其網路權重進行解釋的缺點。反觀，支持向量機在分類上則具有良好的解釋能力，且支持向量機在參數決定也較類神經網路模式為容易，僅需考量 C 及 γ 參數，使用上也較為方便，上述兩點為支持向量機的優勢之處。
7. 粗糙集方法其分類成果在兩實驗區中僅較高斯最大似然分類法為佳，其可能的原因為選取的訓練樣本無法代表整個實驗區之情形，而導致攫取的規則無法對全實驗區影像作良好的分類。在本研究中，僅使用一種離散化及規則生成方式建立分類模式，而不同方式所建立的分類模式可能會對分類成果造成影響，故

建議未來可再針對不同離散化及規則生成方式作更深入的研究。

8. 由訓練樣本之常態分佈檢定過程，得知兩實驗區所採用的訓練樣本皆為非常態分佈，故高斯最大似然分類法所得的分類精度較差。支持向量機、PNN 及三種相對上較 PNN 為傳統的類神經網路在原理上，則不受訓練樣本為非常態分佈之影響，故有較佳的分類成果。
9. 檢核資料是以航空照片經人工判釋方式而得，判釋過程中可能會有誤判的情形發生，故檢核資料的正確性是有待探討的另一項重點。且檢核資料上僅提供水稻及非水稻類別之資訊，若其提供的類別資訊可再細化，將使得在評估各分類模式之優劣能有更深入的探討。



參考文獻

工研院，2001。遙測與資訊技術應用於精準農業技術之建立~結合遙測與 GIS 建置水稻田辨識系統(3/4)，工研院能資所第 063-90-W010 號報告。

工研院，2005。應用高時間與空間解像力遙測影像於水稻田耕作調查(1/3)，工研院能資所報告。

王景南，2003。多類支向機之研究，元智大學資訊管理學系研究所碩士論文。

呂秀慧，2001，頭前溪流域植生覆蓋變遷之研究，國立交通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研究所碩士論文。

施亦良、雷祖強、周天穎，2005。利用粗糙集理論建立水稻田知識庫分類之研究，台灣地理資訊學會年會暨學術研討會論文集。

陳益鳳，1998。應用多時段衛星影像辨識水稻田之研究，國立成功大學測量工程研究所碩士論文。

張斐章、張麗秋、黃浩倫，2004。類神經網路理論與實務，東華書局股份有限公司。

許晉嘉、雷祖強、周天穎，2005。應用支援向量機法於衛星影像分類之研究，農業工程研討會論文集。

黃明哲、李良輝，2005。支持向量機應用於空載雷射掃瞄資料地物分類之研究，電子計算機於土木水利應用研討會。

農復會，1977。水稻栽培灌溉排水管理，農復會、水利局、水利協進會。

- 葉怡成，1998。類神經網路模式應用與實作，五版，儒林書局有限公司。
- 鄧敏松，1997。多時段遙測影像、耕地坵塊與領域知識之區域式影像辨識法於水稻田耕作調查之應用，國立成功大學測量研究所碩士論文。
- 黎瑋，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研究所碩士論文。
- 劉孝恆，1999。監督性模糊分類法於遙測影像分類及變遷偵測之研究，國立中央大學土木工程研究所碩士論文。
- 蕭國鑫，1998。多時遙測光學與雷達資料於水稻田辨識之研究，國立交通大學土木工程研究所碩士論文。
- 羅華強，2001。類神經網路 MATLAB 的應用—類神經網路的介紹，清蔚科技出版。
- Bischof, H., W. Schneider, and A. J. Pinz, 1992. Multispectral Classification of Landsat-images Using Neural Networks, IEEE Transactions on Geoscience and Remote Sensing, 30(3):482-490.
- Burges, C. J. C., 1998. A Tutorial on Support Vector Machines for Pattern Recognition, Data Mining Knowl. Discov., 2:121-167.
- Cristianini, N., and J. Shawe-Taylor, 2000. An Introduction To Support Vector Machines and other kernel-based learning methods, Cambridge University Press.
- Chen, Y. Y., 2002. Plausible Neural Networks, Advance in Neural Networks World, WSEAS Press, 180-185.
- Chen, Y. Y., and J. J. Chen, 2004. Neural Networks and Belief Logic, Proceedings of Hybrid Intelligent Systems 2004, Fourth International Conference on 5-8 Dec.

2004 Page(s):460 – 461.

Chen, Y. Y., 2005. Logic, Science and Complex Systems - A Synthesis View,
<http://www.pnntech.com/index.htm>.

Chen, Y. Y., 2005. Plausible Neural Networks - An Intelligent Self-organized
Network System, <http://www.pnntech.com/index.htm>.

Camps-Valls G., and L. Bruzzone, 2005. Kernel-Based Methods for Hyperspectral
Image Classification, IEEE Transactions on Geoscience and Remote Sensing, 43
(6): 1351-1362.

Duda, R. O., and P. E. Hart, 1973. Pattern Classification and Scene Analysis, Wiley,
New York.

Foody, G. M., and A. Mathur, 2004. A Relative Evaluation of Multiclass Image
Classification by Support Vector Machines, IEEE Transactions on Geoscience
and Remote Sensing, 42 (6): 1335-1343.

