

行政院農業委員會林務局
農林航空測量所

應用高光譜航遙測影像於
土地覆蓋型調查之研究

成 果 報 告 書

委託單位：行政院農業委員會林務局農林航空測量所

受託單位：國立臺灣大學

執行單位：國立臺灣大學土木工程學系

地 址：台北市大安區羅斯福路四段一號

中 華 民 國 108 年 12 月 16 日

目 錄

目 錄.....	I
圖 目 錄.....	IV
表 目 錄.....	VIII
壹、前言	- 10 -
1.1、計畫名稱	- 10 -
1.2、計畫緣起	- 10 -
1.3、計畫目的	- 11 -
1.4、工作項目	- 11 -
1.5、計畫時程	- 13 -
貳、實施方法及執行流程.....	- 16 -
參、高光譜影像研究文獻蒐集.....	- 18 -
3.1、高光譜影像之特性與常見分析方法	- 18 -
3.2、高光譜影像於森林調查之應用	- 22 -
肆、樣區規劃、高光譜影像資料獲取	- 28 -
4.1、樣區規劃	- 28 -
4.2、衛載及機載高光譜影像蒐集	- 31 -
4.3、衛載高光譜影像蒐集	- 32 -
4.4、機載高光譜影像蒐集	- 33 -
伍、實驗樣區高光譜影像蒐集.....	- 45 -
5.1、實驗樣區衛載高光譜影像蒐集	- 45 -
5.2、實驗樣區機載高光譜影像實際取像流程及影像成果	- 47 -
5.2.1、實驗樣區機載高光譜影像取像流程	- 47 -
5.2.2、實驗樣區機載高光譜影像取像成果	- 52 -
陸、自動分類演算法評估.....	- 64 -
6.1、特徵分類法	- 64 -
6.1.1、特徵萃取	- 64 -

6.1.2、傳統影像分類方法	67 -
6.2、結合空間資訊的特徵分類法	68 -
6.3、以機器學習為基礎之分類演算法	72 -
6.3.1、核方法	72 -
6.3.2、深度學習演算法	75 -
柒、實驗樣區高光譜影像分類與成果分析	78 -
7.1、實驗區域之衛載 EO-1 Hyperion 高光譜影像分析	78 -
7.1.1、出雲山苗圃實驗區域 EO-1 Hyperion 影像前處理與地真資料說明 -	78 -
7.1.2、出雲山苗圃 Hyperion 影像以特徵分類法之成果	81 -
7.1.3、出雲山苗圃 Hyperion 影像以機器學習為基礎之分類法成果..	90 -
7.1.4、出雲山苗圃實驗區衛載 Hyperion 影像分析討論	92 -
7.2、花蓮光復實驗樣區之機載高光譜影像分析	93 -
7.2.1、花蓮光復實驗區域、高光譜影像前處理與地真資料說明	93 -
7.2.2、以特徵分類法於花蓮光復實驗區影像分析	95 -
7.2.3、以物件導向分類法於花蓮光復實驗區影像分析	111 -
7.2.4、以機器學習為基礎之分類法於花蓮光復實驗區影像分析	115 -
7.3、出雲山苗圃實驗樣區之機載高光譜影像分析	122 -
7.3.1、出雲山苗圃實驗區域、高光譜影像前處理與地真資料說明 .	122 -
7.3.2、以特徵分類法於出雲山苗圃實驗區影像分析	124 -
7.3.3、以物件導向分類法於出雲山苗圃實驗區影像分析	139 -
7.3.4、以機器學習為基礎之分類法於出雲山苗圃影像分析	143 -
7.3.5、花蓮光復與出雲山苗圃實驗樣區機載高光譜影像分析討論 .	146 -
7.4、高光譜影像應用於森林資源調查之討論評估	147 -
捌、評估適合農航所定翼型無人機(Sky Arrow 55)搭載之高光譜感測器	150 -
8.1、蒐集各型無人載具高光譜感測器相關資訊	150 -
8.2、評估適合農航所定翼型無人機(Sky Arrow 55)搭載之高光譜感測器 .	157 -

8.2.1、Sky Arrow 55 機構安裝及儀器運作需求分析	157 -
8.2.2、Sky Arrow 55 搭載之高光譜感測器之評估建議	161 -
玖、成果交付	163 -
參考文獻	165 -
附件 A-1、期初報告審查會議紀錄及處理情形回覆	171 -
附件 A-2、期中報告審查會議紀錄及處理情形回覆	175 -
附件 A-3、期末報告審查會議紀錄及處理情形回覆	179 -
附件 B-1、高光譜儀	183 -
附件 B-2、雷射掃描儀及數位相機	184 -
附件 C、飛航掃描申請函文	185 -

圖 目 錄

圖 2-1、本計畫執行流程.....	- 16 -
圖 3-1、成像光譜儀之成像示意圖（徐百輝，2003）	- 19 -
圖 3-2、實際高光譜影像之(a)影像立方體與(b)相關矩陣	- 20 -
圖 3-3、研究中採用之高光譜影像與分類成果（Dain et al., 2015）	- 24 -
圖 3-4、利用 SVM 分類獲取目標樹種的預測地圖(Baldeck et al., 2015) -	25 -
圖 3-5、利用隨機森林演算法於高光譜影像、光達資料的森林樹種分類結果(Sommer et al., 2015).....	- 26 -
圖 4-1、候選樣區分布圖.....	- 28 -
圖 4-2、花蓮光復樣區航拍範圍	- 30 -
圖 4-3、出雲山苗圃樣區航拍範圍	- 30 -
圖 4-4、USGS EarthExplorer 網站影像查詢畫面	- 33 -
圖 4-5、高光譜儀器介紹(a)CASI1500 設備；(b)儀器波段.....	- 34 -
圖 4-6、空載光達儀器規格.....	- 34 -
圖 4-7、空載光達資料作業流程	- 37 -
圖 4-8、點雲解算產製處理流程	- 37 -
圖 4-9、高光譜產製流程.....	- 38 -
圖 4-10、輻射校正前後示意圖	- 39 -
圖 4-11、原廠軟體介面.....	- 40 -
圖 4-12、特徵點與控制點分佈示意圖	- 41 -
圖 4-13、幾何校正前後影像比對	- 42 -
圖 4-14、整條航帶幾何校正成果	- 43 -
圖 4-15、影像鑲嵌成果示意圖	- 44 -
圖 5-1、多幅 Hyperion 影像涵蓋範圍與實驗區域.....	- 46 -
圖 5-2、2011 年 4 月 2 日之 Hyperion 影像與地真資料	- 46 -
圖 5-3、飛航申請公文示意圖	- 48 -
圖 5-4、飛航載台及機上儀器設備	- 49 -

圖 5-5、飛航執行過程.....	49 -
圖 5-6、航線規劃流程.....	50 -
圖 5-7、出雲山苗圃(台中測區)航線規劃.....	51 -
圖 5-8、花蓮光復(花蓮測區)航線規劃.....	52 -
圖 5-9、花蓮光復實驗樣區初步單條航帶影像	53 -
圖 5-10、光臘樹單一像元光譜輻射值(radiance).....	54 -
圖 5-11、花蓮光復實驗樣區鑲嵌後影像.....	56 -
圖 5-12、花蓮光復實驗樣區光達資料	57 -
圖 5-13、出雲山苗圃實驗樣區初步單條航帶影像	59 -
圖 5-14、台灣杉單一像元光譜輻射值(radiance).....	60 -
圖 5-15、出雲山苗圃實驗樣區鑲嵌後影像	62 -
圖 5-16、出雲山苗圃實驗樣區光達資料	63 -
圖 6-1、維度縮減(Hsu, 2007)	65 -
圖 6-2、小波轉換用於光譜曲線之例(徐百輝，2003).....	67 -
圖 6-3、物件導向分類流程圖	70 -
圖 6-4、透過資料空間轉換改變資料分佈特性	73 -
圖 6-5、支持向量機分類示意圖	74 -
圖 6-6、卷積神經網路基本架構圖(Rawat and Wang, 2017)	76 -
圖 6-7、以深度學習進行遙測影像分類之基本架構圖(Li, et al., 2018) ..	76 -
圖 7-1、Hyperion 實驗區域影像	80 -
圖 7-2、實驗範圍選取之 8 個類別分布	80 -
圖 7-3、主成分轉換法之分類成果	83 -
圖 7-4、判別分析特徵萃取法之分類成果	84 -
圖 7-5、決策邊界特徵萃取法之分類成果	85 -
圖 7-6、DAFE 特徵分類法，7 個特徵波段之分類成果.....	86 -
圖 7-7、線性小波轉換特徵萃取法之分類成果	88 -
圖 7-8、非線性小波轉換特徵萃取法之分類成果	89 -
圖 7-9、花蓮光復實驗區影像	94 -
圖 7-10、花蓮光復實驗區地真資料分布	94 -

圖 7-11、主成分轉換法之分類成果.....	99 -
圖 7-12、PCT 特徵分類法，35 個特徵波段分類類別圖	100 -
圖 7-13、判別分析特徵萃取法之分類成果	101 -
圖 7-14、DAFE 特徵分類法，9 個特徵波段分類類別圖	102 -
圖 7-15、決策邊界特徵萃取法之分類成果	103 -
圖 7-16、DBFE 特徵分類法，10 個特徵波段分類類別圖	104 -
圖 7-17、線性小波轉換特徵萃取法之分類成果	106 -
圖 7-18、WFE 特徵分類法，5 個特徵波段分類類別圖	107 -
圖 7-19、非線性小波轉換特徵萃取法之分類成果	108 -
圖 7-20、NWFE 特徵分類法，26 個特徵波段分類類別圖	109 -
圖 7-21、不同特徵分類法之分類準確度	110 -
圖 7-22、影像分割參數設定	112 -
圖 7-23、花蓮光復實驗區物件導向分類法分類類別圖	115 -
圖 7-24、花蓮光復實驗區影像區塊用於深度學習法	119 -
圖 7-26、WCRN 深度學習法花蓮光復實驗區影像分類成果	121 -
圖 7-27、出雲山苗圃實驗區影像	123 -
圖 7-28、出雲山苗圃實驗區地真資料分布	123 -
圖 7-29、主成分轉換法之分類成果	127 -
圖 7-30、PCT 特徵分類法，26 個特徵波段分類類別圖	128 -
圖 7-31、判別分析特徵萃取法之分類成果	129 -
圖 7-32、DAFE 特徵分類法，4 個特徵波段分類類別圖	130 -
圖 7-33、決策邊界特徵萃取法之分類成果	131 -
圖 7-34、DBFE 特徵分類法，14 個特徵波段分類類別圖	132 -
圖 7-35、線性小波轉換特徵萃取法之分類成果	134 -
圖 7-36、WFE 特徵分類法，22 個特徵波段分類類別圖	135 -
圖 7-37、非線性小波轉換特徵萃取法之分類成果	136 -
圖 7-38、NWFE 特徵分類法，20 個特徵波段分類類別圖	137 -
圖 7-39、不同特徵分類法之分類準確度	138 -
圖 7-40、影像分割參數設定	140 -

圖 7-41、出雲山苗圃實驗區物件導向分類法分類類別圖	142 -
圖 8-1、各式無人機高光譜儀器	150 -
圖 8-2、不同的高光譜成像模式(Adão, et al., 2017)	154 -
圖 8-3、不同的高光譜感測器感光元件(Adão, et al., 2017)	155 -
圖 8-4、Headwall 高光譜儀航空整合套件 (Headwall, 2016)	156 -
圖 8-5、定翼型無人機 Sky Arrow 55 酬載艙示意圖	158 -
圖 8-6、NASA Sierra UAV 搭載 HyperScan VNIR Micro 示意圖	159 -

表 目 錄

表 1-1、工作時程預定表(甘特圖).....	- 15 -
表 4-1、候選樣區相關資訊.....	- 29 -
表 4-2、常見之成像光譜儀.....	- 32 -
表 5-1、出雲山苗圃實驗區之 EO-1 Hyperion 影像.....	- 45 -
表 5-2、本研究測區之飛航參數規劃	- 51 -
表 5-3、花蓮光復實驗區高光譜影像資訊	- 54 -
表 5-4、出雲山苗圃實驗樣區高光譜影像資訊	- 60 -
表 7-1、EO-1 Hyperion 影像 L1R 無法使用之波段說明(Ganesh et al., 2013)	- 78 -
表 7-2、各類別之像元數、訓練樣本數、檢核樣本數	- 81 -
表 7-3、主成分轉換法（特徵數 17 個）之分類結果	- 83 -
表 7-4、判別分析特徵萃取法（特徵數 7 個）之分類結果	- 84 -
表 7-5、決策邊界特徵萃取法（特徵數 33 個）之分類結果	- 85 -
表 7-6、線性小波轉換特徵萃取法（特徵數 23 個）之分類結果	- 88 -
表 7-7、非線性小波轉換特徵萃取法（特徵數 14 個）之分類結果	- 89 -
表 7-8、不同核函數之 SVM 分類成果.....	- 91 -
表 7-9、花蓮光復實驗區各類別之像元數	- 95 -
表 7-10、不同特徵分類法以不同像元樣本數之分類成果	- 96 -
表 7-11、主成分轉換法（特徵數：35）類別成果	- 99 -
表 7-12、判別分析特徵萃取法（特徵數：9）類別成果	- 101 -
表 7-13、決策邊界特徵萃取法（特徵數：10）類別成果	- 103 -
表 7-14、線性小波轉換特徵萃取法（特徵數：5）類別成果	- 106 -
表 7-15、非線性小波轉換特徵萃取法（特徵數：26）類別成果	- 108 -
表 7-16、選定之物件分類特徵	- 113 -
表 7-17、物件導向分類法類別成果	- 114 -
表 7-18、不同核函數之 SVM 分類成果.....	- 117 -
表 7-19、SVM 線性核函數類別成果.....	- 118 -

表 7-20、花蓮光復實驗區採用 CNN 演算法之實驗結果.....	120 -
表 7-21、CNN 演算法各類別誤差矩陣.....	120 -
表 7-22、出雲山苗圃實驗區各類別之像元數.....	124 -
表 7-23、不同特徵分類法以不同像元樣本數之分類成果.....	125 -
表 7-24、主成分轉換法（特徵數：26）類別成果.....	127 -
表 7-25、判別分析特徵萃取法（特徵數：4）類別成果.....	129 -
表 7-26、決策邊界特徵萃取法（特徵數：14）類別成果.....	131 -
表 7-27、線性小波轉換特徵萃取法（特徵數：22）類別成果.....	134 -
表 7-28、非線性小波轉換特徵萃取法（特徵數：20）類別成果.....	136 -
表 7-29、選定之物件分類特徵.....	140 -
表 7-30、物件導向分類法類別成果.....	141 -
表 7-31、不同核函數之分類成果.....	144 -
表 7-32、SVM 線性核函數類別成果.....	145 -
表 8-1、常見 UAV 高光譜感測器.....	151 -
表 9-1、交付成果及繳交日期時程表.....	164 -

壹、前言

1.1、計畫名稱

計畫名稱：「應用高光譜航遙測影像於土地覆蓋型調查之研究」。

1.2、計畫緣起

台灣森林分布超過國土之 60%以上，因地處亞熱帶，海拔分布自平地至最高山區，其高差超過 3000 公尺以上，因此在森林組成上具有極佳的多樣性與豐富度，然也因此增加了森林資源調查的困難度，自第三次森林資源調查以來，即開始嘗試利用航遙測技術輔助森林資源調查，用以大範圍掌握森林之組成、型態、面積及其蓄積狀況等。最近一次全島森林林型及其他土地利用型圖係於第四次森林資源調查期間完成，係由專業人員利用航照影像，採立體判釋圈繪方式，獲取國有林及公私有林境內森林林型邊界，以及主、次要樹種和組成比例等參數(第四次森林資源調查報告，2015)，惟相關作業皆投注相當之人力、經費與時程。

林務局及農林航空測量所(以下簡稱 貴所)為提升航遙測森林資源調查之效度與速度，曾委託學術單位研究及評估採航攝影像及衛星遙測影像自動分類方法，如航照數位多光譜影像應用於林地經營管理上之應用(陳朝圳，2011 年)、高解析度多光譜 Worldview-2 影像於森林資源調查之應用(林金樹，2013 年)，然此類採用傳統 4 波段多光譜影像進行林業土地分類判釋之成效，仍無法滿足森林資源調查所需的正確度，其對應採用之分析方法亦尚無法全面導入航遙測森林資源調查之流程中。

高光譜遙測感測器(hyperspectral remote sensing)為近 30 年來持續發展之遙測感測技術，不同於傳統多光譜影像將可見光至近紅外光區段分為四至十數個波段感測(以農航所航攝 ADS40 相機為例，擁有藍、綠、紅及近紅等四波段，近紅外波段範圍為 0.835-0.885 微米)，高光譜除獲得更廣之波長

感測域(波長 0.4-2.5 微米間，包含可見光波長範圍及更廣的紅外光段)，並將感測頻段依 5-10 奈米或更短寬度，切分為超過數十至數百個連續波段來記錄其輻射值，進而獲取接近真實光譜分布曲線的輻射反射資訊，從而可掌握更細緻的地物光譜資訊。一般認為高光譜影像能較傳統多光譜影像更有潛力應用於辨識細微的地物差異，目前在農業調查上，已有 90%以上之總體分類準確度(王驥魁等，2012)。

隨著現今機載高光譜影像及影像辨識及分類技術的發展，是否有機會將高光譜的光譜解析優勢應用於森林資源調查，並獲得超越目前分類結果較佳的林地與非林地(如果園、農田、崩塌地、草生地)偵測，或基本林型如針葉樹、闊葉樹、竹林及其他樹種等類別之成效，將有機會擴大使用林地資訊更新，並減少人為作業的主觀差異與負擔。因此，本案將高光譜影像之特性、特徵萃取及分類演算法、林地分類準確度，以及後續應用於森林資源調查之影像來源、作業模式等，進行進一步之測試評估。

1.3、計畫目的

就高光譜影像應用進行相關研究文獻及高光譜影像蒐集，並發展適合用於台灣地區森林環境之自動分類演算法，測試評估其於林地土地覆蓋型調查之能力、分析模式，並提出後續應用於森林資源調查之建議。

1.4、工作項目

本研究相關工作包括「研究文獻收集」、「樣區規劃及高光譜影像資料獲取」、「評估自動分類演算法」、「高光譜影像應用於全國森林資源調查之可行性評估」、「評估適合農航所定翼型無人機搭載之高光譜感測器」及「教育訓練」等工作項目。說明如下：

一、研究文獻蒐集

1. 蒐集各國應用衛載及空載高光譜影像於森林調查之實際案例文獻。
2. 蒐集及彙整最新的高光譜技術發展及資料處理演算法之研究文獻。
3. 提出將應用於本案之高光譜影像分析演算法至少 3 種。

二、樣區規劃及高光譜影像資料獲取

1. 參考台灣地區分布森林類型相關圖資挑選與設計實驗樣區，試驗樣區應包含實驗組與對照組，各組面積至少 25 km²，測試區域於成案後與本所共同討論後確定。
2. 衛載及機載高光譜影像蒐集：
 - (1) 衛載高光譜影像：可採用歷史資料進行研究。
 - (2) 機載高光譜影像(含光達資料)
 - (a) 規劃之平均地面解析度應優於 1.5 公尺。
 - (b) 波長應涵蓋可見光及近紅外光段，其中近紅外光波長範圍至少需達 1000nm 或以上，各波段間距小於 10nm，原始輻射解析度應達 12bit。
 - (c) 光達資料取樣規格須符合試驗所需。
 - (d) 須於期中會議前完成取像作業
3. 地真及其他研究測試資料蒐集