Gonzales, R. C., and R. E. Woods, 2002. Digital Image Processing, Addison-Wesley
Publishing Company.

Hughes, G. F., 1968. On the Mean Accuracy of Statistical Pattern Recognizers, IEEE
Transactions on Information Theory, vol. IT-14, pp. 55-63.

Haralick, R.M., K. Shaunmmugam, and I. Dinstein, 1973. Textural Features for Image
Classification, IEEE Trans. On Syst., Man, and Cybern., SMC-3(6): 610-621.

Hagan, M. T., H. B. Demuth, and M. Beale, 1995. Neural Network Design, PWS
Publishing Company, Boston.

Hsu, C. W., C. C. Chang, and C. J. Lin. A Practical Guide to Support Vector

Classification, <http://www.csie.ntu.edu.tw/~cjlin/libsvm/index.html>.

Kohonen, T., 1990. The Self-Organizing Map, Proceedings of the IEEE, 78(9) : 1464-1480.

Komorowski, J., Z. Pawlak, L. Polkowski, and A. Skowron, 1999. Rough sets: A Tutorial, In S. K. Pal and A. Skowron, editors, Rough Fuzzy Hybridization, A New Trend in Decision Making, pages 3-98, Singapore. Springer.

Landgrebe, D. and L. Biehl, 2001. An Introduction To MultiSpec, Purdue University.

Lillesand, T. M., R. W. Kiefer, J. W. Chipman, 2004. Remote Sensing and Image Interpretation, Fifth Edition, John Wiley & Sons, Inc.

Lin, C. J., 2004. Support Vector Machines for Data Classification and Regression, <http://www.csie.ntu.edu.tw/~cjlin/>.

MathWorks, 2001. Matlab Neural Network Toolbox 4.0 User's Guide, V6.1, MathWorks.

Melgani, F., and L. Bruzzone, 2004. Classification of Hyperspectral Remote Sensing Images with Support Vector Machines, IEEE Transactions on Geoscience and Remote Sensing 42 (8): 1778-1790.

Pawlak, Z., 1991. Rough Sets : Theoretical Aspects of Reasoning about Data, Kluwer Academic Publishers, Dordrecht , Boston.

Pawlak, Z., J. Grzymala-Busse, R. Slowinski, 1995. Rough Sets, Commun ACM, 38(11):89-95.

PCI, 1997. Using PCI Software, V9.1, PCI, Canada.

Predki, B., R. Slowinski, J. Stefanowski, R. Susmaga, and Sz. Wilk, 1998. ROSE - 78

Software Implementation of the Rough Set Theory, In: L.Polkowski, A.Skowron, eds. Rough Sets and Current Trends in Computing, Lecture Notes in Artificial Intelligence, vol. 1424. Springer-Verlag, Berlin, 605-608.

Slowinski, R., 1992. Intelligent Decision Support: Handbook of Applications and Advances of the Rough Sets Theory, Kluwer Academic Publishers, Dordrecht, Boston.

Schowengerdt, R. A., 1997. Remote Sensing: Models and Methods for Image Processing, Second Edition, Academic Press.

Smith, G. M. and E. J. Milton, 1999. The Use of the Empirical Line Method to Calibrate Remotely Sensed Data to Reflectance, Int. J. Remote Sensing, 1999, vol. 20, no. 13, 2653-2662.

Vapnik, V., 1995. The Nature of Statistical Learning Theory, Springer-Verlag, New York.

Yuan, D., and C. D. Elvidge, 1996. Comparison of Relative Radiometric Normalization Techniques, ISPRS Journal of Photogrammetry and Remote Sensing, Volume 51, Number 3, pp. 117-126(10)

Zhu, G., and D. G. Blumberg, 2002. Classification Using ASTER Data and SVM Algorithms; The Case Study of Beer Sheva, Israel, Remote Sensing of Environment, 80 (2): 233-240.

附錄 A 嘉義實驗區各分類成果之誤差矩陣

A-1 不同群聚類別數及訓練樣本集合之分類成果

A-1-1 2 個群聚類別

1. 增加水稻之訓練樣本

表 A-1 高斯最大似然分類法

誤差矩陣 ERROR MATRIX		分類成 果		生產者精度	整體精度： 86.520% Kappa 指標： 0.73154 Kappa 指標標準差： 0.00129
檢核資料	水稻	水稻	水稻區		
檢核資料	水稻	127095	30053	80.876	整體精度： 86.520% Kappa 指標： 0.73154 Kappa 指標標準差： 0.00129
	非水稻	7466	113713	93.839	
使用者精度		94.452	79.096		

表 A-2 支持向量機 ($C=8$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成 果		生產者精度	整體精度： 88.888% Kappa 指標： 0.77286 Kappa 指標標準差： 0.00122 訓練樣本交叉驗證： 100%
檢核資料	水稻	水稻	水稻區		
檢核資料	水稻	143931	13217	91.589	整體精度： 88.888% Kappa 指標： 0.77286 Kappa 指標標準差： 0.00122 訓練樣本交叉驗證： 100%
	非水稻	17732	103447	85.367	
使用者精度		89.032	88.671		

2. 初取選取之訓練樣本

表 A-3 高斯最大似然分類法

誤差矩陣 ERROR MATRIX		分類成 果		生產者精度	整體精度： 84.403% Kappa 指標： 0.69234 Kappa 指標標準差： 0.00136
檢核資料	水稻	水稻	水稻區		
檢核資料	水稻	118948	38200	75.692	整體精度： 84.403% Kappa 指標： 0.69234 Kappa 指標標準差： 0.00136
	非水稻	5211	115968	95.700	
使用者精度		95.803	75.222		

表 A-4 支持向量機 (C=8、 γ =0.5)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.103% Kappa 指標： 0.77752 Kappa 指標標準差： 0.00121 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	143958	13190	91.607	
	非水稻	17140	104039	85.856	
使用者精度		89.361	88.749		

3. 增加非水稻之訓練樣本

表 A-5 高斯最大似然分類法

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 83.864% Kappa 指標： 0.68228 Kappa 指標標準差： 0.00137
		水稻	水稻區		
檢核資料	水稻	117221	39927	74.593	
	非水稻	4984	116195	95.887	
使用者精度		95.922	74.426		

表 A-6 支持向量機 (C=8、 γ =0.5)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.651% Kappa 指標： 0.78919 Kappa 指標標準差： 0.00118 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	143548	13600	91.346	
	非水稻	15203	105976	87.454	
使用者精度		90.423	88.626		

A-1-2 23 個群聚類別

1. 增加水稻之訓練樣本

表 A-7 高斯最大似然分類法

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 88.472% Kappa 指標： 0.76637 Kappa 指標標準差： 0.00123
		水稻	水稻區		
檢核資料	水稻	139181	17967	88.567	
	非水稻	14119	107060	88.349	
使用者精度		90.790	85.630		

表 A-8 支持向量機 ($C=32$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 88.409% Kappa 指標： 0.76214 Kappa 指標標準差： 0.00125 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	145687	11461	92.707	
	非水稻	20801	100378	82.834	
使用者精度		87.506	89.752		

2. 初取選取之訓練樣本

表 A-9 高斯最大似然分類法

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 87.311% Kappa 指標： 0.74643 Kappa 指標標準差： 0.00126
		水稻	水稻區		
檢核資料	水稻	130038	27110	82.749	
	非水稻	8208	112971	93.227	
使用者精度		94.063	80.647		

表 A-10 支持向量機 ($C=32$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 88.487% Kappa 指標： 0.76383 Kappa 指標標準差： 0.00124 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	145579	11569	92.638	
	非水稻	20476	100703	83.103	
	使用者精度	87.669	89.696		

3. 增加非水稻之訓練樣本

表 A-11 高斯最大似然分類法

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 79.473% Kappa 指標： 0.60114 Kappa 指標標準差： 0.00149
		水稻	水稻區		
檢核資料	水稻	103839	53309	66.077	
	非水稻	3822	117357	96.846	
	使用者精度	96.450	68.764		

表 A-12 支持向量機 ($C=2$ 、 $\gamma=8$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.057% Kappa 指標： 0.77674 Kappa 指標標準差： 0.00121 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	143528	13620	91.333	
	非水稻	16838	104341	86.105	
	使用者精度	89.500	88.454		

A-1-3 38 個群聚類別

1. 增加水稻之訓練樣本

表 A-13 高斯最大似然分類法

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 87.5% Kappa 指標： 0.74664 Kappa 指標標準差： 0.00127
		水稻	水稻區		
檢核資料	水稻	137879	19269	87.738	
	非水稻	15523	105656	87.190	
	使用者精度	89.881	84.576		

表 A-14 支持向量機 ($C=32$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 80.023% Kappa 指標： 0.75379 Kappa 指標標準差： 0.00127 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	146072	11076	92.952	
	非水稻	22259	98920	81.631	
	使用者精度	86.777	89.931		

2. 初取選取之訓練樣本

表 A-15 高斯最大似然分類法

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 84.384% Kappa 指標： 0.69097 Kappa 指標標準差： 0.00136
		水稻	水稻區		
檢核資料	水稻	120705	36443	76.810	
	非水稻	7020	114159	94.207	
	使用者精度	94.504	75.802		

表 A-16 支持向量機 ($C=8$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 88.272% Kappa 指標： 0.75879 Kappa 指標標準差： 0.00125 訓練樣本交叉驗證： 99.8904%
		水稻	水稻區		
檢核資料	水稻	146675	10473	93.336	整體精度： 88.272% Kappa 指標： 0.75879 Kappa 指標標準差： 0.00125 訓練樣本交叉驗證： 99.8904%
	非水稻	22169	99010	81.706	
	使用者精度	86.870	90.434		

3. 增加非水稻之訓練樣本

表 A-17 高斯最大似然分類法

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 71.337% Kappa 指標： 0.45563 Kappa 指標標準差： 0.00163
		水稻	水稻區		
檢核資料	水稻	79698	77450	50.715	整體精度： 71.337% Kappa 指標： 0.45563 Kappa 指標標準差： 0.00163
	非水稻	2326	118853	98.081	
	使用者精度	97.164	60.546		