就全案研究所需之其他測試資料、地真資料蒐集等。全案資料蒐集費用(含影像)至少應達全部經費之 50%。

三、評估自動分類演算法

1. 測試及比較不同影像資料組合與處理方法(包括影像、波長範圍、波段間距、解析度、演算法等)，針對不同土地覆蓋情形，研究其影像分類特徵(包括光譜特徵、紋理及其他特徵等)。
2. 進行各種演算法、資料組合，以及分類數、類別定義等對分類準確度之影響並比較。

四、高光譜影像應用於全國森林資源調查之可行性評估

1. 評估高光譜影像及不同演算條件下，其應用於森林覆蓋類型分類及調查能力之優劣。
2. 並提出影像自動分類之最適資料組合、分類數，及類別定義等建議。
3. 提出高光譜影像取像、規格、分析模式、分類設定等面向建議，並提出適合於台灣地區森林林型之自動化分類演算法與流程。

五、評估適合農航所定翼型無人機(Sky Arrow 55)搭載之高光譜感測器

1. 蒐集各型無人載具高光譜感測器相關資訊及應用於森林調查之實際案例。
2. 就農航所定翼型無人機(Sky Arrow 55)之性能規格及本研究之成果，評估適合之高光譜感測器，提供該機後續擴充參考。如經評估無合適感測器，則應提出高光譜感測器選擇方案，並就定翼型無人機後續開發之規格提出建議。

六、教育訓練

於 108 年 12 月 11 日前辦理 1 場至少 4 小時的教育訓練，說明研究方法、工具及研究成果。

1.5、計畫時程

本計畫之執行時程為 108 年 3 月 30 日(決標次日)至 108 年 12 月 16 日，共 262 個日曆天。表 1-1 為本專案工作時程預定表(甘特圖)，以下針對表中之檢核點及重要時間點進行說明：

一、重要查核點：

1. 工作計畫書：已於 108 年 4 月 18 日繳交工作計畫書。
2. 修正後工作計畫書：已於 108 年 5 月 13 日繳交修正後之工作計畫書。
3. 期中報告書：已於 108 年 7 月 15 日繳交期中報告書。
4. 修正後期中報告書：已於 108 年 8 月 25 日繳交修正後期中報告書。
5. 期末報告書：已於 108 年 11 月 15 日前繳交期末報告書。
6. 成果報告書初稿：於期末會議審查通過次日起 10 日內繳交修正後之期末報告書，於 108 年 12 月 10 日繳交。
7. 成果交付：於 108 年 12 月 16 日前繳交，包括成果報告書及外接式儲存裝置 1 份，內含成果報告書電子檔、各期會議及工作會議之簡

報檔、及本案試驗相關影像檔案及其清單。

二、重要時間點：

1. 第一次工作會議：已於 108 年 4 月 15 日召開。
2. 第二次工作會議：已於 108 年 9 月 27 日召開。
3. 教育訓練：已於 108 年 12 月 5 日辦理 1 場 4 小時的教育訓練。

表 1-1、工作時程預定表(甘特圖)

工作內容項目		決標 次日 +20 日	108 04	108 05	108 06	108 07	108 08	108 09	108 10	108 11	108 12
1	撰寫及繳交工作計畫書		★4/18								
2	繳交修正後工作計畫書			★5/13							
3	研究文獻收集		▲4/15								
4	樣區規劃										
5	衛載高光譜影像資料蒐集										
6	機載高光譜影像資料獲取										
7	地真及其他研究測試資料蒐集										
8	評估自動分類演算法										
9	撰寫及繳交期中報告書					★7/15					
10	繳交修正後期中報告書						★8/25				
11	高光譜影像應用於全國森林資源調查之可行性評估										
12	評估適合農航所定翼型無人機(Sky Arrow 55)搭載之高光譜感測器								▲09/27		
13	教育訓練										
14	撰寫及繳交期末報告書									★11/15	
15	繳交成果報告書初稿										★
16	成果交付									12/5▲ 12/16★	★
預定進度累積百分比(%)		10%	20%	30%	40%	50%	65%	75%	85%	95%	100%
備註：											
本計畫重要查核點如下(即表中標示為★者)：											
● 工作計畫書：於決標日次日起 20 個日曆天繳交工作計畫書。 ● 修正後工作計畫書：期初會議審查通過次日起 10 日內。 ● 期中報告書：於 108 年 7 月 15 日前繳交期中報告書。 ● 修正後期中報告書：期中會議審查通過次日起 10 日內。 ● 期末報告書：於 108 年 11 月 15 日前繳交期末報告書。 ● 成果報告書初稿：期末會議審查通過次日起 10 日內。 ● 成果項目：於 108 年 12 月 16 日前繳交所有成果。											
本計畫重要時間點如下(即表中標示為▲者)：											
● 第一次工作會議：已於 108 年 4 月 15 日召開。 ● 第二次工作會議：已於 108 年 9 月 27 日召開。 ● 教育訓練：已於 108 年 12 月 5 日於農林航空測量所進行教育訓練。											

貳、實施方法及執行流程

根據上述之作業項目及內容，整體規劃本研究之執行流程如圖 2-1 所示，首先進行文獻收集，了解國內外高光譜相關研究之最新發展，同時與貴所討論樣區之規劃，決定樣區位置後隨即進行高光譜影像資料獲取，包括衛載資料蒐集及進行機載高光譜影像航拍任務；隨後利用本團隊所整理及自行發展之各種分類演算法對樣區高光譜影像進行分析及評估，並以分類成果為基礎評估應用於全國森林資源調查之可行性；本研究另將評估適合貴所定翼型無人機(Sky Arrow 55)搭載之高光譜感測器；最後本案執行期間將提供 1 場次 4 小時之教育訓練。




圖 2-1、本計畫執行流程

以下章節將針對各方法及執行成果進行詳細說明，第三章說明高光譜影像相關研究文獻蒐集及分析之結果、第四章說明本案實驗樣區之規劃結果、第五章說明本案實驗區高光譜影像之取像成果、第六章說明本案將採用的各種自動分類演算法、第七章進行了影像分類與成果之分析，第八章針對農航所定翼型無人機(Sky Arrow 55)可搭載之高光譜感測器進行評估及建議。

參、高光譜影像研究文獻蒐集

本團隊已蒐集相關研究及應用文獻，包括高光譜影像特性、相關特徵萃取及分類演算法，以及高光譜影像應用於森林源調查等成果，說明如下。另本團隊所提出之三種不同分析演算法，將於第 6 章進行詳細說明。

3.1、高光譜影像之特性與常見分析方法

高光譜影像為 1980 年代中期所發展的成像光譜儀(imaging spectrometer)拍攝而成之影像，其光譜範圍包含了可見光、近紅外光、短波紅外光、中紅外光及其他波譜範圍，並劃分為幾十至幾百個連續的波段資訊，每一波段區間較狹窄，通常僅約 10nm (Goetz, et al., 1985)，圖 3-1 為成像光譜儀的成像示意圖，當掃描線對目標掃描後，光線透過分光鏡將地面反射之光線分為數百個波段，並由面陣列的感光元件記錄不同波段的光譜反射值，多個掃描線組成一個場景，成像後形成三維的影像立方體(image cube)，同時，影像的每一像元形成完整且連續的光譜曲線，由於不同地物對於各個波長之光線均有不同的反射與吸收反應，形成該地物獨特的光譜反射與吸收曲線。因此，高光譜影像除了展現二維的空間資訊外，光譜曲線亦提供豐富且細緻的地物光譜資訊，有助於提升地物辨識與土地使用分類之精度(徐百輝, 2003)。

在進行高光譜影像分析時，也由於光譜解析度的提升，遭遇到相關之挑戰。首先，相較於常見之多光譜影像僅有數個波段，高光譜影像的波段數增加至數十或數百個波段，即單一影像的資料量顯著的增加，同時每一波段區間較狹窄，不同波段之間光譜反射值具有高相關性，亦或是光譜資訊增加並未同時提供較多的資訊進行影像資料分析，即高光譜影像具有相當高的冗餘量(redundancy)，圖 3-2(a)所示為實際 AVIRIS 高光譜影像之影像立方體，可看出光譜方向的資料量相當龐大，圖 3-2(b)為該高光譜影像之相關矩陣(correlation matrix)以灰階影像表示，顯示出高光譜影像不同波段之間具有高冗餘性。此外高光譜影像之高維度資料統計特性，使得以傳統統計理論為基礎的影像分類方法並無法直接適用，最主要的原因是在訓練樣本數目

有限的情況下，無法正確估算類別的相關統計量，造成分類成果不可靠、精度不佳，甚至無法分類的情形，這種因為高資料維度所造成的問題一般稱為維度的詛咒（curse of dimensionality）(Bellman, 1961)。一般透過適當的維度縮減（dimensionality reduction）可有效解決前述之問題，而常用的維度縮減方法為特徵萃取（feature extraction）。常見的特徵萃取方法包括主成份轉換法（principal component transform, PCT）、判別分析特徵萃取法（discriminant analysis feature extraction, DAFE）、決策邊界特徵萃取法（decision boundary feature extraction, DBFE）、小波特徵萃取法（wavelet-based feature extraction, WFE）與 Hilbert-Huang transform（HHT）等(Lee and Landgrebe, 1993; Hsu et al., 2002; Landgrebe, 2003; Hsu, 2007)。經過降維且保留重要資訊的光譜特徵影像即可利用傳統的統計分析或分類方法進行分類。




圖 3-1、成像光譜儀之成像示意圖（徐百輝，2003）




圖 3-2、實際高光譜影像之(a)影像立方體與(b)相關矩陣(白：1/-1，黑：0)

傳統航遙測影像分類大多採用逐像元 (pixel-based analysis) 的分析方式，而逐像元分類容易產生椒鹽現象 (salt and pepper effect) 以及分類後區塊不完整的情況，若採用以物件為基礎的影像分析 (object-based image analysis, OBIA) 方法將可以有效改善此一情形(Zhang and Huang, 2010; 李庭誼, 2011)。而隨著空間解析度的提升，加入影像的空間特徵更有利於地物辨識，空間特徵主要來自於鄰近像元的空間關係，以平滑度、粗糙度或規律性等作為特徵，一般通稱為紋理 (texture) (Gonzalez and Woods, 2002)。Zhang and Huang(2010)針對高光譜影像利用 PCT、DAFE、MNF (maximum noise fraction) 進行維度縮減後，再加入 Haralick 等(1973)提出的紋理指標，引入物件導向 (object-oriented) 的概念，以多層解析度之概念將影像分割為物件，再進行影像分類，其實驗結果證實加入紋理和以物件為基礎的分類皆能有效提高光譜影像的分類準確度。李庭誼(2011)同樣結合高光譜影像的光譜特徵及空間紋理特徵，並建立物件導向的分類流程，研究中利用小波光譜分解縮減高光譜影像的維度，將所萃取出的光譜特徵進行空間紋理分析，再利用所得之混合特徵組進行物件導向分類，根據實驗結果結合光譜及紋理的物件導向分類流程可以達到 94% 的分類準確度，同時對於類別分離度較差的類別也可以準確分類。

近年來，除了訊號及影像處理方法之外，以自我學習方式提昇分析效能的機器學習 (machine learning) 演算法亦常被應用在遙測影像資料的分析及處理上。機器學習為人工智慧研究領域中的一種方法，其主要利用過去的經

驗或輸入的資料不斷地學習，以優化或改進所使用分析或分類函數的效能。常見的機器學習演算法包括人工神經網路(artificial neural networks)、貝式分類器(Bayesian classifiers)、決策樹(decision tree)、隨機森林(random forests)、支持向量機(support vector machines, SVM)、群聚(clustering)、k-鄰近法(k-nearest neighbor, KNN)、關聯式規則學習法(association rules learning)、稀疏表示(sparse representation)、基因演算法(genetic algorithm)等(Mitchell, 1997; Kubat, 2015; Sarkar et al., 2018)。機器學習可依據不同的應用設計不同的學習方式以及分類函數的形式，因此經常應用在資料分類(classification)、群集分析(clustering analysis)、或資料迴歸(regression)等等。而在高光譜遙測影像的應用中，機器學習主要應用在特徵萃取及選取、像元的群集分析及影像分類上 (Waske et al., 2009)。機器學習的優點是無需事先了解太多資料的特性，資料的分佈也不一定必須是常態分布，比較符合實際的遙測影像資料分布狀況。其主要缺點為演算法的複雜度較高，需要較多的計算時間，且某些演算法無法解決非線性資料分布的問題。

Camps-Valls and Bruzzone(2005)運用機器學習方法於高光譜影像分類，包含了線性判別分析(linear discriminant analysis, LDA)、支持向量機(SVM)等方法，探討在高維度、具有雜訊之資料，以及有限訓練樣本情況下，不同方法之分類準確度、計算量；透過實際 AVIRIS 影像實驗，以支持向量機的方法最佳。Demir and Ertürk(2008)同樣將支持向量機用於高光譜影像分類，並利用 empirical mode decomposition (EMD) 做為前處理之工具，其成果比直接採用原始高光譜影像於 SVM 分類的結果更佳。Banki and Shirazi(2009)則將小波轉換整合支持向量機於高光譜影像分類，透過實際 AVIRIS 高光譜影像分類實驗，採用小波-支持向量機的分類成果更佳。Jia 等(2019)提出因地物的空間分布通常具有規則性及區域連續性，結合 Gabor filter 對於高光譜影像的光譜及空間資訊建構三維的濾波器，再利用 PCT 降低維度並利用 SVM 分類，在實際高光譜影像實驗中，其成果均有良好的表現。

本研究彙整不同的高光譜技術發展及資料處理演算法之相關文獻，並以文獻為基礎提出高光譜影像分析之演算方法。

3.2、高光譜影像於森林調查之應用

近年來已有許多利用高光譜影像於農業或森林地物調查之相關應用；王驥魁等(2012)提出結合全波形光達及高光譜影像資料應用於地物分類，其研究中應用 ATLM Pegasus 光達系統及 Itres CASI-1500 高光譜系統，獲取曾文溪主流上游河段之光達及高光譜影像資料，利用統計原理為基礎的融合方式，分別以最小噪聲轉換（minimum noise fraction transform, MNF）與主成份分析法針對高光譜影像與光達回波影像轉換後，挑選較佳的成份軸形成融合影像，融合後以最大似然法進行地物分類，融合保留兩種資料的特性，對於水體、建地茶園等類別的判釋率提升，其結果顯示分類準確度由 89.55% 提升至 93.82%，但其分類類別仍以水體、森林、建地、草地等較大的土地使用分類進行分析。加拿大自然資源部（Natural Resources Canada）也將高光譜影像根據其特性應用於森林資源調查及森林之健康診斷，該單位研究利用衛載高光譜影像調查卑詩省（British Columbia's coast）的 5 種樹種，也利用機載高光譜影像針對西岸的森林樹冠層，調查其葉綠素、含水量、氮含量等。另有相關文獻則是利用機載 HyMap 高光譜影像將不同的光譜組合計算植生指標（vegetation indices, VI）或計算出 Red-Edge Position(REP) 參數，亦或是利用迴歸分析，分析森林資源的結構、特徵，以研究森林資源相關議題(Cho et al., 2009；Gholizadeh et al., 2016)。

近年亦有許多利用高光譜影像在森林樹種的分類；Dalponte 等(2012)則是分別利用高光譜與多光譜影像分別整合點雲密度不同的光達資料針對義大利特倫特省（Province of Trento）於阿爾卑斯山南部的研究區域針對 7 個闊葉與針葉樹種進行分類，研究中採用了支持向量機與隨機森林作為分類演算法，利用高光譜影像結合高密度點雲資料（每平方公尺約 8.6 點）萃取出特徵分類後可以得到較好的成果，其中類別定義詳細至不同樹種時，分類準確度為 76.5%，若類別定義較粗略則分類準確度可以達到 93.2%，然而考量資料取得成本，利用低密度的點雲資料結合高光譜影像進行森林樹種分析，已是充足且可獲取有效的資訊，對於後續森林研究有一定之幫助。George 等(2014)則是利用 EO-1 Hyperion 影像分析印度喜馬拉雅西部的森林

樹種，研究中 Hyperion 影像經過前處理去除雜訊波段、FLAASH 大氣校正和條紋雜訊改正，獲得 160 波段的無雜訊影像，而後採用統計分析 Wilk's Lambda 方法選取 29 個波段，再分別利用光譜角匹配(spectral angle mapping, SAM) 與支持向量機進行分類，分類選取針葉及闊葉樹種 6 種，其實驗結果採用支持向量機的分類準確度為 82.27%、Kappa 指標為 0.79，優於採用 SAM 的分類準確度 74.68%、Kappa 指標 0.70，另外也比較用 Landsat TM 影像進行分類，其分類準確度只有 69.62%、Kappa 指標為 0.65，則該研究提出利用部分 Hyperion 影像即可有效的做森林樹種分辨之研究。Shang 和 Chisholm(2014)利用支持向量機、隨機森林等機器學習方法於機載 HyMap 高光譜影像分類，澳洲比克羅夫特半島 (Beecroft Peninsula) 尤加利樹森林為實驗區域分析，針對其中 7 種樹種分別透過葉片、樹冠以及森林的不同觀察尺度，對樹種進行分類與分析，研究中透過不同樹種的光譜曲線，找出特定波段(如：497nm 和 680nm 波長的葉綠素吸收區間、725nm 波長的 red-edge 區間等)可以做為樹種辨識的特徵，以及透過高光譜影像進行樹種分類，以隨機森林方法分類所獲得的分類結果為最佳，同時該研究也提出的機器學習方法用於高光譜影像分類對於澳洲森林樹種的分類有實際應用之可能性。

Dian 等(2015)則利用機載 CASI-1500 高光譜影像，其具有高空間解析度及光譜解析度的特性，同時結合空間與光譜特徵於高光譜影像分類，實驗區域為中國黑龍江省涼水自然保護區 (Liangshui National Natural Reserve)，並針對冷杉(fir)、赤松(red pine)、落葉松(larch)3 種針葉樹和樺樹(birch)、柳樹(willow) 2 種闊葉樹，以及水體、建物、雲作為類別進行分類，其研究方法先利用最小噪聲轉換降低高光譜影像資料的維度提取光譜特徵，再利用灰階共生矩陣 (GLCM) 計算得到的紋理特徵，最後將利用支持向量機進行分類，在使用不同核函數的實驗中，利用線性核函數所獲得的結果最佳，其分類準確度達 85.92%，因此整合高光譜影像的光譜及空間特徵確實可提升樹種的分類結果，圖 3-3 即為該研究中採用的高光譜影像及分類後的成果。



Fig. 1 Combined image of the research area (R:680 nm, G:550 nm and B:450 nm)




圖 3-3、研究中採用之高光譜影像與分類成果 (Dain et al., 2015)

Baldeck 等(2015)利用機載高光譜影像透過兩種支持向量機方法 (binary SVM、biased SVM)，針對巴拿馬巴羅科羅拉多島 (Barro Colorado Island) 的熱帶雨林內 3 種不同樹種進行分類並且繪製出不同樹數種的位置，透過 biased SVM 分類可以得到 94-97%的分類準確度，並且最後獲得 2107 棵 3 種目標樹種的位置 (如圖 3-4)，此研究透過有效的演算法找出目標樹種，可有助於熱帶雨林多變的生態系統研究。




圖 3-4、利用 SVM 分類獲取目標樹種的預測地圖(Baldeck et al., 2015)

同樣是針對森林樹種繪製地圖，Sommer 等(2015)針對德國巴伐利亞森林國家公園（The Bavarian Forest National Park）機載高光譜影像和全波形光達資料並整合現地觀測資料，針對森林生態系統的結構與狀態進行分析，透過選取高光譜影像的波段資訊、計算植生指標，再結合光達資料所得的坡度/坡向、高程與樹高資料，利用隨機森林演算法對於 13 種樹種之樹冠層資料進行分類，所獲得的分類準確度可超過 90%，分類成果如圖 3-5，同時獲取了大面積的森林物種資訊，對於後續建構森林的資料庫、生態研究有幫助。




Figure 9: Image section of the classification result.

圖 3-5、利用隨機森林演算法於高光譜影像、光達資料的森林樹種分類結果(Sommer et al., 2015)

Lim 等(2019)同時利用 Hyperion 高光譜資料及 Sentinel-2 多光譜資料對於南韓江原道廣陵的 Korea National Arboretum(KNA)與中國長白山的森林中紅松 (Korean pine)、日本落葉松 (Japanese larch) 兩種針葉樹種分類。除了利用光譜資料外，該研究中亦逐步加入地形資料和紋理資料，分別利用隨機森林、支持向量機等方法進行樹種分類，隨著加入的資訊增多隨機森林的分類準確度由 82%提升至 88%、支持向量機的分類準確度由 85%提升至 90%。在 EO-1 衛星已經除役的狀態下，Hyperion 於 2017 年之後已停止新增影像，因此研究中亦嘗試將舊有 Hyperion 影像中萃取部分波段與 Sentinel-2 影像整合後分類，實驗結果中顯示兩種分類方法的分類準確度仍可以達到 86% 和 89%。而長白山地區的訓練資料取得相對不容易，研究中也嘗試利用 KNA 地區的訓練資料用在長白山的影像分類中，但其成果不佳，若是將兩個實驗區域的訓練資料結合隨機森林和支持向量機的分類準確度卻可以達到 99% 及 97%，因此在該研究中則可以看到不同資料類型、特性及訓練資料的整

合可以對於高光譜影像於樹種分類上有所提升。從前述之近年高光譜影像用於森林樹種的研究已被廣泛的應用，同時除了單純的光譜資訊外，相關研究亦加入了多樣的資訊或特徵，如：透過光譜值計算的植生指數，機載高光譜影像之空間解析度較佳則可以進一步計算影像紋理，或是加入光達資料將地形或高程資料納入分析的特徵。在分析的方法上，近年研究也多以機器學習方法為主，包含支持向量機、隨機森林等，更可以將多樣的光譜、紋理或地形資訊整合，以獲得更佳的森林資源調查之成果。

除了利用衛載或機載高光譜影像於森林資源調查分析，近期則有研究分別利用定翼和旋翼無人載具搭載多光譜感測器、光達及高光譜感測器，針對美國亞利桑那州北部一處森林進行調查，其結果顯示多光譜影像可以獲得高空間解析度影像適合監測森林變化，而高光譜影像結合光達除了可以透過光譜變化分辨樹種，光達高程資料可以分辨樹高，可適用於大範圍的森林變化監測 (Sankey et al., 2017)。Cao 等(2018)利用無人載具高光譜影像針對中國廣東省珠海地區的淇澳島 (Qi'ao Island) 紅樹林，以物件導向的影像分析方式辨識紅樹林樹種，其研究方法是先利用 UAV 高光譜影像及數值地表模型 (DSM) 進行影像物件分割，後續計算物件的光譜特徵、紋理特徵及植生指標等，最後利用 k-鄰近法 (KNN) 及支持向量機進行分類。研究中只利用光譜、紋理和植生指標等特徵 KNN 及 SVM 的分類準確度分別為 76.12%、82.39%，利用 SVM 方法進行分類所獲得成果較佳，再加入由 DSM 獲取的樹高作為特徵進行分類，KNN 與 SVM 的分類準確度則分別提升至 82.09% 與 88.66%，是由於不同紅樹林樹種的光譜曲線相似，但平均樹高有所差異使得分類成果有所提升，因此該研究提出 UAV 高光譜影像之分類方法提升了紅樹林樹種的分析效能。

以上所述為本團隊根據此研究需求所進行的文獻回顧，包括許多利用高光譜影像於森林資源之研究或森林調查之應用，本研究彙整相關的森林調查的實際案例文獻，並歸納整理出可採用的高光譜資料處理及分析方法。

肆、樣區規劃、高光譜影像資料獲取

本章節根據研究的目標說明樣區規劃與選定、高光譜影像資料獲取和處理流程。

4.1、樣區規劃

本研究主要目標之一是發展適合用於台灣地區森林環境之高光譜影像自動分類演算法，並測試評估其於林地土地覆蓋型調查之能力、分析模式，因此樣區規劃必須是在具有豐富地表覆蓋類型的區域。本研究將參考台灣地區分布森林類型相關圖資挑選與設計實驗樣區，實驗樣區須包含實驗組與對照組，各組面積至少 25 Km²，經農航所建議，初步規劃候選樣區分布如圖 4-1 所示，各區域之說明如表 4-1 所示。




圖 4-1、候選樣區分布圖

表 4-1、候選樣區相關資訊

驗證參考 資料來源	地點	地標	圖幅	主要分布樹種及土地覆蓋型
	資料說明		執行高光譜計畫之考量	
林業試驗所	宜蘭福山	福山研究中心	97224093	闊葉樹天然森林，由多種闊葉樹種組成，且大小不一
	500*500 平方公尺樣區，總面積 25 公頃；進行每木調查，紀錄座標位置、胸高直徑、樹種名稱		機載高光譜影像解析度若為 1.5 米，是否可檢視到林木個體?且可能有對位上的誤差(樹冠中心不等於量測之座標位置)	
農林航空測量所	花蓮光復	大農大富平地森林園區	96202047	闊葉樹人工造林地，由多樹種、多塊重複組成，主要樹種包括茄苳、印度紫檀、台灣欒樹、光臘樹、杜英、楓香..等
			96202046	
			96202056	
			96202057	
			96202066	
	總面積 1250 公頃，每塊人工純林造林面積大小不一，平均面積為 0.5 公頃		闊葉樹種因樹冠型態相似，森林資源調查人工判釋時不易區分，多歸為"其他闊"一大類；因此若能以高光譜影像研究區分不同闊葉樹種為機會。	
林務局第四次森林資源調查及檢訂調查成果	合歡山	合歡山小風口	96212032	針葉樹(鐵杉、冷杉、雲杉、松樹)、其他闊葉林、箭竹、道路
		中橫霧社支線	96212022	
		中橫 8	96212012	
	此區域圖徵圈繪面積較大塊且多為針葉樹混淆林，需再細挑訓練樣區		25 平方公里樣區內能掌握之森林類別有限	
	棲蘭	神木園區(退輔會森林保護處管理)	96222067	針葉樹(檜木、柳杉等)人造林、檜木天然林(神木園區)、其他闊葉林
			96222068	
			25 平方公里樣區內能掌握之森林類別有限	
	出雲山苗圃	大雪山社區(台中市和平區)	95212006	果園、道路、定居地、針葉樹人造林，樹種包括肖楠、杉木、柳杉等、單桿竹、其他闊葉樹
			95212007	
			95212016	
			95212008	
			25 平方公里樣區內能掌握之森林類別有限	

上述候選實驗區經 108 年 4 月 15 日第一次工作會議後作成決議，將以花蓮光復及出雲山苗圃為本計畫之實驗區域，其航拍範圍分別如圖 4-2 及圖 4-3 所示，詳細航線規劃流程與細節將於 5.2、節說明。



圖 4-2、花蓮光復樣區航拍範圍




圖 4-3、出雲山苗圃樣區航拍範圍

4.2、衛載及機載高光譜影像蒐集

目前成像光譜儀之發展已日趨成熟，若根據其載具的形式可概分為機載（或稱空載，air-borne）與衛載（space-borne）兩種（如表 4-2 所示）。在機載方面，美國航空暨太空總署（NASA）噴射推進實驗室（JPL）所發展的 AVIRIS（Airborne Visible/Infrared Imaging Spectrometer）成像光譜儀可以說是最具代表性的感測器，其包含 224 個連續波段，波長涵蓋範圍為 0.4 至 2.5 μm ，每一波段區間約為 10nm。HYDICE(Hyperspectral Digital Imagery Collection Experiment)同樣為空載成像光譜儀，為 Naval Research Laboratory 與 Hughes-Danbury Optical Systems, Inc.所發展，包含 210 個波段，波長涵蓋範圍為 0.4 至 2.5 μm 。國內目前亦有民間公司引進加拿大 Itres 公司的 CASI-1500 高光譜成像儀，其在可見光至近紅外光（0.38 至 1.05 μm ）之間提供了 288 個波段的光譜資料。澳洲 HyVista 公司則發展 HyMap 機載成像儀，提供了 128 個波段，波長涵蓋範圍為 0.45 至 2.45 μm 。

衛載高光譜感測器目前仍是許多國家正著手積極研發的項目，由 NASA Goddard Space Flight Center 所發展搭載於實驗衛星 EO-1 上的 Hyperion 高光譜儀，其包含了 242 個波段，波長涵蓋範圍為 0.4 至 2.5 μm ，發射後提供給全球許多地區相當豐富的高光譜影像應用。EO-1 衛星已於 2017 年 3 月停止運作。中國大陸於 2018 年 5 月發射的高分五號(Gaofen-5)衛星搭載有一高光譜儀 AHSI(Advanced Hyperspectral Imager)，其可在 0.4 至 2.5 μm 的光譜範圍內收集具 330 個波段的高光譜影像，可以說是目前全球唯一的衛載高光譜儀。而正在發展中的衛載高光譜儀包括義大利太空機構 Agenzia Spaziale Italiana (ASI)於 2008 年開始發展的 PRISMA，其為一中等解析度高光譜成像的任務，包含 249 個波段，波長涵蓋範圍為 0.4 至 2.5 μm ，預計 2019 年 3 月發射。此外，德國所發展的 EnMap 計畫(Environmental Mapping and Analysis Programme)亦規畫有一高光譜感測器，預計發射時間為 2020 年。

表 4-2、常見之成像光譜儀

感測器	載具型態	發展機構	波段數	波長涵蓋範圍(nm)
AVIRIS	機載	Jet Propulsion Lab, NASA	224	400-2500 (波段區間 10nm)
HYDICE	機載	Naval Research Lab	210	400-2500
CASI-1500	機載	加拿大 Itres 公司	288	380-1050
HyMap	機載	澳洲 HyVista 公司	128	450-2500 (波段區間 15-20nm)
Hyperion	衛載 (EO-1)	NASA Goddard Space Flight Center	242	400-2500
AHSI	衛載 (Gaofen-5)	China Aerospace Science and Technology Corporation	330	400-2500
PRISMA	衛載	Agenzia Spaziale Italiana	249	400-2505
EnMap	衛載	German Aerospace Center	262	420-2450

4.3、衛載高光譜影像蒐集

表 4-2 中所述衛載高光譜感測器中，大陸的高分五號仍在測試階段，PRISMA 及 EnMap 衛星則尚未發射，因此目前唯一可以取得的衛載高光譜影像為美國 EO-1 的 Hyperion 歷史影像，該影像可直接於美國 USGS EarthExplorer 網站進行搜尋並下載，如圖 4-4 所示，分別將出雲山苗圃和花蓮光復實驗樣區位置與 EarthExplorer 歷史影像對照，其中接近中央山脈由北到南為台中市山區至高雄市山區，有一歷史航帶，出雲山苗圃位於該航帶上方，故蒐集與出雲山苗圃樣區最多重疊之 Hyperion 高光譜影像，作為進一步分析評估之用，5.1、節將說明歷史 Hyperion 高光譜影像之細節。




圖 4-4、USGS EarthExplorer 網站影像查詢畫面

4.4、機載高光譜影像蒐集

一、飛行掃瞄儀器

機載高光譜儀主要為獲取窄波段連續光譜影像數據，使每一個像元為幾乎連續的光譜數據。本案高光譜儀將採用 Itres CASI-1500，為最廣泛之商用機載光譜儀(如圖 4-5)，具有最高可達 288 波段之可記錄波段數及 380 至 1050nm 光譜範圍，波段數量需搭配現地的航高以及飛行航速之規劃，才能決定最終之波段數量。本儀器屬於推帚式掃瞄儀(Pushbroom)，推帚式是利用線型掃描器理念，將掃瞄成像於光譜儀的狹縫上，再由光譜成像於面型 CCD 感測器(area CCD array)，一維為光譜軸，另一維為空間軸，當飛機飛行時，二維 CCD 元件上的一行影像被重複讀出，進而取得涵蓋相應地面之高光譜影像。以上高光譜儀像係規格詳見附件 B-1。




圖 4-5、高光譜儀器介紹(a)CASI-1500 設備；(b)儀器波段

本案於拍攝高光譜影像時，同時蒐集光達點雲資料，以獲取地形資訊作為高光譜影像幾何改正之用。一般空載光達整體系統包括雷射掃瞄系統硬體元件、飛行載台(固定翼飛機或直昇機)、GNSS 與 IMU 元件及數據處理軟體等整合構成作業系統。本案所用空載光達儀為加拿大 Optech 公司生產型號為 ALTM Pegasus 雷射掃瞄儀，其規格如圖 4-6 所列。雷射掃瞄系統結合雷射測距、光學掃瞄、GNSS 及 IMU 等技術，能快速獲得掃瞄點三維坐標及反射強度。以上雷射掃瞄系統硬體規格詳見附件 B-2。



圖 4-6、空載光達儀器規格

二、飛航作業申請

本案飛航作業皆依照「國土測繪法」及「實施航空測量攝影及遙感探測管理規則」等相關規定，檢附相關文件向內政部提出申請，並於飛航掃瞄前一併向民航局主管單位提交飛航申請計畫，並且需避開國防部頒布之全台軍事區域，也就是禁航區域，待許可後選擇目標區域合適之天候，進行飛航影像獲取任務。

三、掃描規劃

掃瞄事前規劃需考慮掃瞄區範圍、實施地形的高度、預定規劃的載體航高、掃瞄儀掃瞄角度、每一航線涵蓋地面寬度、航線間的重疊率、交叉航線位置及航區管制等條件，故於實際飛航前，必須規劃詳細的飛航資訊、展繪飛航規劃圖與提出飛航申請，以確定飛航任務之可行性與資料完整性。掃瞄任務之規劃會影響影像的遮蔽程度、航帶檢核與重疊區分析等重要資訊，飛航規劃作業的方法與步驟流程說明如下：

1. 地形分析：分析地形最高、最低、平均高度、坡度，量測區面積等，分析測區地形特徵。
2. 決定航帶之間的重疊量(Overlap)：高光譜因為考慮時間和天候得視實際情形在空中進行重疊量的調整，一般重疊率需大於 20%。
3. 飛機速度：決定影像空間與光譜解析度，依規劃設計符合所需。
4. 決定航線：由航高、地面地形高度變化、掃瞄旋角視域 FOV，計算帶寬的變化，進一步依據設計的航帶重疊量，規劃出航線與航線的間距。
5. 空載高光譜系統之影像解析度需達 1.5 公尺解析度，且光譜範圍涵蓋可見光及近紅外波段(400~1000 nm)，波譜寬度約 10 nm。
6. 參考光達掃瞄公式及以往豐富執行經驗，以規劃軟體試算設計參數，規劃求出掃瞄角度(FOV)、航高、雷射發射頻率、掃瞄頻率、航高、航向和航帶重疊率參數組合，確保點雲品質符合所需。

飛航操控人員因藉由 GPS\IMU 之輔助，可直接於飛機上了解高光譜儀飛航之影像即時狀況，包含蒐集之資料品質及高光譜影像重疊率等

資訊。若遇突發狀況，能立刻決定是否補飛作業。此外為了能於每次掃瞄時獲得最佳之高光譜品質成果，將選擇測區上空無雲之天候進行資料獲取。一般臺灣實務高光譜影像作業將以離地高約 2000 m，FOV 為 40°之掃瞄參數進行作業。獲取地面解析度為 1m 之影像，且至少可記錄 72 個波段數，但最終波段數得依據上述飛航規劃作業，決定可獲取的對應波段數量，點雲部分則可獲取密度每平方公尺 1 點之成果。

四、機載光達處理流程

空載 LiDAR 資料前處理作業包括原始資料整理備份、飛航掃瞄航跡 POS 解算及 LiDAR 原始點雲產出。雷射掃瞄資料作業流程如圖 4-7 所示。

(一) 掃瞄軌跡解算

以軌跡解算軟體將地面 GNSS 主站資料及空載光達系統之 GNSS 資料進行結合，過程中需輸入地面 GNSS 主站之坐標值，設定相關參數應用如 C/A Code、L1 相位值及利用 L2 載波處理電離層效應後，以動態差分原理求解 LiDAR 掃瞄儀航跡之精確三維坐標。最終將載體 IMU 記錄資料與所解算的 GNSS 坐標結合於三維航跡上，求解出 LiDAR 掃瞄時掃瞄儀之瞬間三維位置與姿態資訊(POS)，一般稱為 Sbet 飛航軌跡資料。

(二) 原始點雲產出

以計算高精度 POS Sbet 軌跡技術，經由結合雷射掃瞄測距(掃瞄角與距離)，逐條航線求解原始點雲和影像(Applanix, 2017)，如圖 4-8 所示，原始雷射點雲成果。每條航線原始點雲產出後，需逐條檢驗資料品質，包括點雲密度、不合理點位，及重疊區點雲高程內部精度檢核等。




圖 4-7、空載光達資料作業流程




圖 4-8、點雲解算產製處理流程

五、機載高光譜影像處理流程

高光譜資料獲取後將依圖 4-9 高光譜整體影像處理流程進行高光譜資料產製，整體流程包含幾大重要步驟，1.輻射校正、2.率定作業、3.幾何校正、4.影像鑲嵌，最終才完成飛航區域高光譜影像的產製，進而提供後續影像應用分析，相關步驟和流程如下說明：




圖 4-9、高光譜產製流程

(一) 輻射校正(Radiometric Correction)

獲取原始航帶資料數位值(DN 值, Digital Number Value)後, 配合原廠率定檔案, 依據飛航時之光圈大小利用 ITRES 軟體(RadCor.exe)進行輻射校正, 校正後可得到.PIX 檔案(Radiance 值)以及 ATT 檔案。PIX 為 PCI 格式的影像檔, ATT 檔案即為 CASI-1500 的飛航資料, 其使用的時間記錄為 CASI-1500 的內部時間。轉換示意圖如圖 4-10。




圖 4-10、輻射校正前後示意圖

(二) 光束法平差率定作業(Bundle Adjustments)

以數位量測相機進行攝影測量領域的分析應用, 首先須有精確的幾何率定參數, 才能有精度較高的測量成果; 本案高光譜儀 CASI-1500 亦需進行率定以獲得感測器內方位元素。透過感測器率定, 將影像量測坐標轉換到以相機內部幾何定義的像空間坐標, 建立像物空間對應點的幾何約制關係。高光譜資料產製時, 使用原廠提供軟體進行(圖 4-11), 利用光束法反算相機率定參數, 經已知且均勻布設的物空間量測點(特徵點), 確定三維空間坐標系, 並藉多張影像重疊範圍選取航帶的控制點(圖 4-12), 配合光束法平差, 可同時求解內外方位參數及物空間坐標, 產製後續正射化鑲嵌影像, 提供後續空間資訊上的應用及分析, 整體率定步驟如下:

1. 同步姿態資料，利用 ITRES 軟體產生一批次檔案(Attsync)，執行此批次檔案即將輻射校正中所產出之 ATT 檔案轉換成 ATP 檔案，ATP 檔案的格式與 ATT 檔案格式相同，其目的是將 CASI-1500 時間轉換成 GPS 時間。
2. 轉換 GPS 資料，利用 ITRES 軟體產生一批次檔案(Makegps)，執行此批次檔即將 GPS 檔案轉換成標準二進位檔案格式(.gps)，並且將 GPS 位置轉換至 WGS84 系統。




圖 4-11、原廠軟體介面

3. 結合位置及姿態資料，加入 LEVER ARMS 資料並利用 ITRES 軟體產生一批次檔案(Formnav)，在此批次檔案中須將坐標系統改為 TWD97 系統以符合需求，執行此批次檔後則根據 ATP 檔的姿態資料以及 GPS 資料產生一 RNV 檔，RNV 檔資料則結合了位置及姿態。
4. 調整航行資料，此步驟須加入由光束法平差產生的六個幾何偏移參數，利用 ITRES 軟體產生一批次檔案(Navcor)，執行此批次檔即將原始檔案(RNV)轉換成一校正過後之檔案(CNV)。




圖 4-12、特徵點與控制點分佈示意圖

(三) 幾何校正(Geometric Correction)

未經幾何校正之影像會根據飛航的方向產出沒有方向性及未帶坐標之影像，如圖 4-13 校正前之影像為扭曲變形沒有正確方向以及坐標，校正後為一般常見之正確並帶坐標之影像，而校正的資料以空載光達產製之 1 公尺網格高程資料進行幾何校正，利用 ITRES 軟體產生程式(Geocor.exe)之批次執行檔案，執行後產製出之 PIX 檔案即為幾何校正影像檔案，一個航帶一張影像(如圖 4-14 所示)。




圖 4-13、幾何校正前後影像比對




圖 4-14、整條航帶幾何校正成果

(四) 影像鑲嵌

影像鑲嵌為將單條航帶影像拼接成同幅或同測區影像所需進行之步驟，利用 ITRE 軟體或目前市面常見影像軟體(ENVI、ArcGIS)進行影像鑲嵌工作，即為產生一鑲嵌的圖幅資料。圖 4-15 為最後影像鑲嵌圖成果示意圖。




圖 4-15、影像鑲嵌成果示意圖

伍、實驗樣區高光譜影像蒐集

5.1、實驗樣區衛載高光譜影像蒐集

根據第一次工作會議討論結果，本計畫之實驗區域選定為花蓮光復及出雲山苗圃，因此以實驗區域位置為基準蒐集 EO-1 Hyperion 高光譜影像，且配合第四次森林資源調查地真資料取得時間，以 2007 年至 2011 年間的影像為蒐集目標。

出雲山苗圃位於台中市和平區，主要分布樹種及土地覆蓋型包含果園、道路、定居地、針葉樹人造林，樹種包括肖楠、杉木、柳杉等、單桿竹、其他闊葉樹等，樣區內能掌握之森林類別有限，則透過美國 USGS EarthExplorer 網站查詢，歷年影像有符合出雲山苗圃所在的區域，且影像取得時間符合，雲覆蓋量低，如表 5-1 所示，共有 5 幅 Hyperion 影像符合條件，其中 2011 年 4 月 2 日的影像與出雲山苗圃實驗區域的重疊度最高（如圖 5-1 和圖 5-2），該幅影像雲覆蓋率約為 0%至 9%，然而在研究區域內影像右上角有明顯的雲遮蔽區域。

表 5-1、出雲山苗圃實驗區之 EO-1 Hyperion 影像

影像編號	影像獲取時間	雲覆蓋率
EO1H1170442011141110P0_WPS_01	2011/05/21	30% – 39%
EO1H1170442011128110P0_PF1_01	2011/05/08	0% – 9%
EO1H1170442011110110P0_PF2_01	2011/04/20	10 – 19%
EO1H1170442011092110K0_PF1_01	2011/04/02	0% – 9%
EO1H1170442011053110P0_PF1_01	2011/02/22	20% – 29%




圖 5-1、多幅 Hyperion 影像涵蓋範圍與實驗區域




圖 5-2、2011 年 4 月 2 日之 Hyperion 影像與地真資料

5.2、實驗樣區機載高光譜影像實際取像流程及影像成果

本計畫選定花蓮光復及出雲山苗圃為本計畫為實驗區域，此兩個實驗樣區之機載高光譜影像取像作業完成時間分別為：花蓮光復實驗區於 108 年 6 月 30 日及出雲山苗圃實驗區於 108 年 7 月 13 日完成取像，取像流程及影像成果說明如下：

5.2.1、實驗樣區機載高光譜影像取像流程

本小節針對實驗樣區取像之行政作業、航拍操作流程進行說明。

一、飛行掃描申請歷程

本團隊依規定於本案開始後依照「國土測繪法」及「實施航空測量攝影及遙感探測管理規則」等相關規定，於 108 年 4 月 30 日檢附相關文件(申請文號：(108)中興測字第 1080000125 號)向內政部提出申請實施本案飛航掃描作業，並於 108 年 6 月 3 日核復通過(核復文號：108 年 6 月 3 日-台內地字第 1080121507 號)。同時於 108 年 6 月 6 日依內政部審核成果由航空公司向民航局申請拍攝空域和時間(申請文號：(108)中興測字第 1080000209 號)，民航局於 108 年 6 月 27 日核准飛航區域(核復文號：108 年 6 月 27 日-空運管字第 1080015319 號)，圖 5-3 為內政部與民航局核准飛航申請之公文，詳細往來函文詳見附件 C。

二、飛行掃描儀器

本計畫採用之空載高光譜係採用 Itres CASI-1500，為最廣泛之商用空載光譜儀，如同 4.4、節所述，為最廣泛之商用空載光譜儀，視地形及飛航參數設定，最高可記錄具有 288 波段之可記錄波段數及 380 至 1050 nm 光譜範圍。Itres CASI-1500 屬於推帚式掃描儀，推帚式之掃描方式是使二維 CCD 元件上的一行影像以高光譜分辨率被重複讀出，進而取得涵蓋相應地面之高光譜影像，與傳統只具備波段的影像不同，同時具有空間資訊（坐標資訊）與光譜（高連續波段）模式的影像。

三、航空攝影儀器之載具和機上執行情形

本團隊租用前進航空股份有限公司，以其飛航載台（前進航空 C208B）如圖 5-4，載台上裝載高光谱相機，及相關 GPS+IMU 設備，操控人員可直接於飛機上了解當時飛航情形，包括蒐集之資料品質及影像重疊率等資訊，若遇天候突發狀況時，可於機上決定航線的拍攝順序。圖 5-5 為實際執行飛航過程之紀錄，於地面檢查飛機相關設定以及機師進行飛航設備安全檢查，檢查完後針對空拍儀器之所有連線測試，確保所有儀器接能通電並正常開關，電腦螢幕皆能顯示儀器之訊號和接受的資料展示，最後為確認所有儀器設備皆能正常運作方可作業。

發 件 人: 陳 明 賢	發 件 人: 陳 明 賢
內政部 函	交通部民用航空局 函
地址：10011臺北市中正區徐州路5號 聯絡人：陳以瑞 聯絡電話：02-23855272 傳真：02-23976875 電子郵件：noi1912@mail.gov.tw	地址：台北市敦化北路340號 傳真：(02)23495353 聯絡人：謝孟瑜 聯絡電話：23495317 電子郵件：mcag0518@mail.caa.gov.tw
受文者：中興測量有限公司	受文者：中興測量有限公司
發文日期：中華民國108年5月3日	發文日期：中華民國108年5月27日
發文字號：台內地字第1080121507號	發文字號：空運營字第1389015319號
類別：普通函	類別：普通函
密等及密級：普通及秘密級	密等及密級：普通及秘密級
附件：無	附件：如文(申請書及航線圖)(1080015319-0-0.tif)
主旨：貴公司受國立臺灣大學委託辦理行政院農業委員會林務局農林航空測量所「應用高光谱航遙測影像於土地覆蓋型調查之研究案」案，申請實施航空測量攝影1案，原則同意，請查照。	主旨：貴公司使用C208B型機（國籍編號為：B-23062、B-23063）於臺中市及花蓮縣地區執行中興測量有限公司委託之「應用高光谱航遙測影像於土地覆蓋型調查之研究案」所需航空測量攝影作業一案，同意自本局核准次日起至108年12月16日止辦理，請查照。
說明： 一、依國土測繪法第55條規定及國防部108年5月27日國情整備字第1080001392號函辦理，並復貴公司108年4月30日(108)中興測字第1080000125號函。 二、貴公司實施航空測量攝影期間為核准次日起至108年12月16日止，本案實施航空測量攝影獲取成果，請依「實施航空測量攝影及遙感探測管理規則」第8條及第9條規定，於沖洗成影像處理後，提送本部會同國防部審查，以完備程序；並請於執行任務完竣後60日內編製相關文件送本部備查。 三、請依「普通航空業管理規則」第9條規定於執行航空攝影作業5工作日前，檢附相關文件向交通部民用航空局申請核	說明： 一、復貴公司108年6月12日019前字第083號申請書。 二、請依據「航空器飛航作業管理規則」、「航空產品與其各項裝備及零組件適航維修管理規則」、「飛航規則」、「飛航指南」等相關規定作業，作業前應先與相關航管單位協調並保持密切聯繫；另各項飛航作業紀錄應每架次詳實管制登載備查。 三、作業範圍應符合內政部同意之航攝區域，另執行作業1工作日前務必將飛航作業地區範圍（應附有比例尺之範圍，包
第 1 頁，共 2 頁	第 1 頁，共 2 頁

(a)內政部核准飛航申請

(b)民航局核准飛航申請

圖 5-3、飛航申請公文示意圖



圖 5-4、飛航載台及機上儀器設備



圖 5-5、飛航執行過程

四、實驗樣區之飛航規劃

空載高光譜掃描資料獲取前需要有完整的飛航規劃，考慮的內容包括掃描區範圍、實施地形的高度、預定規劃的載體航高、掃描儀之掃描角度、每一航線涵蓋地面寬度、航線間的重疊率及航區管制等種種條件，故於實際進行飛航之前，必須規劃詳細的飛航資訊及展繪飛航規劃圖及提出飛航申請，以確定飛航任務之可行性。

空載高光譜系統掃描參數之規定：影像解析度須達 1 m 解析度，且光

譜範圍涵蓋可見光及近紅外波段(400~1000 nm)，頻寬約 4-8 nm。空載高光譜掃瞄於可獲取最大波段數之規劃中，須根據欲獲取之地面解析力、航高與載具速度等參數決定，因此為滿足本案之需求，空載高光譜影像將以離地高約 1500 m 以上，FOV 為 40° 之掃瞄參數獲取地面解析度為 1 m 影像，並以頻寬 5-10nm 平均分配於所收集光譜資料範圍內，其範圍則涵蓋近紫外線波段、可見光波段及近紅外線波段(362.8~1051.3 nm)高光譜資料，預計獲取兩測區不同波段數。掃瞄任務之規劃會影響影像品質、航線數及高光譜實際可獲取之波段數量，整體飛航規劃作業的方法與步驟流程說明如圖 5-6 所示，先進行坐標系統的選擇，針對地形高程進行分析，接著依據測區欲選擇的波段數量進行測區飛航參數計算，看是否能達到欲選擇的波段數量，最後才針對確定的參數進行航線繪製。




圖 5-6、航線規劃流程

本案飛行掃瞄範圍共有兩區，又根據實驗樣區所在縣市，分別將掃瞄測區訂為台中測區和花蓮測區，台中測區 A1 位在測區右上方，設計時若只考慮 A2 航線，等於 A2 最右邊之航線地勢從 600m-1590m 公尺，高差起伏過大，空中飛行掃瞄時雖然可直接飛過進行掃瞄，但考量後續資料品質，遂在地勢 1000m-1590m 區域，增加一條航線確保後續的資料完整性。花蓮測區因地勢起伏不大較為平坦，故同一測區使用相同的飛航參數，兩測區根據地形高程進行航線設計，規劃了不同之飛航參數，飛航參數規劃如表 5-2。雖然實際規劃如表 5-2，但有時飛航掃瞄仍舊會有突發狀況，這時會以空中遭遇之突發狀況進行航線微調及飛航參數更改。飛航規劃示意圖，台中測區航線規劃如圖 5-7，花蓮測區航線規劃如圖 5-8。

表 5-2、本研究測區之飛航參數規劃

飛航區域	航線數	地形最高(m)	地形最低(m)	離地高(m)	航高(m)	航速(KTS)	掃描角度(deg.)	掃描頻率(Hz)	掃描帶寬(m)	重疊帶寬(%)	波段數
台中測區 A1	1	1590	1000	1750	3050	90	±20	38	1260	20	96
台中測區 A2	4	1200	600	1850	2650	90	±20	38	1332	20	96
花蓮測區 B	3	330	120	1980	2180	80	±20	38	1425	20	144
Total	8	任務時間：一架次預計 1.5hr 轉彎時間：預計 0.66hr									
總公里數	77.4km (預計)										




圖 5-7、出雲山苗圃(台中測區)航線規劃




圖 5-8、花蓮光復(花蓮測區)航線規劃

5.2.2、實驗樣區機載高光譜影像取像成果

一、花蓮光復實驗樣區高光譜影像

花蓮光復實驗樣區取像共包含了 3 條航帶影像，圖 5-9 為花蓮光復實驗樣區真實彩色單條航帶影像，表 5-3 則為該實驗區高光譜影像資訊，鑲嵌後影像大小為寬 11,133 個像元、高 14,639 個像元，由於實驗區為東北-西南走向，鑲嵌後影像會含有空白區域，影像之地面解析度為 1 公尺，波段則有 144 波段，144 個波段實際光譜涵蓋範圍為 363.3nm – 1043.8nm，圖 5-10 為影像中光臘樹單一像元的光譜輻射值曲線，圖 5-11(a)、(b)分別為鑲嵌後自然彩色影像及紅外假色影像 (R：763.2nm、G：630.0nm、B：520.5nm)。此外該實驗區所對應的光達點雲資料如圖 5-12 所示，由光達資料可看出實驗區的地形變化較少，於影像中東南方才有較明顯的地形起伏，整體的高程變化在 122.048 公尺至 419.659 公尺，該組光達資料共有 53,187,549 點，平均的點間距為 1.002 公尺。



圖 5-9、花蓮光復實驗樣區初步單條航帶影像

表 5-3、花蓮光復實驗區高光譜影像資訊

航帶數目	3 條航帶
鑲嵌後影像大小	11133×14639 像元(含空白區域)
波段數	144 波段
地面解析度	1 公尺
實際光譜涵蓋範圍	363.3nm – 1043.8nm
影像座標涵蓋範圍 (E、N 座標)	左上：(294168, 2619535)右上：(297715, 2618483) 左下：(286629, 2606885)右下：(289996, 2605381)
影像涵蓋面積	約 44.8 平方公里
光達點雲數	53,187,549 點
平均點間距	1.002 公尺





圖 5-10、光臘樹單一像元光譜輻射值(radiance)



(a)真實彩色影像



(b)紅外假色影像

圖 5-11、花蓮光復實驗樣區鑲嵌後影像




圖 5-12、花蓮光復實驗樣區光達資料

二、出雲山苗圃實驗樣區高光譜影像

出雲山苗圃實驗樣區之取像包含了 5 條航帶影像，如圖 5-13 所示。表 5-4 為出雲山苗圃實驗區高光譜影像資訊，經鑲嵌後影像大小為寬 4,787 個像元、高 14,335 個像元，實驗區影像的走向與花蓮光復樣區相同為東北-西南走向，故影像邊緣有空白區域，影像的地面解析度為 1 公尺，含有 96 個波段，其波段含涵蓋的波長區間為 364.5nm – 1042.6nm，圖 5-14 取影像中針葉樹林型台灣杉之單點光譜輻射值曲線作為範例，鑲嵌後出雲山苗圃實驗區之真實彩色及紅外假色影像（R：764.4nm、G：628.8nm、B：521.7nm）如圖 5-15(a)、(b)所示，而影像中左下角則有雲遮蔽區，其所涵蓋之面積約為 1 平方公里。出雲山苗圃實驗區所對應的光達點雲資料如圖 5-16 所示，由光達資料可看出實驗區的地形起伏變化較大，實驗區東側的高程較高，整體的高程變化在 500.587 公尺至 1662.276 公尺，該組光達資料共有 60,236,051 點，平均的點間距為 1.393 公尺。本報告書中相關之影像資料將於本計畫成果報告完整交付電子檔。




圖 5-13、出雲山苗圃實驗樣區初步單條航帶影像

表 5-4、出雲山苗圃實驗樣區高光譜影像資訊

航帶數目	5 條航帶
鑲嵌後影像大小	4787×14335 像元(含空白區域)
波段數	96 波段
地面解析度	1 公尺
實際光譜涵蓋範圍	364.5nm – 1042.6nm
影像座標涵蓋範圍 (E、N 座標)	左上：(239607, 2685699)右上：(242854, 2685699) 左下：(238552, 2676800)右下：(240990, 2676152)
影像涵蓋面積	約 30.4 平方公里
光達點雲數	60,236,051 點
平均點間距	1.393 公尺




圖 5-14、台灣杉單一像元光譜輻射值(radiance)



(a)真實彩色影像



(b) 紅外假色影像

圖 5-15、出雲山苗圃實驗樣區鑲嵌後影像




圖 5-16、出雲山苗圃實驗樣區光達資料

陸、自動分類演算法評估

根據第 3 章之文獻回顧，本團隊將高光譜影像分類演算法概分成三大類，包括：

- 一、特徵分類法
- 二、結合空間資訊的特徵分類法
- 三、以機器學習為基礎之分類法

以下針對各種分類演算法進行說明。

6.1、特徵分類法

特徵分類法主要以傳統統計式分類方法進行高光譜影像分類，統計式分類法主要由已知訓練樣本計算類別的統計資訊，據以對未知像元進行分類。常見的統計式分類方法如最小距離法 (minimum distance classifier, MDC)、及最大似然法 (maximum likelihood classifier, MLC) 等。然而此類方法並無法直接適用於高光譜影像，最主要的原因是在訓練樣本數目有限的情況下，無法獲得可靠的類別統計量，造成分類成果不可靠、精度不佳，甚至無法分類的情形。由文獻回顧可知解決此問題的方法之一是先對高光譜影像資料進行特徵萃取以降低資料維度，之後再對特徵進行分類，此種兩階段的分類方法我們稱之為特徵分類法。以下說明幾種常見的特徵萃取法以及統計式分類方法。

6.1.1、特徵萃取

為解決「維度的詛咒」之問題，須將高光譜影像進行維度縮減。維度縮減的方法主要可分為特徵選取與特徵萃取，如圖 6-1 所示；特徵選取是透過設定的準則，從所有資料中找出最適合的子集合；特徵萃取則是透過不同的轉換方法，可為線性或是非線性之轉換，將原始資料轉換為數量較少，且具有代表性之特徵(徐百輝，2003)。高光譜影像之維度縮減通常採用特徵萃取，以下說明常見的特徵萃取法：




圖 6-1、維度縮減(Hsu, 2007)