表 A-18 支持向量機 ($C=8$ 、 $\gamma=8$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 88.997% Kappa 指標： 0.77566 Kappa 指標標準差： 0.00121 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	143131	14017	91.080	整體精度： 88.997% Kappa 指標： 0.77566 Kappa 指標標準差： 0.00121 訓練樣本交叉驗證： 100%
	非水稻	16606	104573	86.296	
	使用者精度	89.604	88.180		

A-2 支持向量機於不同核函數之分類成果

A-2-1 線性核函數

表 A-19 支持向量機 (Linear、C=32768)

誤差矩陣 ERROR MATRIX	分類成果		生產者精度	整體精度： 87.859% Kappa 指標： 0.75661	
	水稻	水稻區			
檢核資料	水稻	132524	24624	84.331	
	非水稻	9167	112012	92.435	
	使用者精度	93.530	81.978	訓練樣本交叉驗證： 95.6897%	

A-2-2 多項式核函數

1. 1 階多項式

表 A-20 支持向量機 (Polynomial 1、C=8192、 $\gamma=2$)

誤差矩陣 ERROR MATRIX	分類成果		生產者精度	整體精度： 87.852% Kappa 指標： 0.75649	
	水稻	水稻區			
檢核資料	水稻	132470	24678	84.296	
	非水稻	9133	112046	92.463	
	使用者精度	93.550	81.950	訓練樣本交叉驗證： 95.8621%	

2. 2 階多項式

表 A-21 支持向量機 (Polynomial 2、C=128、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX	分類成果		生產者精度	整體精度： 89.830% Kappa 指標： 0.79303	
	水稻	水稻區			
檢核資料	水稻	143278	13870	91.174	
	非水稻	14437	106742	88.086	
	使用者精度	90.846	88.500	訓練樣本交叉驗證： 100%	

3. 3 階多項式

表 A-22 支持向量機 (Polynomial 3、C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度：
檢核資料	水稻	水稻區			89.812%
	水稻	143371	13777	91.233	Kappa 指標： 0.79262
	非水稻	14579	106600	87.969	Kappa 指標標準差： 0.00117
	使用者精度	90.770	88.555		訓練樣本交叉驗證： 100%

4. 4 階多項式

表 A-23 支持向量機 (Polynomial 4、C=2、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度：
檢核資料	水稻	水稻區			89.768%
	水稻	143500	13648	91.315	Kappa 指標： 0.79165
	非水稻	14831	106348	87.761	Kappa 指標標準差： 0.00117
	使用者精度	90.633	88.626		訓練樣本交叉驗證： 100%

5. 5 階多項式

表 A-24 支持向量機 (Polynomial 5、C=0.5、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度：
檢核資料	水稻	水稻區			89.748%
	水稻	143107	14041	91.065	Kappa 指標： 0.79140
	非水稻	14492	106687	88.041	Kappa 指標標準差： 0.00117
	使用者精度	90.805	88.370		訓練樣本交叉驗證： 100%

A-2-2 兩層式類神經網路核函數

表 A-25 支持向量機 (\tanh 、 $C=32768$ 、 $\gamma=0.001953125$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 87.813% Kappa 指標： 0.075659 Kappa 指標標準差： 0.00124 訓練樣本交叉驗證： 95.5172%
		水稻	水稻區		
檢核資料	水稻	130455	26693	83.014	Kappa 指標標準差： 0.00124 訓練樣本交叉驗證： 95.5172%
	非水稻	7228	113951	94.035	
使用者精度		94.750	81.021		

A-3 其它分類理論之分類成果

1. 倒傳遞類神經網路

表 A-26 倒傳遞類神經網路

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.629% Kappa 指標： 0.78931 Kappa 指標標準差： 0.00117
		水稻	水稻區		
檢核資料	水稻	142100	15048	90.424	Kappa 指標標準差： 0.00117
	非水稻	13816	107363	88.599	
使用者精度		91.139	87.707		

2. 學習向量量化類神經網路

表 A-27 學習向量量化類神經網路

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 88.297% Kappa 指標： 0.75903 Kappa 指標標準差： 0.00125
		水稻	水稻區		
檢核資料	水稻	147327	9821	93.750	Kappa 指標標準差： 0.00125
	非水稻	22751	98428	81.225	
使用者精度		86.623	90.927		

3. 輻狀基底函數類神經網路

表 A-28 輻狀基底函數類神經網路

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.262% Kappa 指標： 0.78195 Kappa 指標標準差： 0.00119
		水稻	水稻區		
檢核資料	水稻	141343	15805	89.943	
	非水稻	14082	107097	88.379	
	使用者精度	90.940	87.140		

4. 粗糙集理論

表 A-29 粗糙集理論

誤差矩陣 ERROR MATRIX		分類成果		生產者精度 整體精度： 86.947% Kappa 指標： 0.73826 Kappa 指標標準差： 0.00128
		水稻	水稻區	
檢核資料	水稻	131375	25773	83.600
	非水稻	10558	110618	91.287
	使用者精度	92.561	81.104	

5.PNN V1.0

表 A-30 PNN V1.0

誤差矩陣 ERROR MATRIX		分類成果		生產者精度 整體精度： 94.189% Kappa 指標： 0.88203 Kappa 指標標準差： 0.00090
		水稻	水稻區	
檢核資料	水稻	148090	9058	94.236
	非水稻	7115	114064	94.129
	使用者精度	95.416	92.643	