一、主成份轉換法（PCT）

主成份轉換法是最常見的特徵萃取方法，其透過對資料的協變方矩陣進行特徵分解，以獲得資料的特徵向量(eigenvectors)及相對應的特徵值(eigenvalues)，轉換後各特徵向量彼此之間互相正交。主軸轉換法應用於高光譜影像資料時，轉換後前 M 個具有較大特徵值的成份通常包含了最多的資訊量，可用來代表原始資料，並可用於影像分類。主軸轉換法具有模式簡單、不需已知的訓練樣本，以及對低維度資料具有不錯的轉換成果等優點，因此被廣泛使用於遙測資料的維度縮減。然而，主軸轉換法是透過整體資料的協變方矩陣，找出變異量較大的分量，但高光譜影像部分有意義的資訊，可能會被隱藏於排序較低(即變異量較小)的分量中，而這些分量通常是被忽略的。此外，整體資料的協變方矩陣無法代表單一類別的變異分布，且容易受到資料本身含有的雜訊影響(Schowengerdt, 1997)，同時大量的原始資料亦會使得主軸轉換法的計算效率降低。

二、判別分析特徵萃取法（DAFE）

判別分析特徵萃取法（DAFE）是將資料透過轉換找出最佳的特徵軸，使資料類別的分離度最佳。為了使資料的分離度最佳，DAFE 即是將類

別間間距增大，並且縮小類別內的資料分布。雖然 DAFE 已經是有效實作的演算法，於不同的情況下，均可找到有效特徵。但是 DAFE 的缺點包含了：DAFE 轉換得到的特徵數量，最多僅有類別數減 1；當不同類別的平均值極為接近或相同時，萃取得到的特徵將變得不可靠，但這樣的情況在高光譜影像中屬常見的情形(Fukunaga, 1990; Lee and Landgrebe, 1993)。此外，為了得到可靠的統計資訊，即類別內與類別間的散布矩陣，通常需要較多的訓練資料，然而高光譜影像通常沒有足夠的訓練資料。

三、決策邊界特徵萃取法 (DBFE)

Lee 與 Landgrebe(1993)提出利用類別間的決策邊界(decision boundary)之方向，將有用的特徵從冗餘的資料中分離出來。以 2 種類別為例，當萃取出來的特徵向量與決策邊界垂直時，則該特徵將有助於分辨不同類別；若取得之特徵向量與決策邊界平行，則該特徵無法表示出原始資料的變異，將無益於分類。DBFE 仍需要足夠的訓練樣本，以計算各類別間的決策邊界，而高維度的資料亦需要大量的訓練樣本，對於高光譜影像而言，通常訓練資料是有限的，當訓練資料不足時，會產生奇異的現象，並且無法得到良好的統計值。此外，龐大的計算量亦是 DBFE 的缺點。

四、以小波轉換為基礎的特徵萃取

小波轉換 (wavelet transform) 是一種良好的訊號處理分析工具，若將高光譜影像中每一像元的光譜曲線視為一維向量訊號，並將小波轉換運用於光譜曲線上，從光譜空間轉換至時間-尺度空間，利用時頻分析以了解不同時間及不同尺度(頻率)之下的光譜能量變化。徐百輝(2003)提出以小波理論為基礎的高光譜影像之光譜特徵萃取，則高光譜影像的單一像元之光譜向量，可被分解為一個近似部分與多個細節部分的係數，如圖 6-2 所示，不同的小波係數選取方式即衍生出不同的小波特徵萃取方法，例如 Linear wavelet feature extraction 是將光譜曲線經小波分解後的近似部分係數，選取 M 個($M < N$, N 為波段數)係數作為萃取

後之特徵；Nonlinear wavelet feature extraction 則是將光譜曲線經小波分解後的近似部分與細節部分之係數，遞減排序後，選取前 M 個係數值作為萃取後之特徵。以小波理論所萃取出的光譜特徵，可以有效降低高光譜影像的資料維度，並且保持影像分類的精度。然而以小波轉換為基礎的特徵萃取法在使用上仍有許多未定變數，例如必須事先選定小波轉換的基底函數，以及不適用於非線性資料等。




圖 6-2、小波轉換用於光譜曲線之例(徐百輝，2003)

6.1.2、傳統影像分類方法

在傳統統計式分類方法中最具代表性、也常廣泛使用於遙測影像的方法為最大似然法（MLC）。最大似然法是根據貝氏的機率理論，判斷未知類別的像元與不同類別機率分布之間的關係(Richards and Jia, 2006)，在資料為常態分布的情況，最大似然法的辨識函數為：

$$g_i(x) = -\ln|\Sigma_i| - (x - m_i)^T \Sigma_i^{-1} (x - m_i) \quad (6-1)$$

式中， m_i 與 Σ_i 分別為類別 i 的平均向量和協變方矩陣，均可透過訓練

樣本計算而得。由於式(6-1)中必須求解協變方矩陣的反矩陣，若訓練樣本數小於波段數（即協變方矩陣之維度），則該矩陣為秩虧矩陣，無法直接求得其反矩陣。就算訓練樣本數大於波段數，通常其數量亦要足夠大，才能得到可靠的統計參數估算結果。其他分類方法，如最小距離法、Mahalanobis 距離分類法等，均是根據貝氏定理與最大似然法的辨識函數衍生推導得到的，亦屬於參數式的分類方法(楊琇涵，2007)。

統計式分類方法大都屬於監督式（supervised）的分類法，也就是須透過訓練樣本去計算統計參數，然而當不同監督式分類方法用於高光譜影像時，由於高光譜影像屬於高維度資料，相較於維度的數量訓練樣本數是有限的，甚至不足以用於分類，造成分類成果不佳或是無法分類之情形，仍須透過維度縮減以解決此類問題。

6.2、結合空間資訊的特徵分類法

上述特徵分類法大都針對單一像元進行分類，分類成果常有椒鹽現象或是分類區塊不完整的情況，分類時若能同時考量周遭像元的光譜變化，將可有效改善此一情況。目前結合空間資訊的分類方法中，以物件(object)為基礎的影像分析方法（OBIA）具有較高的分類效能，OBIA 主要是基於「人類對地物認知程度」的概念，對影像進行判釋工作，與像元式分類方法不同，物件分類是以影像區塊（region）為基本單元，藉由影像分割（image segmentation）的步驟，讓影像中彼此相關的像元能結合在一起，形成有意義的區塊，除了考量光譜訊息外，區塊物件更加入能用於分類的附加屬性或特徵（features），如：形狀、紋理、位相關係等，對於光譜特性混淆時提供有效的幫助。而物件分類加入的多層解析度分割（multiresolution segmentation）的概念，只要地物間有明顯的差異，就能夠作區分，同時分類的過程中，以區塊為概念，減少了所需處理的單元個數，效率也有所提升(徐百輝與張嘉玳，2010)。圖 6-3 為物件導向分類之流程圖，透過影像分割將影像分割成多個物件，稱為物件影像，再進行分類知識庫的建立，分別透過物件特徵萃取及建立分類規則，即可進行分類，通常會採用模糊邏輯（fuzzy logic）分類，透過制定隸屬度函數（membership function）來進行分

類。

物件分類方法的基本步驟主要可區分為影像分割(segmentation)、特徵萃取(feature extraction)、建立類別階層(class hierarchy)、及分類(classification)等四個主要步驟，以下簡單說明之：

一、 影像分割：

藉由影像光谱反應之不連續性及形狀特徵（包含平滑度、緊緻度）之異質性將整張影像劃分成許多小區塊，後續分類動作則以這些分割後之小區塊為基本單元，進行影像分類之工作。為有效將地物輪廓完整地描述清楚，通常會依研究對象的空間特性及使用者本身之判釋知識，而給予影像適當的分割標準。良好的分割尺度大小（scale）選定將更加有利於地物空間特徵之萃取。因此，在研究中分割尺度大小及異質性參數（heterogeneity）的設定，是決定分類成果好壞的一個很重要的步驟。

影像分割通常是使用資料驅動的分割方式，主要可分為四種（徐百輝與張嘉玳，2010）：(1)門檻執法(threshold)，(2)以邊緣為主的方法(edge-based method)，(3)以區域為主的方法（region-based method），及分水嶺分割法(watersheds method)，其中以區域為主的區域成長法(region growing)最常被使用。區域成長法是從一個點的小區域，將影像中同質性高的相鄰像元組合成同一物件，並經過重複迭代之步驟，當影像中所有像元皆有所歸屬之區塊，即完成區域成長法之影像分割。此外，將區域成長法做進一步改良的多層解析度分割，除了使用影像光谱值作為分割依據外，另考量影像區塊的其他特性，如區塊異質性(heterogeneity)或均質性(homogeneity)，強化影像區塊分割或合併的判斷標準(李庭誼，2011)。




圖 6-3、物件導向分類流程圖

二、特徵萃取：

航遙測影像由於各種外在因素之影響，「同物異譜」或「同譜異物」的情形經常出現，僅靠光譜特徵並不足以獲得正確的分類或判釋結果。物件導向分析在獲得同質的影像區塊或物件之後，便可以以區塊或物件為基本單元，計算許多以往無法從單一像元獲得的地物特徵。常見的物件特徵包含：

1. 光譜特徵：影像各波段像元值及其統計量，例如：平均值、標準差、最大值和最小值等。
2. 幾何特徵：即各區塊的幾何形狀特徵，如：面積(area)、密度(density)、長寬比(length/width)、圓度(roundness)，或其他形狀因子(shape index)。
3. 紋理特徵：如 Haralick 等(1973)提出之統計型紋理特徵，例如：同質性(homogeneity)、對比(contrast)、不相似度(dissimilarity)、熵(entropy)、角二次矩(angular second moment)、平均值(mean)、標準差(standard deviation)及相關性(correlation)等。
4. 類別間關係之特徵：與其他類別相鄰接的相對邊長長度(Rel. Border To)及類別於一定範圍內所占的面積比率(Rel. Area To)。

而這些特徵本質上為有關於物件特性的量化指標，可以用來作為判斷物件類別的依據。

三、建立類別階層：

類別階層為後續影像分類之主要架構，其中包含了判釋類別的建立、類別間之階層關係及類別的空間特徵等。分類時需依據欲分類地物之需求，定義各類別之階層關係，主要有以下兩種關係：

1. 繼承(inheritance)：繼承的概念指的則是類別與類別之間的關係，位於上層的父類別(super-class)的物件會傳遞其本身空間特徵的描述給下層子類別(sub-class)物件。
2. 集合語意(group semantic)：除了上述所提的繼承關係之外，階層

間的操作尚包含了集合語義的設定，因為對於航遙測影像而言，地物種類有時並不單純，並非所有類別使用單一空間特徵就能完整萃取，例如組成較複雜區域的分類須設定較多判釋條件及門檻值方能取得較良好之分類成果。

四、分類：

完成影像分割及類別階層描述兩步驟後，再定義各子類別屬性名稱，即可對物件進行分類，分類方式可採用監督式或非監督式的分類方法。常見的分類方式可歸納為以下三種：

1. 訂定規則：利用前一步驟所建立的類別階層描述，以規則集的方式建立分類依據。
2. 使用隸屬度函數進行模糊分類 (fuzzy classification)：模糊度分類是利用物件屬於某個類別的可能性當作分類之依據，而可能性數值範圍介於 0 到 1 之見的浮點數。
3. 最鄰近分類：即是給定物件型態的訓練樣本，並且選取作為最鄰近分類之分類依據的物件特徵，根據物件到其最鄰近訓練樣本的特徵空間距離 (feature space distance)，判斷該物件之類別歸屬。

6.3、以機器學習為基礎之分類演算法

機器學習方法近年來廣泛的被使用於資料分析，在航遙測影像分析中亦有相當多的文獻採用不同的機器學習方法進行影像分類。本研究將著重在核方法 (kernel-based method) 與深度學習 (deep learning) 演算法，進行其應用於高光譜影像分類之效能評估。

6.3.1、核方法

核方法具有完備的統計理論架構，透過核函數 (kernel function) K 的轉換 (如式(6-2))，將原始資料 $\mathbf{x}$ 轉換映射至特徵空間 $\phi(\mathbf{x})$ ，使資料特性由原本的非線性，在特徵空間中成為線性，將其簡化以解決問題，圖 6-4 即是核方法將資料透過轉換使資料分布簡化，已簡單解決分類問

題之示意圖，而常見的支持向量機即為核方法中的一種。

$$K(\mathbf{x}, \mathbf{x}') = \langle \phi(\mathbf{x}), \phi(\mathbf{x}') \rangle \quad (6-2)$$

核函數（式(6-2)）之關鍵在域映射函數 $\phi(\mathbf{x})$ 的選擇，經過映射函數的轉換後，核函數的演算則可以利用簡單的內積計算取代，而不需要了解資料在特徵空間中實際的分布情形(Gómez-Chova *et al.*, 2011)。常見的核函數有以下三種(Gómez-Chova *et al.*, 2011)：

(一) 線性 (linear kernel)：

$$K(\mathbf{x}, \mathbf{z}) = \langle \mathbf{x}, \mathbf{z} \rangle \quad (6-3)$$

(二) 多項式 (polynomial kernel)：

$$K(\mathbf{x}, \mathbf{z}) = (\langle \mathbf{x}, \mathbf{z} \rangle + 1)^d, d \in \mathbb{Z}^+ \quad (6-4)$$

(三) 輻狀基底函數 (radial basis function)：

$$K(\mathbf{x}, \mathbf{z}) = \exp(-\|\mathbf{x} - \mathbf{z}\|^2 / 2\sigma^2), \sigma \in \mathbb{R}^+ \quad (6-5)$$




圖 6-4、透過資料空間轉換改變資料分佈特性

支持向量機(Cortes and Vapnik, 1995)是以統計學習理論為基礎的監督式分類方法，其概念是將資料映射至特徵空間（ R_d 空間）中，並且在該空間找出超平面將資料分為兩群，同時要使得不同類別超平面的距離最大；支持向量機的示意圖如圖 6-5 所示，透過找出決策超平面（decision hyperplane）且使得類別超平面（support hyperplane）間的距離最大，以區分不同類別。支持向量機的分類函式（decision function） $f(x)$ ：

$$y_i = f(x) = w^T x_i + b = \sum_i \alpha_i y_i x_i^T x_j + b \quad (6-6)$$

其中， w 和 b 的值是由支持向量來決定的，而 $w = \sum_i \alpha_i y_i x_i$ 。同時可以注意到分類函式中資料向量為 $x_i^T x_j$ 的形式，即為內積 $\langle x_i, x_j \rangle$ 。因此可以將資料帶入映射函數進行轉換後，改變資料於特徵空間的特性後，再進行內積運算，形成核函數的形式（如式(6-2)），透過核函數的運用將有助於支持向量機分類。因此高光譜影像則可以透過其本身的資料特性，搭配合適的核函數，將資料轉換至特徵空間後，使得資料在特徵空間中的分布有利於支持向量機分類，在配合數量較少的訓練樣本之下，提升特徵萃取成果及影像分類之精度及效能。




圖 6-5、支持向量機分類示意圖

6.3.2、深度學習演算法

人工神經網路是機器學習中的一個重要演算法，其發展主要來自生物神經系統（biological nervous systems）的啟發。一般的神經網路架構係由許多非線性處理層（nonlinear processing layers）組合在一起，並可以平行的方式處理每一個層中的簡單單元（simple elements），一般稱為神經元（neurons）。神經網路藉由神經元之間的相互連結，藉由感知外部資訊的變化而調整網路內部參數，因此屬於一種自適應的計算模型。深度學習（deep learning）則是傳統神經網路的重要延伸，也被歸類為是機器學習中的一種方法，其利用神經網路的深層架構直接從大數據中學習資料內部的複雜結構。深度學習利用多個處理層（multiple processing layers）所組成的計算模型來學習具有多種抽象級別的資料表徵（data representations）(LeCun et al., 2015)，因此具有比淺層神經網路更強大的學習能力。過去幾年來，深度學習已成功地應用在二維影像的辨識及分析上，如影像分類（classification）(Krizhevsky et al., 2012)、影像分割（segmentation）(Long et al., 2015; Noh et al., 2015; Saito et al., 2016)、影像判釋（recognition）(He et al., 2016)、物體偵測及定位（detection and localization）(Sermanet et al., 2014)、以及場景認知（scene understanding）(Berger, 2014; Farabet et al., 2013)。

在眾多深度學習方法中，卷積神經網路（convolutional neural networks, 簡稱 ConvNet 或 CNNs）可以說是最受矚目，也已被廣泛使用的一個方法(LeCun et al., 2015; LeCun et al., 1990)。CNNs 的優點之一是不需要繁複的影像前處理過程，CNNs 可以直接輸入原始影像進行一系列的影像處理工作。圖 6-6 所示為 CNNs 的基本架構圖(Rawat and Wang, 2017)，與大多數前饋式神經網路(feedforward networks)架構類似，CNNs 由一個輸入層（input layer），一個輸出層（output layer），及許多隱藏層(hidden layers)所組成；隱藏層依據網路功能又可分為兩大部分，第一部分為特徵偵測層（feature detection layers），其主要由卷積層（convolution layers）、池化層（pooling layers）所組成。特徵偵測層可重複多次，使得每一次可以對應到物體不同層級的特徵；第二部分為全連結層（fully

connected layer, FC)，可用來進行影像分類或辨識，主要目的是將前一層所偵測到的特徵對應到欲分類的類別。




圖 6-6、卷積神經網路基本架構圖(Rawat and Wang, 2017)

由於 CNNs 非常有利於影像處理，因此僅需對網路架構進行些微調整或修改，CNNs 也可以應用到一般航測或衛星影像辨識或分類，圖 6-7 所示即為一個用來處理遙測影像分類的 CNNs 基本架構(Li, et al., 2018)。對於一般航測或多光譜影像，一般是將影像切成許多小區塊後，進行網路參數學習，對於高光譜影像則可分別針對光譜特徵、空間特徵或是同時整合光譜及空間特徵進行網路的訓練，如圖 6-8 所示。




圖 6-7、以深度學習進行遙測影像分類之基本架構圖(Li, et al., 2018)




圖 6-8、適用於高光譜影像的 CNNs 基本架構圖(Li, et al., 2018)

柒、實驗樣區高光譜影像分類與成果分析

7.1、實驗區域之衛載 EO-1 Hyperion 高光譜影像分析

7.1.1、出雲山苗圃實驗區域 EO-1 Hyperion 影像前處理與地真資料說明

根據 5.1、節衛載 Hyperion 高光譜影像蒐集，最後選定 2011 年 4 月 2 日之影像做為實驗影像，而於 USGS EarthExplorer 網站取得之 Hyperion 影像為 Level 1R (L1R)，下載所得之影像已進行影像輻射改正，但是未經過大氣改正與幾何改正，同時 L1R 影像的 242 個波段中只有 198 個非零的波段，並且部分波段之坡長重疊或是為水氣吸收波段(Ganesh et al., 2013)，詳細波段說明如表 7-1 所示。因此下載所得之 2011 年 4 月 2 日 Hyperion 影像仍需經過前處理，利用可公開取得之 Hyperion tool 套件(hyperion_tools.sav，來源：<https://github.com/dawwhite/HyperionTools>)，除去無法使用之影像波段，同時根據影像相關參數進行大氣改正，採用的大氣改正模式為 FLAASH (fast line-of-sight atmospheric analysis of spectral hypercubes)，最後根據與地真資料重疊區域取得合適的影像大小範圍。

表 7-1、EO-1 Hyperion 影像 L1R 無法使用之波段說明(Ganesh et al., 2013)

波段	波段說明
1 – 7	Not illuminated
58 – 78	Overlap region
120 – 132	Water vapor absorption band
165 – 182	Water vapor absorption band
185 – 187	Identified by Hyperion bad band list
221 – 224	Water vapor absorption band
225 – 242	Not illuminated

經過前處理後用於後續實驗分析之 Hyperion 影像如圖 7-1 所示，影像大小為寬 256 個像元、高 425 個像元，波段數為 155 個波段，同時根據第四次森林資源調查成果，以欄位「差異形態名稱」為類別選取的基準，以森林植被為主選取 8 個類別，分別為：竹林、針葉樹林型、闊葉樹林型、竹針混淆林、竹闊混淆林、針闊混淆林、竹針闊混淆林、果樹，類別分布狀況如圖 7-2 所示。將影像與地真資料對位後，以像元為單位逐像元選取目標區域（region of interest, ROI），同時避免選取接近類別邊界之像元，最後於後續程式中，隨機選取固定比例之像元分別作為訓練資料和檢核資料，各類別之像元數、訓練資料數、檢核資料數如表 7-2 所示，由於不同類別的像元樹木差距相當大，總像元數小於 1000 的類別其訓練樣本與檢核樣本的比例為 7:3，總像元數大於 1000 的類別則採用訓練樣本為 900 個、檢核樣本為 400 個，比例亦約為 7:3。影像分類的方法則程序前面章節所描述之分類演算法，包含特徵分類法與以機器學習為基礎之分類法，由於 Hyperion 影像的地面解析度為 30 公尺，較不適合採用加入空間資訊分析，如形狀、紋理等，故未將結合空間資訊的特徵分類法加入分析。




圖 7-1、Hyperion 實驗區域影像




圖 7-2、實驗範圍選取之 8 個類別分布

表 7-2、各類別之像元數、訓練樣本數、檢核樣本數

類別編號	類別名稱	總像元數	訓練樣本數	檢核樣本數
1	竹林	864	605	259
2	針葉樹林型	3,265	900	400
3	闊葉樹林型	24,104	900	400
4	竹針混淆林	53	37	16
5	竹闊混淆林	1,458	900	400
6	針闊混淆林	3,828	900	400
7	竹針闊混淆林	77	54	23
8	果樹	835	585	251

7.1.2、出雲山苗圃 Hyperion 影像以特徵分類法之成果

本次研究中特徵分類法共採用 5 種不同的特徵萃取方法，降低資料維度、獲取可靠的資料特徵後，再利用最大似然法進行影像分類。研究中所採用的特徵萃取方法分別為：

1. 主成分轉換法 (PCT)：將實驗影像根據其波段資訊以主成分轉換法分析後，最後取得 22 個特徵波段（第 22 個特徵波段所佔比例為 0.01%）。
2. 判別分析特徵萃取法 (DAFE)：將實驗影像配合目標類別的訓練像元，進行 DAFE 轉換，根據演算法特性，特徵波段數為類別數減 1，最後取得 7 個特徵波段。
3. 決策邊界特徵萃取法 (DBFE)：同樣將實驗影像配合目標類別的訓練像元進行轉換，最後取得 40 個特徵波段（第 40 個特徵波段對應之特徵值為 0.0504）
4. 線性小波轉換特徵萃取法 (linear wavelet feature extraction, WFE)：將實驗影像的像元光譜曲線進行小波轉換，依照計算得到的近似、細節函數排序後取 35 個特徵作為波段。
5. 非線性小波轉換特徵萃取法 (nonlinear wavelet feature extraction,

NWFE)：特徵萃取方法類似 WFE，而取得小波係數後是將係數依照數值大小排序，取前 35 個特徵作為波段。

利用 PCT 特徵萃取之分類成果如圖 7-3 所示，隨著特徵波段數增加整體分類準確度 (overall accuracy, OA) 由 27.37% 逐漸增加，當特徵波段為 17 個時分類準確度為 42.36%，Kappa 指標則由 0.1452 增加到 0.3142，之後隨著特徵數目的增加分類準確度沒有太大的變化；表 7-3 為 PCT 採用 17 個特徵波段時，各類別之生產者準確度與使用者準確度，各個類別的生產者準確度和使用者準確度皆不高，其中以竹針混淆林及竹針闊混淆林的結果最差，顯示各類別皆有明顯的誤判及漏判之情況。利用 DAFE 特徵萃取時，因為最多能取得的特徵數為類別數減 1，因此最多為 7 個特徵波段，而整體的分類準確度則也是隨著特徵數增加而增加，最高的分類準確度落在 7 個特徵波段，其 OA 為 59.87%、Kappa 指標為 0.5198 (如圖 7-4)；表 7-4 為 DAFE 採用 7 個特徵波段時各類別精度，其中可以看到果樹分類結果最佳，生產者準確度和使用者準確度分別為 92.4%、88.85%，竹林、針葉樹林型和竹闊混淆林的成果次佳，而竹針混淆林與竹針闊混淆林則明顯有漏判及誤判之情況。圖 7-5 利用 DBFE 特徵萃取時，同樣是隨著特徵數的增加而整體分類成果提升，當特徵數為 3 個時，分類準確度超過 52%，之後隨這特徵數的增加逐漸有小幅度的提升，當特徵數為 33 個時，整體分類準確度為 59.31%，Kappa 指標為 0.5147；由表 7-5 利用 DBFE 的各類別分類成果來看，與 DAFE 的成果相似，果樹的生產者準確度與使用者準確度成果最佳，而在生產者準確度以針闊混淆林與竹闊混淆林的成果略佳，即漏判之情形較少，而使用者準確度則是竹林與闊葉樹林行成果略佳，即誤判之情形較其他類別少，同樣竹針混淆林與竹針闊混淆林成果較差。

圖 7-6 為利用 DAFE 特徵萃取的分類後影像，圖中分類後的各類別分布位置與原始地真資料相似，而原本闊葉樹林型分布範圍最廣，但分類後許多像元被誤分類為其他類別，果樹原本的分布範圍較小，但分類後許多非選定的類別，包含河道的部分被分類為果樹，另外原本雲遮蔽區域也有被區隔出來。




圖 7-3、主成分轉換法之分類成果

表 7-3、主成分轉換法（特徵數 17 個）之分類結果

特徵波段數	OA	Kappa 指標
17	42.36%	0.3147
類別	生產者準確度(%)	使用者準確度(%)
竹林	51.74	40.24
針葉樹林型	55.00	49.00
闊葉樹林型	15.25	36.53
竹針混淆林	0.00	0.00
竹闊混淆林	53.25	39.89
針闊混淆林	35.50	42.26
竹針闊混淆林	0.00	0.00
果樹	56.00	66.67




圖 7-4、判別分析特徵萃取法之分類成果

表 7-4、判別分析特徵萃取法（特徵數 7 個）之分類結果

特徵波段數	OA	Kappa 指標
7	59.87%	0.5198
類別	生產者準確度(%)	使用者準確度(%)
竹林	71.81	65.96
針葉樹林型	63.75	57.17
闊葉樹林型	30.25	51.05
竹針混淆林	0.00	0.00
竹闊混淆林	64.00	66.49
針闊混淆林	59.00	49.06
竹針闊混淆林	4.35	25.00
果樹	92.40	88.85




圖 7-5、決策邊界特徵萃取法之分類成果

表 7-5、決策邊界特徵萃取法（特徵數 33 個）之分類結果

特徵波段數	OA	Kappa 指標
33	59.31%	0.5147
類別	生產者準確度(%)	使用者準確度(%)
竹林	55.98	75.92
針葉樹林型	49.75	67.46
闊葉樹林型	32.50	58.56
竹針混淆林	0.00	0.00
竹闊混淆林	69.50	60.96
針闊混淆林	73.25	48.83
竹針闊混淆林	0.00	0.00
果樹	91.60	86.09




圖 7-6、DAFE 特徵分類法，7 個特徵波段之分類成果

利用小波轉換特徵萃取法之分類準確度如圖 7-7 與圖 7-8 所示。線性小波轉換特徵萃取法 (WFE) 的分類成果隨著特徵數的增加，分類準確度逐漸增加，其中特徵數為 23 個時分類準確度為 50.28%、Kappa 指標為 0.4076，但是當特徵數在 26 個以上時會造成最大似然法中矩陣秩虧，無法進行影像分類；表 7-6 為 WFE 各類別的分類成果，其中果樹的成果最佳，生產者準確度和使用者準確度分別為 87.2%、78.99%，其他各類別的分類成果則較差，分類成果最差的類別同樣是竹針混淆林和竹針闊混淆林。非線性小波轉換特徵萃取法 (NWFE) 也是隨著特徵數增加，當特徵數大於 5 個時，分類準確度超過 40%，特徵數再逐漸增加時分類準確度則沒有明顯的提升，最高的分類準確度發生在特徵數 14 個，分類準確度為 41.81%、Kappa 指標為 0.3043；表 7-7 為 NWFE 的各類別成果，在生產者準確度以針葉樹林型與果樹的成果最佳，生產者準確度為 74%，其他類別的生產者準確度皆低於 41%，使用者準確度則只有果樹達到 77.73%，其他類別則都低於 46%，而竹針混淆林和竹針闊混淆林之成果最差，與其他特徵萃取的成果相似。

而整體利用特徵分類法於實驗區 Hyperion 影像分類的結果並未非常良好，不同特徵萃取法分類後的整體分類準確度皆低於 60%，從影像分類結果來看，其中除了部分類別的像元被錯誤分類，且影像的椒鹽效應相當明顯，此外原本 Hyperion 影像的條紋雜訊也影響了分類成果。




圖 7-7、線性小波轉換特徵萃取法之分類成果

表 7-6、線性小波轉換特徵萃取法（特徵數 23 個）之分類結果

特徵波段數	OA	Kappa 指標
23	50.28%	0.4076
類別	生產者準確度(%)	使用者準確度(%)
竹林	28.57	65.49
針葉樹林型	65.25	49.62
闊葉樹林型	17.25	50.74
竹針混淆林	0.00	0.00
竹闊混淆林	54.2	57.56
針闊混淆林	60.25	42.36
竹針闊混淆林	0.00	0.00
果樹	87.20	78.99




圖 7-8、非線性小波轉換特徵萃取法之分類成果

表 7-7、非線性小波轉換特徵萃取法（特徵數 14 個）之分類結果

特徵波段數	OA	Kappa 指標
14	41.81%	0.3043
類別	生產者準確度(%)	使用者準確度(%)
竹林	35.14	45.50
針葉樹林型	74.00	39.89
闊葉樹林型	14.25	31.84
竹針混淆林	0.00	0.00
竹闊混淆林	40.25	43.63
針闊混淆林	27.00	34.07
竹針闊混淆林	0.00	0.00
果樹	74.00	77.73

7.1.3、出雲山苗圃 Hyperion 影像以機器學習為基礎之分類法成果

本次以機器學習為基礎的分類法主要利用支持向量機搭配不同的核函數進行分類，採用的核函數包含：

1. 線性核函數 (linear kernel)；
2. 多項式核函數 (polynomial kernel)：採用的項次為 2 至 5；
3. 輻狀基底函數 (radial basis function, RBF)：採用的 γ 為 1、2、5、10；
4. 採用近似係數的小波核函數 (wavelet kernel)：利用 2 次離散小波轉換，取近似係數的核函數，採用的小波基底函數為 haar、Daubechies 2、Daubechies 3。
5. 採用近似與細節係數的小波核函數 (wavelet kernel)：根據資料長度 n 進行 $\log_2(n)$ 次離散小波轉換，取近似係數的核函數，採用的小波基底函數為 haar、Daubechies 2、Daubechies 3。

將不同的實驗區 Hyperion 影像利用支持向量機進行分類之結果如表 7-8 所示，首先採用最常見的線性核函數時，分類準確度為 48.51%，Kappa 指標為 0.4064，多項式核函數的項次為 1 時即是線性核函數，而當項次逐漸增加，分類成果反而逐漸下降，多項式核函數的大小是決定類別邊界彈性的參數，越高的項次其邊界變化越明顯，類別決策邊界向類別中心緊縮，使得分布較外圍的資料未被正確分類。小波核函數同時考慮近似與細節係數的成果整體分類準確度超過 48%，比只考慮近似係數的成果佳，而考量不同小波基底函數的成果則差異不大。此外，表中 SVM 使用輻狀基底函數核函數的分類結果比其他核函數結果都來得佳，當 γ 參數設定為 5 時，整體分類準確度為 53.91%、Kappa 指標為 0.4618。而整體而言以支持向量機用於實驗區 Hyperion 影像分類的成果與前述方法相似，並未相當良好。

表 7-8、不同核函數之 SVM 分類成果

SVM 核函數 (參數)	Overall Accuracy (%)	Kappa 指標
線性核函數	48.51	0.4064
多項式核函數(項次=2)	44.65	0.3557
多項式核函數(項次=3)	32.59	0.2393
多項式核函數(項次=4)	24.35	0.1526
多項式核函數(項次=5)	17.18	0.0938
輻狀基底函數核函數($\gamma=1$)	2.75	0.0207
輻狀基底函數核函數($\gamma=2$)	52.47	0.4504
輻狀基底函數核函數($\gamma=5$)	53.91	0.4618
輻狀基底函數核函數($\gamma=10$)	49.53	0.4168
小波核函數(採用近似係數、haar)	43.25	0.3541
小波核函數(採用近似係數、db2)	44.18	0.3648
小波核函數(採用近似係數、db3)	43.44	0.3564
小波核函數 (同時採用近似與細節係數、haar)	48.51	0.4046
小波核函數 (同時採用近似與細節係數、db2)	48.42	0.4055
小波核函數 (同時採用近似與細節係數、db3)	48.18	0.4031

7.1.4、出雲山苗圃實驗區衛載 Hyperion 影像分析討論

本研究採用出雲山苗圃實驗區之衛載 Hyperion 高光譜影像，透過所提出的不同自動分類方法進行分類，其成果仍有提升之空間，採用的方法所得到的分類準確度皆不超過 60%，且部分類別錯誤分類情形明顯，分類後地圖的椒鹽效應也明顯。其中可能的原因包含：首先 Hyperion 高光譜影像在前處理時，只除去無法使用的波段及進行 FLAASH 改正，對於影像中存在的條紋雜訊，肉眼雖不易辨識，但對於分類之結果仍有影響；同時 Hyperion 的地面解析度為 30 公尺，像元中可能同時涵蓋了多種類別，即是光譜混合（spectral mixing）的情形，以及 Hyperion L1R 之影像沒有進行幾何校正，與真實地真資料的對位情形也有可能造成影響，因此需要針對目標類別的樣本像元作更細緻選擇分析。最後，此次研究選擇的類別以較粗略的林型做為目標，而同樣為針葉樹、闊葉樹林型中的樹種可能有所差異，以及混淆林型的樹種不同和多種樹種比例的差異，也會對於逐像元光譜分析造成影響；以及其他可能之實驗操作變因皆有可能對於成果造成影響。後續也把可能影響因素進行調整與精進，並且於機載高光譜影像分析納入考量。

7.2、花蓮光復實驗樣區之機載高光譜影像分析

7.2.1、花蓮光復實驗區域、高光譜影像前處理與地真資料說明

承續 5.2.2、節花蓮光復實驗樣區之取像成果，因取像後已完成相關之高光譜影像前處理程序，並完成影像鑲嵌，因此後續進行影像分析前只需決定影像大小及類別，根據農航所提供之 2017 年以 UAV 影像判釋之地真資料，花蓮光復實驗區所包含的植物物種共有光臘樹、杜英、楓香等共 34 種物種，其中約有 20 多種樹種分布僅有 1 個區域且涵蓋面積小，因此選定 10 種物種進行高光譜影像分類之實驗分析，影像大小則根據選定的樹種分布範圍，擷取最符合之影像範圍。

則經過裁切的花蓮光復實驗區影像如圖 7-9 所示，影像大小為寬 3700 個像元、高 5500 個像元，波段數 114 個波段；選定之物種分布地真資料如圖 7-10，共選取 10 個類別，分別為光臘樹、台灣檫、楓香、茄苳、杜英、烏心石、檸檬香茅、沉香、印度紫檀與水黃皮。決定實驗影像及類別後，則利用遙測影像處理軟體 ENVI 選取目標區域作為後續分析中訓練資料和檢核資料，目標區域避免選取鄰近類別邊界之區域，並於選取後以像元為單位，選定之各類別總像元數如表 7-9 所示。本節次後續則會說明不同影像分類之分析方法的操作流程與結果。



圖 7-9、花蓮光復實驗區影像




圖 7-10、花蓮光復實驗區地真資料分布

表 7-9、花蓮光復實驗區各類別之像元數

編號	樹種	目標區域(ROI)總像元數
1	光臘樹	129,628
2	台灣櫟	94,522
3	楓香	80,327
4	茄苳	55,029
5	杜英	72,941
6	烏心石	71,978
7	檸檬香茅	24,759
8	沉香	99,462
9	印度紫檀	28,322
10	水黃皮	39,606

7.2.2、以特徵分類法於花蓮光復實驗區影像分析

一、以特徵分類法之實驗方法說明

承續 6.1、節提出之特徵萃取方法，研究中共採用 5 種不同特徵萃取方法，透過維度縮減獲取可靠的特徵波段，研究中採用的特徵萃取方法，及相關參數設定說明如下：

1. 主成分轉換法 (PCT)：將花蓮光復實驗區影像根據其波段資訊進行主成分轉換後，可獲得特徵波段，其中當特徵波段總數為 59 個時，所涵蓋的影像資訊量為 99.99%，然而為了使得不同特徵萃取方法的特徵波段數一致，最後選定 35 個特徵波段。
2. 判別分析特徵萃取法 (DAFE)：將實驗影像利用開源軟體 Multispec©，配合目標類別的訓練資料進行 DAFE 轉換，而據演算法的特性，最後取的類別數減 1 個特徵波段，即 9 個特徵波段。
3. 決策邊界特徵萃取法 (DBFE)：將實驗影像同樣利用開源軟體 Multispec©，並配合目標類別的訓練資料進行特徵萃取之計算，計算後第 39 個特徵波段的特徵值為 0.0099，並隨著特徵波段的增加特徵

值會逐漸變小，後續影像分類則與其他特徵萃取方法之特徵波段數一致，選定 35 個特徵波段。

4. 線性小波轉換特徵萃取法 (WFE)：將實驗影像的每一個像元光谱曲線進行小波轉換，小波分解次數為 7 次，小波基底函數選擇 Daubechies 3 小波函數，以近似係數、細節係數尺度由大到小為順序，選取 35 個特徵波段。
5. 非線性小波轉換特徵萃取法 (NWFE)：NWFE 的特徵萃取方法與線性小波特徵萃取法相似，小波係數的排列方式則是根據係數的振幅(即係數絕對值大小)由大到小排列，選取 35 個特徵波段。

取得不同特徵萃取方法的特徵影像後，再利用最大似然法進行影像分類。

二、訓練資料數

由於選定的 10 個類別於影像中皆含有相當多像元數(如表 7-9)，為了採用合適的訓練樣本數及檢核樣本數進行影像分類，在考量類別像元數及程式軟體效能，分別利用隨機選取之方式，合計採用 5000、10000 與 20000 個像元數，以 7：3 之比例測試不同特徵分類法之成果，如表 7-10。則表中顯示採用 5000 個樣本像元時，不同特徵萃取方法的分類準確度皆比數量較多的樣本數略差一些，但不超過 1%，而利用 10000 個或 20000 個樣本像元兩者的成果差異並不明顯，考量到程式計算的效能，後續研究皆採用 10000 個像元樣本數(即 7000 個訓練樣本、3000 個檢核樣本)進行影像分類之分析。