6. PNN V1.3

表 A-31 PNN V1.3

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.412% Kappa 指標： 0.78495 Kappa 指標標準差： 0.00118
檢核資料	水稻	水稻	水稻區		
	水稻	141673	15475	90.153	Kappa 指標標準差： 0.00118
	非水稻	13994	107185	88.452	
使用者精度		91.010	87.384		

A-4 紋理影像輔助支持向量機之分類成果

A-4-1 8月7日紅光波段之八種紋理影像分類成果

1. 多光譜影像加八種紋理影像

表 A-32 支持向量機 ($C=8192$ 、 $\gamma=0.03125$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 88.509% Kappa 指標： 0.76733 Kappa 指標標準差： 0.00122 訓練樣本交叉驗證： 100%
檢核資料	水稻	水稻	水稻區		
	水稻	138769	18379	88.305	Kappa 指標標準差： 0.00122 訓練樣本交叉驗證： 100%
	非水稻	13603	107576	88.774	
使用者精度		91.073	85.408		

2. 多光譜影像加 Mean 紹理影像

表 A-33 支持向量機 ($C=8$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.605% Kappa 指標： 0.78824 Kappa 指標標準差： 0.00118 訓練樣本交叉驗證： 100%
檢核資料	水稻	水稻	水稻區		
	水稻	143537	13611	91.339	Kappa 指標標準差： 0.00118 訓練樣本交叉驗證： 100%
	非水稻	15320	105859	87.358	
使用者精度		90.356	88.607		

3. 多光譜影像加 Variance 紋理影像

表 A-34 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.666% Kappa 指標： 0.78951 Kappa 指標標準差： 0.00118 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	143529	13619	91.334	
	非水稻	15143	106036	87.504	
使用者精度		90.456	88.618		

4. 多光譜影像加 Homogeneity 紹理影像

表 A-35 支持向量機 (C=32、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.332% Kappa 指標： 0.78357 Kappa 指標標準差： 0.00119 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	140970	16178	89.705	
	非水稻	13513	107666	88.849	
使用者精度		91.253	86.937		

5. 多光譜影像加 Contrast 紹理影像

表 A-36 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.667% Kappa 指標： 0.78954 Kappa 指標標準差： 0.00118 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	143501	13647	91.316	
	非水稻	15112	106067	87.529	
使用者精度		90.472	88.600		

6. 多光譜影像加 Dissimilarity 紋理影像

表 A-37 支持向量機 ($C=8$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度：
		水稻	水稻區		89.665%
檢核資料	水稻	142980	14168	90.984	Kappa 指標： 0.78970
	非水稻	14597	106582	87.954	Kappa 指標標準差： 0.00117
使用者精度		90.737	88.267	訓練樣本交叉驗證： 100%	

7. 多光譜影像加 Entropy 紹理影像

表 A-38 支持向量機 ($C=32$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度：
		水稻	水稻區		89.527%
檢核資料	水稻	145454	11694	92.559	Kappa 指標： 0.78582
	非水稻	17455	103724	85.596	Kappa 指標標準差： 0.00119
使用者精度		89.285	89.868	訓練樣本交叉驗證： 100%	

8. 多光譜影像加 ASM 紹理影像

表 A-39 支持向量機 ($C=8$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度：
		水稻	水稻區		89.710%
檢核資料	水稻	144106	13042	91.701	Kappa 指標： 0.79019
	非水稻	15599	105580	87.127	Kappa 指標標準差： 0.00117
使用者精度		90.233	89.005	訓練樣本交叉驗證： 100%	

9. 多光譜影像加 Correlation 紋理影像

表 A-40 支持向量機 ($C=8$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.705% Kappa 指標： 0.79058
		水稻	水稻區		
檢核資料	水稻	142856	14292	90.905	Kappa 指標標準差： 0.00117 訓練樣本交叉驗證： 100%
	非水稻	14363	106816	88.147	
	使用者精度	90.864	88.199		100%

A-4-2 10月12日近紅光波段之八種紋理影像分類成果

1. 多光譜影像加八種紋理影像

表 A-41 支持向量機 ($C=128$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 88.123% Kappa 指標： 0.76134
		水稻	水稻區		
檢核資料	水稻	134155	22993	85.369	Kappa 指標標準差： 0.00123 訓練樣本交叉驗證： 100%
	非水稻	10064	111115	91.695	
	使用者精度	93.022	82.855		100%

2. 多光譜影像加 Mean 紹理影像

表 A-42 支持向量機 ($C=8$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.115% Kappa 指標： 0.77825
		水稻	水稻區		
檢核資料	水稻	142815	14333	90.879	Kappa 指標標準差： 0.00120 訓練樣本交叉驗證： 100%
	非水稻	15964	105215	86.826	
	使用者精度	89.946	88.011		100%

3. 多光譜影像加 Variance 紋理影像

表 A-43 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.832% Kappa 指標： 0.79381 Kappa 指標標準差： 0.00116 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	141428	15720	89.997	
	非水稻	12579	108600	89.619	
使用者精度		91.832	87.355		