表 7-10、不同特徵分類法以不同像元樣本數之分類成果

像元樣本數		20,000 (訓練：14,000、檢核：6,000)		10,000 (訓練：7,000、檢核：3,000)		5,000 (訓練：3,500、檢核：1,500)	
特徵萃取法	特徵波段數	OA(%)	Kappa 指標	OA(%)	Kappa 指標	OA(%)	Kappa 指標
PCT	35	81.59	0.7975	81.58	0.7974	80.90	0.7899
DBFE	35	82.99	0.8129	83.01	0.8131	82.28	0.8051
DAFE	9	83.84	0.8222	83.93	0.8232	83.52	0.8187
WFE	35	40.05	0.3406	40.74	0.3481	36.73	0.3040
NWFE	35	64.73	0.6120	64.68	0.6115	64.13	0.6055

三、不同特徵分類法之分類成果

本小節依序說明利用不同特徵萃取方法配合最大似然法分類後之成果。首先，利用 PCT 特徵萃取之分類成果與特徵波段數之關係如圖 7-11 所示，特徵波段數為 1 時的分類準確度最差，隨著特徵波段數增加，其分類成果也逐漸提升，當特徵波段為 9 個時，整體分類準確度為 77.32%、Kappa 指標為 0.7519，再逐漸增加特徵數時，分類準確度呈現小幅度增加之情形，因本次研究選定最多為 35 個特徵波段，因此當特徵波段為 35 時，達到最高的分類準確度為 81.58%，Kappa 指標為 0.7974，同時檢視各類別的分類成果，如表 7-11，由各個類別生產者準確度來看漏判之情形，其中杜英和楓香的結果較差，生產者準確度皆不超過 70%，其次為茄苳和烏心石，其他類別的生產者準確度大於 80%，分類結果最佳的類別為光臘樹；而由使用者準確度觀察各類別之誤判情形，以烏心石的成果最差，使用者準確度為 74.69%，而檸檬香茅、沉香、和水黃皮則是誤判情形較少之類別，其使用者準確度均大於 95%。圖 7-12 則是整張實驗影像進行分類後的類別成果圖，可以看出主要選定之類別大致都有被正確分類，且可看出其分區之情形，同時河道、道路等不屬於選定類別之區域也都有正確區分出來，由於是採用逐像元分類，因此分類成果會有椒鹽效應之影響，以及在航帶之間鑲嵌的區域分類成果也較差。

利用 DAFE 的分類成果如圖 7-13 所示，因為演算法特性的緣故，最多只有 9 個特徵波段，而分類成果也隨著特徵數的增加，分類準確度逐漸提升，當特徵波段為 9 個時，分類準確度為 83.93%，Kappa 指標為 0.8232，表 7-12 為各類別分類之成果，其中楓香、杜英、茄苳和烏心石為漏判情形較明顯之類別，生產者準確度均小於 80%，又以楓香和杜英的結果最差，而使用者準確度表現較差的類別也是楓香；檸檬香茅與沉香則是分類結果較好的類別，在生產者準確度和使用者準確度均較高。而圖 7-14 中 DAFE 的類別分類成果圖，同樣可看出各類別的分區情形，及道路、河道等區域未被錯誤分類，成果圖中也有椒鹽效應和鑲嵌區域分類成果較差之情形。

DBFE 的分類成果則是略優於 PCT 和 DAFE，如圖 7-15，DBFE 分類

準確度同樣隨著特徵波段增加而逐漸增加，當特徵波段數為 10 個時，分類結果最好，整體分類準確度為 84.25%、Kappa 指標為 0.8267，隨著特徵波段數持續增加，整體分類準確度則有小幅變差之情形，採用 35 個特徵波段時，整體分類準確度為 83.01%。由表 7-13 觀察各類別分類結果，生產者準確度仍是以楓香、杜英的結果較差，其次為茄苳，其他剩餘類別的生產者準確度都介於 80%到 90%之間，使用者準確度較佳的仍為檸檬香茅、沉香等 2 個類別，而烏心石的使用者準確度最差，只有 78.86%。圖 7-16 同樣為整張實驗影像的分類成果類別圖，其分類成果和 PCT、DAFE 特徵分類法的成果差異不大，同樣的可看出不同類別之分區情形，以及椒鹽現象、影像鑲嵌影響之情形。




圖 7-11、主成分轉換法之分類成果

表 7-11、主成分轉換法（特徵數：35）類別成果

特徵波段數		OA	Kappa 指標
35		81.58%	0.7974
類別	生產者準確度(%)	使用者準確度(%)	
1 光臘樹	90.00	90.76	
2 台灣檫	85.33	91.76	
3 楓香	68.47	79.24	
4 茄苳	75.87	88.73	
5 杜英	66.10	78.94	
6 烏心石	77.70	74.69	
7 檸檬香茅	81.00	100.00	
8 沉香	82.00	98.76	
9 印度紫檀	83.70	87.07	
10 水黃皮	87.50	96.29	




圖 7-12、PCT 特徵分類法，35 個特徵波段分類類別圖




圖 7-13、判別分析特徵萃取法之分類成果

表 7-12、判別分析特徵萃取法（特徵數：9）類別成果

特徵波段數		OA	Kappa 指標
9		83.93%	0.8232
類別	生產者準確度(%)	使用者準確度(%)	
1 光臘樹	84.63	81.14	
2 台灣檫	86.93	92.29	
3 楓香	71.20	74.92	
4 茄苳	76.77	88.68	
5 杜英	73.70	80.99	
6 烏心石	79.70	78.39	
7 檸檬香茅	89.67	100.00	
8 沉香	90.60	97.28	
9 印度紫檀	83.57	89.92	
10 水黃皮	86.80	94.83	




圖 7-14、DAFE 特徵分類法，9 個特徵波段分類類別圖




圖 7-15、決策邊界特徵萃取法之分類成果

表 7-13、決策邊界特徵萃取法（特徵數：10）類別成果

特徵波段數		OA	Kappa 指標
10		81.58%	0.7974
類別	生產者準確度(%)	使用者準確度(%)	
1 光臘樹	87.67	86.00	
2 台灣檫	84.97	94.55	
3 楓香	72.40	80.59	
4 茄苳	78.17	88.72	
5 杜英	73.10	82.26	
6 烏心石	81.80	78.86	
7 檸檬香茅	87.97	100.00	
8 沉香	86.33	98.03	
9 印度紫檀	84.93	86.43	
10 水黃皮	89.73	92.22	




圖 7-16、DBFE 特徵分類法，10 個特徵波段分類類別圖

利用小波轉換特徵萃取法的分類準確度如圖 7-17 和圖 7-19 所示，其中線性 WFE 的分類成果較其他特徵分類法來得差，當特徵波段數為 5，整體分類準確度為 59.24%、Kappa 指標為 0.5516，當特徵數持續增加，反而使得最大似然法中矩陣不穩定，造成分類準確度有明顯的下降之情形，表 7-14 為 WFE 個類別分類成果，其中杜英的分類成果最差，其生產者準確度和使用者準確度分別為 23.47%、34.31%，皆低於 40%，而檸檬香茅的分類結果最佳，生產者及使用者準確度都高於 85%。而非線性小波特徵轉換的分類結果如圖 7-19，當特徵波段數逐漸增加時，分類準確度逐漸上升，當特徵波段數大於 7 個時，分類準確度呈現比較平穩上升的狀態，當特徵波段數為 26 個，其分類準確度為 65.89%、Kappa 指標為 0.6248，表 7-15 為各類別的分類成果，同樣是杜英的分類結果最差，生產者及使用者準確度都不超過 50%，而檸檬香茅在這個分類方法中，雖然使用者準確度仍達到 98.25%，顯示誤判之情形較少，但生產者準確度為 73%，即漏判的情況比其他方法明顯。圖 7-18、圖 7-20 分別為線性和非線性小波轉換特徵萃取方法的分類類別圖，則圖中 2 個方法的椒鹽效應也是相當明顯，類別之間也有錯誤分類的情形，以及部分背景像元也沒有被正確排除。探討造成小波特徵轉換萃取法的分類成果較差之原因，可能為特徵萃取時是透過逐一像元進行特徵萃取，同時未配合訓練資料輔助計算特徵，在實驗影像中，同一個物種類別的像元，可能因為光線照射之方向、生長情形，以及在 1 公尺的空間解析度下，某些像元是屬於背景像元而非類別像元，讓同一個類別中的像元亮度有顯著的差距，在進行小波轉換後，同一個排序的特徵可能對應到該類別不同吸收帶或曲線特徵，則使得特徵波段無法成為有效之特徵，造成分類成果不佳。




圖 7-17、線性小波轉換特徵萃取法之分類成果

表 7-14、線性小波轉換特徵萃取法（特徵數：5）類別成果

特徵波段數		OA	Kappa 指標
5		59.24%	0.5516
類別	生產者準確度(%)	使用者準確度(%)	
1 光臘樹	61.57	41.26	
2 台灣檫	58.40	66.97	
3 楓香	62.40	46.93	
4 茄苳	46.33	59.20	
5 杜英	23.47	34.31	
6 烏心石	67.30	52.62	
7 檸檬香茅	85.50	95.21	
8 沉香	57.97	84.25	
9 印度紫檀	20.90	58.71	
10 水黃皮	68.33	51.11	




圖 7-18、WFE 特徵分類法，5 個特徵波段分類類別圖




圖 7-19、非線性小波轉換特徵萃取法之分類成果

表 7-15、非線性小波轉換特徵萃取法（特徵數：26）類別成果

特徵波段數		OA	Kappa 指標
26		65.89%	0.6248
類別	生產者準確度(%)	使用者準確度(%)	
1 光臘樹	76.87	60.02	
2 台灣櫟	78.07	77.88	
3 楓香	49.03	51.45	
4 茄苳	51.90	76.03	
5 杜英	44.07	42.32	
6 烏心石	67.27	65.86	
7 檸檬香茅	73.00	98.25	
8 沉香	61.33	76.99	
9 印度紫檀	46.83	79.02	
10 水黃皮	78.83	76.09	




圖 7-20、NWFE 特徵分類法，26 個特徵波段分類類別圖




圖 7-21、不同特徵分類法之分類準確度

圖 7-21 為本研究中採用不同特徵分類法的分類準確度比較，可以看到其中利用 DAFE、DBFE 的分類準確度比其他方法來得佳，可以達到約 85% 的分類準確度，其次為 PCT 當特徵波段逐漸增加，分類準確度亦可以逐漸增加到約 82%，而採用小波轉換的特徵萃取法則比其他方法來得差。另外，從不同特徵分類法的分類類別成果圖，大致不同類別的分區都有正確被分類，而影像中則都有受到椒鹽效應，以及不同航帶間鑲嵌區域成果不佳的影響，在影像中單一類別的生長情形、光線角度、背景像元也都會對於分類之成果造成影響，未來可針對相關之情形進行深入探討。

7.2.3、以物件導向分類法於花蓮光復實驗區影像分析


一、以物件導向分類法之實驗方法說明

以物件導向分類法是利用 eCognition 軟體進行實驗操作，在進行物件導向分類操作前，利用主成分轉換（PCT）降低影像的波段數，因原始影像含有 144 個波段，在後續計算分割或是特徵值都會造成軟體效能不佳，因此利用 PCT 將影像降維成 15 個特徵波段，以較少的波段數進行分析。後續物件導向分類之實驗程序主要為影像分割，分割後得到的影像物件進行特徵選擇並計算特徵值，最後以影像物件為單位，利用軟體中最鄰近分類法（Nearest Neighbor Classification, NN）進行影像分類。


首先須將影像分割為合適的物件大小，所需設定的參數包含尺度因子（scale），是決定分割後物件大小的參數，第 2 為形狀異質性指標（shape）則是決定分割依據以形狀或是波段值為主，當形狀異質性指標較小，則波段值的比重較重，第 3 為緊密度異質性指標（compactness），當緊密度異質性指標較大時，則分割獲得的影像物件形狀較為完整，非彎曲不平的多邊形。因此根據花蓮光復實驗區的類別分布情形，不同類別仍需一波段的差異進行分割，分割波段依據為 PCT 特徵波段 1 至 3，將形狀異質性指標設定為 0.3，而花蓮光復實驗區中，不同類別的分布形狀都是以規則矩形或多邊形為主，因此將緊密度異質性指標設定較大的值為 0.9，進行分割。後續則需決定尺度因子找出合適的影像物件大小，如圖 7-22 所示，圖 7-22(a) 中設定較小的尺度因子（scale=200），則分割後的影像物件區塊偏小，同一個物件區物被分割為過多的小區塊，圖 7-22(c)則是設定較大的尺度因子（scale=1000），雖然圖(c)右側之類別區塊被分割為較合適且完整的區塊，但圖(c)左側的分割區塊則過大，一個影像物件涵蓋了多個類別，若尺度因子設定為 600，如圖 7-22(b)，則圖(b)左側類別的分割區塊與原始類別的區塊較為吻合，影像物件區塊沒有過大或過小之情形，圖(b)的右側類別雖然比圖(c)分割為更小的區塊，但區塊形狀仍完整；因此將影像分割參數設定為圖 7-22(b)。

分割獲得影像物件後，需選取物件之特徵，不同類別的分類依據仍以


波段值為主要依據，因此選定了影像各波段的平均值、標準差，以及整體向的亮度（brightness）和 Max diff.，另外也將影像物件的形狀因子加入考量，因此加入 Border index、Compactness、Density、Roundness、Shape index 等形狀指標，選定之特徵如表 7-16。透過 eCognition 軟體進行影像分割並計算特徵後，則利用內建的最鄰近分類法進行影像分類。



(a)尺度因子：200，形狀異質性指標：0.3，緊密度異質性指標：0.9



(b)尺度因子：600，形狀異質性指標：0.3，緊密度異質性指標：0.9



(c)尺度因子：2000，形狀異質性指標：0.3，緊密度異質性指標：0.9

圖 7-22、影像分割參數設定

表 7-16、選定之物件分類特徵

特徵性質	波段值	空間
特徵	● 平均值：特徵波段 1 至 15 平均值 ● 標準差：特徵波段 1 至 15 標準差 ● 其他：Brightness、Max. diff	● 形狀：Border index、Compactness、Density、Roundness、Shape index

二、物件導向分類法之分類成果

將物件導向分類之成果，以檢核資料進行分類結果評估，則整體分類準確度為 77.36%，Kappa 指標為 0.7510，表 7-17 顯示各類別的分類成果，在生產者準確度中成果最差的為楓香，漏判的情形很顯著，其次為茄苳、印度紫檀與杜英的成果較差，而沉香、烏心石與檸檬香茅在生產者準確度有較好的表現，均超過 90%，使用者準確度中，則沒有單一類別特別差的現象，但台灣欒、楓香、杜英和烏心石等類別的使用者準確度較差，大約在 60% 左右，檸檬香茅、沉香與印度紫檀的使用者準確度較佳，皆優於 90%。圖 7-23 則為利用物件導向分類法各類別的分類圖，可以看到原本地真資料分布區塊較大較完整的區域，如影像左下方的光臘樹、台灣欒、沉香和檸檬香茅等區塊的分割成果較完整，且被正確分類，而其他區域物種的分布區塊較小，容易與其他類別混淆，部分分割成果也不夠精確，造成被分類至錯誤類別的情形，仍是需要調整改善的因素。

表 7-17、物件導向分類法類別成果

		OA	Kappa 指標
		77.36%	0.7510
類別	生產者準確度(%)	使用者準確度(%)	
1 光臘樹	89.83	68.87	
2 台灣檫	79.00	56.96	
3 楓香	12.23	59.10	
4 茄苳	60.80	88.37	
5 杜英	69.30	59.30	
6 烏心石	96.90	61.69	
7 檸檬香茅	92.03	100.00	
8 沉香	99.87	98.75	
9 印度紫檀	66.93	94.05	
10 水黃皮	89.43	89.02	




圖 7-23、花蓮光復實驗區物件導向分類法分類類別圖

7.2.4、以機器學習為基礎之分類法於花蓮光復實驗區影像分析

花蓮光復實驗區影像利用機器學習方法進行分類，主要採用了支持向量機與深度學習演算法，以下則進行分類方法與成果說明：

一、利用支持向量機進行高光譜影像分類

以支持向量機進行高光譜影像分類之分析，分析的工具是透過 Python 程式中的機器學習 scikit-learn 模組搭配高光譜影像分析的 spectral 模組，

以自行撰寫程式的方式操作實驗，而訓練樣本的選取則延續特徵分類法的設定，選定 10000 個像元，以 7：3 的數量分配，其中 7000 個像元為訓練資料、3000 個像元為檢核資料；實際操作方法主要是利用支持向量機搭配不同核函數及參數設定，以逐像元的方式進行影像分類，採用的核函數包含：

1. 線性核函數 (linear kernel)；
2. 多項式核函數 (polynomial kernel)：採用的項次為 2 至 5；
3. 輻狀基底函數 (radial basis function, RBF)：採用的 γ 為 1、5、10；
4. 採用近似係數的小波核函數 (wavelet kernel)：利用 2 次離散小波轉換，取近似係數的核函數，採用的小波基底函數為 haar、Daubechies 2、Daubechies 3。

花蓮光復實驗區高光譜影像利用不同的支持向量機分類成果如表 7-18 所示。首先採用最簡單的線性核函數時，分類的成果最佳，可達到 89% 整體分類準確度，Kappa 指標為 0.8777；利用多項式核函數的成果則明顯比線性核函數差，同時隨著項次增加，分類準確度卻明顯下降，當多項式的項次增加，也使得支持向量機中類別邊界的變化越明顯，並且類別決策邊界往類別中心緊縮，則在資料分布變異較大時，會使得分布較外圍的資料點未被正確分類。類似的情形也可以在輻狀基底函數核函數可以看到，當 γ 參數設定為程式預設值時， γ 為波段數分之一，則分類準確度為 84.12%，而隨著 γ 參數設定為 1 或逐漸增加至 5、10 時，分類準確度也很明顯下降，因 γ 參數會對決策邊界造成影響，當 γ 參數變大，各類別的決策邊界會向該類別的支持向量分布範圍緊縮，則分布較外圍的資料容易被錯誤分類。利用小波核函數的分類成果則與線性核函數的成果相近，採用近似係數的小波核函數 (基底函數為 Daubechies 3) 時分類準確度有 88.45%，而 haar、Daubechies 2、Daubechies 3 的差異為消失動量 (vanishing moment) 的不同，在成果的顯示上差異不明顯。表 7-19 為採用線性核函數的各類別分類成果，其中以杜英和楓香的分類結果較差，生產者與使用者準確度都不超過 80% 或只有 82%，而其他類別的生產者與使用者準確度均優於 85%，其

中檸檬香茅與沉香的分類結果最佳，即是漏判或誤判的情形很低。

表 7-18、不同核函數之 SVM 分類成果

SVM 核函數 (參數)	Overall Accuracy(%)	Kappa 指標
線性核函數	89.00	0.8777
多項式核函數(項次=2)	72.87	0.6985
多項式核函數(項次=3)	70.31	0.6701
多項式核函數(項次=4)	60.00	0.5555
多項式核函數(項次=5)	57.88	0.5320
輻狀基底函數核函數(γ =default)	84.12	0.8236
輻狀基底函數核函數(γ =1)	65.87	0.6208
輻狀基底函數核函數(γ =5)	11.69	0.0188
輻狀基底函數核函數(γ =10)	10.81	0.0090
小波核函數(採用近似係數、haar)	87.87	0.8653
小波核函數(採用近似係數、db2)	88.14	0.8682
小波核函數(採用近似係數、db3)	88.45	0.8716