4. 多光譜影像加 Homogeneity 紹理影像

表 A-44 支持向量機 (C=32、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 88.704% Kappa 指標： 0.77316 Kappa 指標標準差： 0.00120 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	134597	22551	85.650	
	非水稻	8890	112289	92.664	
使用者精度		93.804	83.276		

5. 多光譜影像加 Contrast 紹理影像

表 A-45 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.679% Kappa 指標： 0.79068 Kappa 指標標準差： 0.00117 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	141282	15866	89.904	
	非水稻	12859	108320	89.388	
使用者精度		91.658	87.224		

6. 多光譜影像加 Dissimilarity 紋理影像

表 A-46 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 87.197% Kappa 指標： 0.74432 Kappa 指標標準差： 0.00126 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	129549	27599	82.438	
	非水稻	8034	113145	93.370	
使用者精度		94.161	80.391		

7. 多光譜影像加 Entropy 紹理影像

表 A-47 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.646% Kappa 指標： 0.79064 Kappa 指標標準差： 0.00117 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	139611	17537	88.840	
	非水稻	11281	109898	90.691	
使用者精度		92.524	86.238		

8. 多光譜影像加 ASM 紹理影像

表 A-48 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.669% Kappa 指標： 0.79062 Kappa 指標標準差： 0.00117 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	140844	16304	89.625	
	非水稻	12451	108728	89.725	
使用者精度		91.878	86.960		

9. 多光譜影像加 Correlation 紋理影像

表 A-49 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.549%
		水稻	水稻區		
檢核資料	水稻	143321	13827	91.201	Kappa 指標： 0.78714
	非水稻	15261	105918	87.406	Kappa 指標標準差： 0.00118
	使用者精度	90.377	88.453		訓練樣本交叉驗證： 100%

A-4-3 全部波段之八種紋理影像並以 PCA 法取前八波段之分類成果

1. 多光譜影像加八種 PC 紋理影像

表 A-50 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 81.843%
		水稻	水稻區		
檢核資料	水稻	109785	47363	69.861	Kappa 指標： 0.64549
	非水稻	3172	118007	97.382	Kappa 指標標準差： 0.00143
	使用者精度	97.192	71.359		訓練樣本交叉驗證： 100%

2. 多光譜影像加 PC1 紹理影像

表 A-51 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 85.870%
		水稻	水稻區		
檢核資料	水稻	123272	33876	78.443	Kappa 指標： 0.72011
	非水稻	5452	115727	95.501	Kappa 指標標準差： 0.00131
	使用者精度	95.765	77.356		訓練樣本交叉驗證： 100%

3. 多光譜影像加 PC2 紋理影像

表 A-52 支持向量機 (C=32=0.5)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.167% Kappa 指標： 0.77965 Kappa 指標標準差： 0.00120 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	142077	15071	90.410	
	非水稻	15081	106098	87.555	
使用者精度		90.404	87.562		

4. 多光譜影像加 PC3 紹理影像

表 A-53 支持向量機 (C=32、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.484% Kappa 指標： 0.78546 Kappa 指標標準差： 0.00119 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	144091	13057	91.691	
	非水稻	16213	104966	86.621	
使用者精度		89.886	88.937		

5. 多光譜影像加 PC4 紹理影像

表 A-54 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.775% Kappa 指標： 0.79135 Kappa 指標標準差： 0.00117 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	143598	13550	91.378	
	非水稻	14964	106215	87.651	
使用者精度		90.563	88.686		

6. 多光譜影像加 PC5 紋理影像

表 A-55 支持向量機 ($C=8$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度：
		水稻	水稻區		89.948%
檢核資料	水稻	143478	13670	91.301	Kappa 指標： 0.79543
	非水稻	14307	106872	88.193	Kappa 指標標準差： 0.00116
使用者精度		90.933	88.660	訓練樣本交叉驗證： 100%	

7. 多光譜影像加 PC6 紹理影像

表 A-56 支持向量機 ($C=32$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度：
		水稻	水稻區		89.632%
檢核資料	水稻	143482	13666	91.304	Kappa 指標： 0.78882
	非水稻	15190	105989	87.465	Kappa 指標標準差： 0.00118
使用者精度		90.427	88.579	訓練樣本交叉驗證： 100%	

8. 多光譜影像加 PC7 紹理影像

表 A-57 支持向量機 ($C=8$ 、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度：
		水稻	水稻區		89.668%
檢核資料	水稻	143758	13390	91.479	Kappa 指標： 0.78945
	非水稻	15368	105811	87.318	Kappa 指標標準差： 0.00118
使用者精度		90.342	88.767	訓練樣本交叉驗證： 100%	

9. 多光譜影像加 PC8 紋理影像

表 A-58 支持向量機 (C=8192、 γ =0.03125)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.706% Kappa 指標： 0.79034 Kappa 指標標準差： 0.00117 訓練樣本交叉驗證： 99.9138%
		水稻	水稻區		
檢核資料	水稻	143528	13620	91.333	整體精度： 89.706% Kappa 指標： 0.79034 Kappa 指標標準差： 0.00117 訓練樣本交叉驗證： 99.9138%
	非水稻	15031	106148	87.596	
	使用者精度	90.520	88.628		

A-4-4 全部波段之五種紋理影像並以 PCA 法取前八波段之分類成果

1. 多光譜影像加八種 PC 紋理影像

表 A-59 支持向量機 (C=2、 γ =2)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 82.212% Kappa 指標： 0.65228 Kappa 指標標準差： 0.00142 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	110938	46210	70.595	整體精度： 82.212% Kappa 指標： 0.65228 Kappa 指標標準差： 0.00142 訓練樣本交叉驗證： 100%
	非水稻	3300	117879	97.277	
	使用者精度	97.111	71.838		

2. 多光譜影像加 PC1 紹理影像

表 A-60 支持向量機 (C=8、 γ =0.5)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 85.339% Kappa 指標： 0.71015 Kappa 指標標準差： 0.00133 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	121480	35668	77.303	整體精度： 85.339% Kappa 指標： 0.71015 Kappa 指標標準差： 0.00133 訓練樣本交叉驗證： 100%
	非水稻	5138	116041	95.760	
	使用者精度	95.942	76.489		

3. 多光譜影像加 PC2 紋理影像

表 A-61 支持向量機 (C=32、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.150% Kappa 指標： 0.77920 Kappa 指標標準差： 0.00120 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	142324	14824	90.567	
	非水稻	15375	105804	87.312	
使用者精度		90.250	87.711		

4. 多光譜影像加 PC3 紹理影像

表 A-62 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.517% Kappa 指標： 0.78606 Kappa 指標標準差： 0.00119 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	144325	12823	91.840	
	非水稻	16355	104824	86.503	
使用者精度		89.821	89.100		

5. 多光譜影像加 PC4 紹理影像

表 A-63 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.739% Kappa 指標： 0.79102 Kappa 指標標準差： 0.00117 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	143556	13592	91.351	
	非水稻	14967	106212	87.649	
使用者精度		90.558	88.655		

6. 多光譜影像加 PC5 紋理影像

表 A-64 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.861% Kappa 指標： 0.79340 Kappa 指標標準差： 0.00117 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	144002	13146	91.635	
	非水稻	15073	106106	87.561	
使用者精度		90.525	88.976		

7. 多光譜影像加 PC6 紹理影像

表 A-65 支持向量機 (C=32、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.644% Kappa 指標： 0.78906 Kappa 指標標準差： 0.00118 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	143503	13645	91.317	
	非水稻	15178	106001	87.475	
使用者精度		90.435	88.596		

8. 多光譜影像加 PC7 紹理影像

表 A-66 支持向量機 (C=8、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.660% Kappa 指標： 0.78925 Kappa 指標標準差： 0.00118 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	143853	13295	91.540	
	非水稻	15484	105695	87.222	
使用者精度		90.282	88.827		

9. 多光譜影像加 PC8 紋理影像

表 A-67 支持向量機 (C=32、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 89.782% Kappa 指標： 0.79245 Kappa 指標標準差： 0.00117 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	142211	14937	90.495	
	非水稻	13503	107676	88.857	
使用者精度		91.328	87.818		



附錄 B 新竹實驗區各分類成果之誤差矩陣

B-1 支持向量機於不同核函數之分類成果

B-1-1 線性核函數

表 B-1 支持向量機 (Linear、C=128)

誤差矩陣 ERROR MATRIX		分類 成 果		生產者精度	整體精度： 81.508% Kappa 指標： 0.62504 Kappa 指標標準差： 0.00213 訓練樣本交叉驗證： 99.4841%
		水稻	水稻區		
檢核資料	水稻	66448	20156	76.726	整體精度： 81.508% Kappa 指標： 0.62504 Kappa 指標標準差： 0.00213 訓練樣本交叉驗證： 99.4841%
	非水稻	5013	44491	89.874	
使用者精度		92.985	68.821		

B-1-2 輻狀基底核函數

表 B-2 支持向量機 (RBF、C=128、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類 成 果		生產者精度	整體精度： 84.989% Kappa 指標： 0.68269 Kappa 指標標準差： 0.00205 訓練樣本交叉驗證： 100%
		水稻	水稻區		
檢核資料	水稻	73838	12766	85.259	整體精度： 84.989% Kappa 指標： 0.68269 Kappa 指標標準差： 0.00205 訓練樣本交叉驗證： 100%
	非水稻	7665	41839	84.516	
使用者精度		90.595	76.621		

B-1-3 多項式核函數

1. 1 階多項式

表 B-3 支持向量機 (Polynomial 1、C=32768、 $\gamma=0.0078125$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 81.177% Kappa 指標： 0.61889
檢核資料	水稻	水稻	水稻區		
	水稻	66047	20557	76.263	Kappa 指標標準差： 0.00215 訓練樣本交叉驗證： 99.5701%
	非水稻	5062	44442	89.775	
使用者精度		92.881	68.373		

2. 2 階多項式

表 B-4 支持向量機 (Polynomial 2、C=512、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 83.737% Kappa 指標： 0.66120
檢核資料	水稻	水稻	水稻區		
	水稻	71251	15353	82.272	Kappa 指標標準差： 0.00208 訓練樣本交叉驗證： 100%
	非水稻	6782	42722	86.300	
使用者精度		91.309	73.563		

3. 3 階多項式

表 B-5 支持向量機 (Polynomial 3、C=128、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 84.004% Kappa 指標： 0.66624
檢核資料	水稻	水稻	水稻區		
	水稻	71615	14989	82.692	Kappa 指標標準差： 0.00207 訓練樣本交叉驗證： 100%
	非水稻	6782	42715	86.298	
使用者精度		91.349	74.024		

4. 4 階多項式

表 B-6 支持向量機 (Polynomial 4、C=32、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 84.198% Kappa 指標： 0.66961
檢核資料	水稻	水稻	水稻區		
	水稻	71997	14607	83.134	Kappa 指標標準差： 0.00207
	非水稻	6901	42603	86.060	
	使用者精度	91.253	74.468		訓練樣本交叉驗證： 100%

5. 5 階多項式

表 B-7 支持向量機 (Polynomial 5、C=32、 $\gamma=0.5$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 84.425% Kappa 指標： 0.67341
檢核資料	水稻	水稻	水稻區		
	水稻	72497	14107	83.711	Kappa 指標標準差： 0.00206
	非水稻	7092	42412	85.674	
	使用者精度	91.089	75.040		訓練樣本交叉驗證： 100%

6. 6 階多項式

表 B-8 支持向量機 (Polynomial 6、C=512、 $\gamma=0.125$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 83.985% Kappa 指標： 0.66586
檢核資料	水稻	水稻	水稻區		
	水稻	71602	15002	82.677	Kappa 指標標準差： 0.00207
	非水稻	6796	42708	86.272	
	使用者精度	91.331	74.005		訓練樣本交叉驗證： 100%

B-1-4 兩層式類神經網路核函數

表 B-9 支持向量機 (\tanh 、 $C=2048$ 、 $\gamma=0.03125$)

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 81.808% Kappa 指標： 0.63074 Kappa 指標標準差： 0.00212 訓練樣本交叉驗證： 99.4841%
		水稻	水稻區		
檢核資料	水稻	66778	19826	77.107	Kappa 指標標準差： 0.00212 訓練樣本交叉驗證： 99.4841%
	非水稻	4935	44569	90.031	
使用者精度		93.118	69.212		

B-2 其它分類理論之分類成果

1. 高斯最大似然分類法

表 B-10 高斯最大似然分類法

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 80.343% Kappa 指標： 0.60052 Kappa 指標標準差： 0.00219
		水稻	水稻區		
檢核資料	水稻	65931	20673	76.129	Kappa 指標標準差： 0.00219
	非水稻	6082	43422	87.714	
使用者精度		91.554	67.746		

2. 倒傳遞類神經網路

表 B-11 倒傳遞類神經網路

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 84.188% Kappa 指標： 0.6655 Kappa 指標標準差： 0.00209
		水稻	水稻區		
檢核資料	水稻	73379	13225	84.729	Kappa 指標標準差： 0.00209
	非水稻	8297	41207	83.240	
使用者精度		89.842	75.704		

3. 學習向量量化類神經網路

表 B-12 學習向量量化類神經網路

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 85.559% Kappa 指標： 0.68969 Kappa 指標標準差： 0.00205
		水稻	水稻區		
檢核資料	水稻	76147	10457	87.925	
	非水稻	9198	40306	81.420	
	使用者精度	89.223	79.400		

4. 輻狀基底函數類神經網路

表 B-13 輻狀基底函數類神經網路

誤差矩陣 ERROR MATRIX		分類成果		生產者精度 整體精度： 84.321% Kappa 指標： 0.67190 Kappa 指標標準差： 0.00206
		水稻	水稻區	
檢核資料	水稻	72187	14417	83.353
	非水稻	6923	42581	86.015
	使用者精度	91.249	74.706	

5. 粗糙集理論

表 B-14 粗糙集理論

誤差矩陣 ERROR MATRIX		分類成果		生產者精度 整體精度： 81.440% Kappa 指標： 0.61448 Kappa 指標標準差： 0.00219
		水稻	水稻區	
檢核資料	水稻	69334	17270	80.059
	非水稻	7992	41512	83.856
	使用者精度	89.665	70.620	

6. PNN V1.0

表 B-15 PNN V1.0

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 91.037% Kappa 指標： 0.80276 Kappa 指標標準差： 0.00170
		水稻	水稻區		
檢核資料	水稻	82612	3992	95.391	
	非水稻	8207	41297	83.422	
使用者精度		90.963	91.185		

7. PNN V1.3

表 B-16 PNN V1.3

誤差矩陣 ERROR MATRIX		分類成果		生產者精度	整體精度： 84.445% Kappa 指標： 0.66468 Kappa 指標標準差： 0.00212
		水稻	水稻區		
檢核資料	水稻	75765	10839	87.484	
	非水稻	10332	39172	79.129	
使用者精度		88.000	78.327		

作者簡歷

姓名：陳承昌

籍貫：台灣省基隆市

出生日期：民國 71 年 6 月 29 日

電子郵件：kolen.cv93g@nctu.edu.tw

學歷：國立台北工專土木工程科畢業

國立台北科技大學土木工程系畢業

國立交通大學土木工程學系測量與空間資訊組碩士班肄業