表 7-19、SVM 線性核函數類別成果

核函數		OA	Kappa 指標
linear		89.00%	0.8777
類別	生產者準確度(%)	使用者準確度(%)	
1 光臘樹	92.37	82.84	
2 台灣櫟	91.73	94.77	
3 楓香	78.57	77.76	
4 茄苳	85.60	85.89	
5 杜英	77.10	82.02	
6 烏心石	85.47	86.80	
7 檸檬香茅	99.50	100.00	
8 沉香	95.83	97.72	
9 印度紫檀	92.33	89.35	
10 水黃皮	91.47	93.68	

二、利用深度學習演算法進行高光譜影像分類

本研究中利用深度學習演算法進行分類，分別採用了 Convolution neural network(CNN)和 Wide Contextual Residual Network(WCRN)2 種深度學習演算法，而深度學習演算法在程式計算時都需要耗費大量的電腦記憶體與計算資源，則本研究中擷取 1000×1000 的影像大小區域進行深度學習演算法高光譜影像分析，如圖 7-24，此區域包含的類別則有光臘樹、台灣櫟、楓香、杜英及檸檬香茅等 5 種類別。




圖 7-24、花蓮光復實驗區影像區塊用於深度學習法


利用 CNN 深度學習演算法之成果如表 7-20 所示，則可以看到整體分類準確度為 85%，而各個類別的分類準確度除了光臘樹的表現較差，分類之精度為 59%，其他類別的分類成果均有良好的表現，楓香的分類準確度為 85%，台灣櫟、杜英、檸檬香茅的類別分類準確度，皆優於 92%，圖 7-25 為利用 CNN 演算法的影像類別成果圖，由圖 7-25(b)可以看出分類後各類別種類分布與地真資料大致相符。WCRN 為 CNN 演算法的一種延伸，其採用的神經網路層數較 CNN 來得多，可以到達 256 層神經網路，本研究中實驗操作是利用 Python 程式的 Keras 和 TensonFlow 工具。採用 WCRN 的整體分類準確度可到達 98.24%，圖 7-26 則是 WCRN 的分類類別成果圖，圖 7-26(b)可看出僅有少部分的資料點數被錯誤分類，其成果較 CNN 方法佳。

表 7-20、花蓮光復實驗區採用 CNN 演算法之實驗結果


類別	Precision	recall	f1-score	support
台灣櫟	93%	0.99	0.96	1063
楓香	85%	0.94	0.89	4025
光臘樹	59%	0.96	0.73	2217
杜英	96%	0.83	0.89	4414
檸檬香茅	92%	0.74	0.82	6189
OA			85%	17908
macro avg	0.85	0.89	0.86	17908
weighted avg	0.88	0.85	0.85	17908

表 7-21、CNN 演算法各類別誤差矩陣

類別名稱	台灣櫟	楓香	光臘樹	杜英	檸檬香茅
台灣櫟	1055	8	0	0	0
楓香	65	3766	14	51	129
光臘樹	0	1	2133	26	57
杜英	17	388	160	3662	187
檸檬香茅	0	283	1291	58	4557




(a)原始訓練資料區塊




(b)分類後影像成果

圖 7-25、CNN 深度學習法花蓮光復實驗區影像分類成果



(a)原始訓練資料區塊



(b)分類後影像成果

圖 7-26、WCRN 深度學習法花蓮光復實驗區影像分類成果

7.3、出雲山苗圃實驗樣區之機載高光譜影像分析

7.3.1、出雲山苗圃實驗區域、高光譜影像前處理與地真資料說明

同樣承續 5.2.2、節出雲山苗圃實驗樣區之取像成果，取得完成前處理與影像鑲嵌之實驗區高光譜影像，則後須根據地真資料決定分類的類別與影像大小。地真資料為貴所提供之第四次森林資源調查成果，並配合 2017 年正射影像編輯修改後，獲得更新的地真資料分布，同時根據前述之衛載 Hyperion 影像分析成果，若以「差異型態名稱」的不同林型做為分類目標，在單一林型中可能會包含不同樹種，而不同樹種的光譜曲線通常會有所差異，若視為同一類別進行分類可能會使得分類成果不理想。因此，本研究中則選取欄位「差異型態名稱」的針葉樹林型，以針葉樹林型中不同樹種為分類目標，類別分部範圍如圖 7-28 所示，選定檜木(紅檜、扁柏)、臺灣肖楠、杉木(巒大杉、杉木等)、柳杉、台灣杉等 5 種針葉樹樹種作為分類目標類別，選定的總像元樹如表 7-22 所示。

根據選定的類別以及排除原始影像雲遮蔽區的影響，裁切後的出雲山苗圃實驗區影像如圖 7-27，影像大小為寬 4200 個像元、長 6500 個像元，波段數為 96 個波段。與花蓮光復實驗區處理步驟相同，決定實驗影像與類別後，利用 ENVI 軟體選取訓練資料，以像元為單位選取訓練資料與檢核資料後，用於不同影像分類之分析方法中。




圖 7-27、出雲山苗圃實驗區影像




圖 7-28、出雲山苗圃實驗區地真資料分布

表 7-22、出雲山苗圃實驗區各類別之像元數

編號	樹種	目標區域(ROI)總像元數
1	檜木(紅檜、扁柏)	11,180
2	臺灣肖楠	73,911
3	杉木(巒大杉、杉木等)	243,609
4	柳杉	115,455
5	台灣杉	146,262

7.3.2、以特徵分類法於出雲山苗圃實驗區影像分析

一、以特徵分類法之實驗方法說明

同樣承續 6.1、節提出之特徵萃取方法，本研究採用 5 種不同特徵萃取方法，影像經維度縮減後獲取可靠的特徵波段，特徵萃取方法及相關參數設定說明如下：

1. 主成分轉換法 (PCT)：將出雲山苗圃實驗區影像以波段資訊進行主成分轉換，當特徵波段總數為 46 個時，所涵蓋的影像資訊量即達到 100%，而為了與不同特徵萃取方法的特徵波段一致，亦選定 35 個特徵波段。
2. 判別分析特徵萃取法 (DAFE)：將實驗影像利用 Multispec©軟體，配合目標類別的訓練資料進行 DAFE 轉換，而據演算法的特性，最後取的類別數減 1 個特徵波段，即 4 個特徵波段。
3. 決策邊界特徵萃取法 (DBFE)：將實驗影像同樣 Multispec©軟體，配合目標類別的訓練資料進行特徵轉換計算，計算後第 53 個特徵波段的特徵值為 0.0100，並隨著特徵波段的增加特徵值會逐漸變小，為了與其他特徵萃取方法之特徵波段數一致，同樣選定 35 個特徵波段。
4. 線性小波轉換特徵萃取法 (WFE)：將實驗影像的每一個像元的光譜曲線進行小波轉換，小波基底函數為 Daubechies 3 小波函數，小波分解次數為 6 次，以係數尺度由大到小為順序，選取 35 個特徵波段。
5. 非線性小波轉換特徵萃取法 (NWFE)：NWFE 的特徵萃取方法與線性小波特徵萃取法相似，小波係數排列方式則以係數絕對值大小由大到小

排列，選取 35 個特徵波段。

取得不同特徵萃取方法的特徵影像後，再利用最大似然法進行影像分類。

二、訓練資料數

與花蓮光復實驗區相同，出雲山苗圃實驗區為了採用合適的訓練及檢核樣本樹進行影像分類，同時考量類別像元樹及程式軟體效能，分別採用 5000、10000、20000 個像元，以 7:3 之比例測試不同特徵分類法之成果，其中檜木(紅檜、扁柏)的像元數不足 2 萬個，則將總數利用 7:3 之比例分為訓練與檢核樣本。表 7-23 為不同樣本數的分類結果，則可以看到利用不同像源樣本處的成果差異不顯著，以 PCT 為例樣本數為 10000 個的分類結果最佳，但比其他方法好 0.6~0.7%左右，因此與花蓮光復實驗區相同，採用 10000 個像樣本數(即 7000 個訓練樣本、3000 個檢核樣本)進行影像分類之分析。

表 7-23、不同特徵分類法以不同像元樣本數之分類成果

像元樣本數		20000 (訓練：14000、檢核：6000)		10000 (訓練：7000、檢核：3000)		5000 (訓練：3500、檢核：1500)	
特徵萃取法	特徵波段數	OA(%)	Kappa 指標	OA(%)	Kappa 指標	OA(%)	Kappa 指標
PCT	35	72.22	0.6643	72.96	0.6755	72.40	0.6688
DBFE	35	73.72	0.6824	74.14	0.6897	73.86	0.6863
DAFE	4	74.61	0.6938	75.19	0.7023	75.03	0.7004
WFE	35	54.79	0.4582	62.62	0.5514	63.02	0.5563
NWFE	35	45.87	0.3453	46.08	0.3529	46.24	0.3549

三、不同特徵分類法之分類成果

本小節說明利用不同特徵分類法的分類成果；首先，利用 PCT 特徵萃取的分類成果與特徵波段之關係如圖 7-29 所示，與前述的實驗成果相似，隨著特徵波段數增加，整體分類準確度也逐漸增加，當特徵波段數大於 11 時，分類準確度的增加幅度則呈現平緩，當特徵數為 26 個時，分類結果為 PCT 方法最佳，整體分類準確度為 73.84%、Kappa 指標為 0.6861。表 7-24 為不同類別的分類成果，其中杉木(巒大杉、杉木等)的分類成果最差，生

產者準確度為 55.47%、使用者準確度為 64.55%，其次較差的類別為臺灣肖楠和台灣杉，檜木的分類成果為最佳，生產者準確度為 82.77%，使用者準確度則可達到 92.24%。由圖 7-30 則可以看出整體分類類別圖的成果較不理想，影像中雖然選定的類別分類結果大致正確，但影像中仍可看出椒鹽效應及影像鑲嵌區域分類成果不佳，同時其他未選定的區域也被錯誤分類，可能原因為未選定之類別亦包含了本實驗中選定的類別樹種，此外出雲山苗圃實驗區的地形起伏較為明顯，使得影像中光線方向和地形效應對於不同像元造成的影像較為顯著。

利用 DAFE 的分類成果如圖 7-31 所示，當特徵波段從 1 個增加到 4 個時，分類準確度也隨之增加，當特徵波段為 4 個時，分類準確度為 75.19%、Kappa 指標為 0.7023，各類別的分類結果也與 PCT 特徵分類法相似，如表 7-25，同樣為杉木(巒大杉、杉木等)的分類成果最差，生產者準確度和使用者準確度都在 55% 左右，其次較差的類別同樣是臺灣肖楠與台灣杉，最後檜木的分類成果則較其他類別來得好，其生產者準確度為 87.93%、使用者準確度為 85.79%，在整體分類成果圖中(如圖 7-32)，成果亦不理想，除了椒鹽效應、影像鑲嵌區域分類結果較差，亦有地形效應之影響。

DBFE 之分類準確度與特徵波段之關係如圖 7-33 所示，當特徵波段數大於 5 時，分類準確度的提升幅度逐漸平緩，或有些微降低之情形，當特徵波段數為 14 個時，分類成果最佳，分類準確度為 77.06%、Kappa 指標為 0.7247，由表 7-26 中，不同類別的分類成果仍是杉木(巒大杉、杉木等)的分類成果最差，其次依序為臺灣肖楠、台灣杉、柳杉，而分類結果為檜木最佳。圖 7-34 的 DBFE 分類類別圖則與 PCT、DAFE 的成果類似，雖然選定的類別區域大致有正確分類，但未選定的區域也有錯誤分類之情形，以及影像鑲嵌和整體影像的地形效應，也對分類結果造成影響。




圖 7-29、主成分轉換法之分類成果

表 7-24、主成分轉換法（特徵數：26）類別成果

特徵波段數		OA	Kappa 指標
26		73.84%	0.6861
類別	生產者準確度(%) 使用者準確度(%)		
1 檜木(紅檜、扁柏)	82.77	92.24	
2 臺灣肖楠	60.97	80.68	
3 杉木(巒大杉、杉木等)	55.47	64.55	
4 柳杉	80.07	78.34	
5 台灣杉	67.93	71.41	




圖 7-30、PCT 特徵分類法，26 個特徵波段分類類別圖




圖 7-31、判別分析特徵萃取法之分類成果

表 7-25、判別分析特徵萃取法（特徵數：4）類別成果

特徵波段數		OA	Kappa 指標
4		75.19%	0.7023
類別	生產者準確度(%) 使用者準確度(%)		
1 檜木(紅檜、扁柏)	87.93	85.79	
2 臺灣肖楠	67.90	81.48	
3 杉木(巒大杉、杉木等)	55.67	55.91	
4 柳杉	82.37	78.97	
5 台灣杉	70.67	70.36	




圖 7-32、DAFE 特徵分類法，4 個特徵波段分類類別圖




圖 7-33、決策邊界特徵萃取法之分類成果

表 7-26、決策邊界特徵萃取法（特徵數：14）類別成果

特徵波段數		OA	Kappa 指標
14		77.06%	0.7247
類別	生產者準確度(%) 使用者準確度(%)		
1 檜木(紅檜、扁柏)	87.40	92.95	
2 臺灣肖楠	64.17	83.19	
3 杉木(巒大杉、杉木等)	61.87	64.60	
4 柳杉	82.97	80.89	
5 台灣杉	69.97	74.49	




圖 7-34、DBFE 特徵分類法，14 個特徵波段分類類別圖

利用小波轉換特徵萃取法的分類準確度如圖 7-35 及圖 7-37 所示，小波特徵萃取分類法的結果皆比前述之方法來得差，其中，線性 WFE 的分類結果隨著特徵波段數增加，分類準確度有明顯的起伏變化，當特徵波段為 22 個時，整體分類準確度為 69.99%，Kappa 指標為 0.6399，而 NWFE 的分類結果為最差，整體的分類準確度都低於 52%。表 7-27 和表 7-28 分別為線性與非線性小波轉換特徵萃取分別在 22 個和 20 個特徵波段的各類別分類結果，從表中可以看到與 PCT、DAFE、DBFE 各類別的分類結果趨勢較不一致，在線性小波轉換特徵萃取法中，各種類的分類結果並沒有特別良好的類別，其中生產者準確度最好的種類為檜木的 85.07%，而使用者準確度則是柳杉的成果最佳，為 87.35%。在分類類別圖的成果中(圖 7-36、圖 7-38)，則可以看到 2 種小波轉換特徵萃取法的成果亦受到椒鹽效應、影像鑲嵌與地形效應的影響，雖然選定的類別有一定的正確性，但未選定類別的區域也被錯誤分類，而非線性小波轉換特徵萃取法的成果又更差，反而顯現出該區域的地形變化情形。




圖 7-35、線性小波轉換特徵萃取法之分類成果

表 7-27、線性小波轉換特徵萃取法（特徵數：22）類別成果

特徵波段數		OA	Kappa 指標
22		69.99%	0.6399
類別		生產者準確度(%) 使用者準確度(%)	
1	檜木(紅檜、扁柏)	85.07	78.77
2	臺灣肖楠	62.00	72.54
3	杉木(巒大杉、杉木等)	62.63	51.58
4	柳杉	62.40	87.35
5	台灣杉	50.67	67.92




圖 7-36、WFE 特徵分類法，22 個特徵波段分類類別圖




圖 7-37、非線性小波轉換特徵萃取法之分類成果

表 7-28、非線性小波轉換特徵萃取法（特徵數：20）類別成果

特徵波段數		OA	Kappa 指標
20		51.69%	0.4203
類別	生產者準確度(%) 使用者準確度(%)		
1 檜木(紅檜、扁柏)	57.70	69.38	
2 臺灣肖楠	42.67	64.74	
3 杉木(巒大杉、杉木等)	20.63	39.53	
4 柳杉	66.17	38.72	
5 台灣杉	41.67	43.40	




圖 7-38、NWFE 特徵分類法，20 個特徵波段分類類別圖




圖 7-39、不同特徵分類法之分類準確度

圖 7-39 為出雲山苗圃實驗區採用不同特徵分類方法的分類準確度比較，可以看出利用 DAFE、DBFE 的分類準確度比其他方法佳，可以達到約 77% 的分類準確度，其次為 PCT 方法，而採用小波轉換特徵萃取法的成果較差，非線性小波轉換特徵萃取法只能達到 50% 的分類準確度，而可能的原因為出雲山苗圃實驗區因地形變化更顯著，使得同一個類別的不同像元亮度有明顯的差異，也就是同一類別的光譜曲線標準差較大，在進行小波轉換後，選定的同一排序波段可能並非對應到相同的吸收帶或曲線特徵，無法組成帶有有效資訊的特徵波段，使得分類成果不佳。此外，從不同特徵分類法的類別成果圖可以看出，影像分類結果除了椒鹽效應、影像航帶間鑲嵌區域之影響，因為光線入射角度和地形起伏，造成的地形效應也使得同一類別的像元不一定能被正確分類，造成分類結果較差之情形，以及其他未被選定的類別區域，也可能含有針葉樹林型的樹種，產生未選定之區域被分類之情況。


7.3.3、以物件導向分類法於出雲山苗圃實驗區影像分析

一、以物件導向分類法之實驗方法說明


出雲山苗圃實驗區影像同樣利用 eCognition 軟體進行實驗操作，在進行物件導向分類操作前，利用主成分轉換法(PCT)將原始影像 96 個波段減少為 15 個特徵波段，以較少的波段數進行分析。後續則進行物件導向分類法之實驗程序，先進行影像分割，分割後得到的影像物件進行特徵選擇並計算特徵值，最後以影像物件為單位，利用軟體中最鄰近分類法(NN)進行影像分類。

首先須將影像分割為合適的物件大小，所需設定的參數包含決定分割後物件大小的尺度因子 (scale)，形狀異質性指標 (shape) 則是決定分割依據以形狀或是波段值為主，以及緊密度異質性指標 (compactness) 決定分割獲得的影像物件形狀是否較為完整，或屬於彎曲不平的多邊形。根據出雲山苗圃實驗區的類別分布情形，不同類別主要是利用波段值進行分割，因此選擇 PCT 特徵波段 1 至 3 為分割依據，同時此區域的類別分布不是形狀規則的多邊形或矩形為主，所以將形狀異質性指標設定為 0.1，比花蓮光復實驗區更加重波段值的權重，而緊密度異質性指標者設為 0.7，對於形狀的完整度要求較低，後續則需決定尺度因子，找出合適的影像物件大小，如圖 7-40，圖 7-40(a)將尺度因子設定為 600，則分割得到的物件大致會比選定的類別分布較小，或符合類別分布之形狀，若是再降低尺度因子，則會使得影像物件大小過小，而圖 7-40(b)則是將尺度因子設定為 1000，可以看到分割後的影像物件可能會擴及其他類別的區塊，因此將影像分割參數設定為圖 7-40(a)。

分割獲得影像物件後，選擇的物件特徵與花蓮光復實驗區相同，不同類別分類仍以波段值為主要依據，因此選定了影像各波段的平均值、標準差，以及整體向的亮度 (brightness) 和 Max diff.，另外也將影像物件的形狀因子加入考量，因此加入 Border index、Compactness、Density、Roundness、Shape index 等形狀指標，選定之特徵如表 7-29。透過 eCognition 軟體進行影像分割並計算特徵後，則利用內建的最鄰近分類法進行影像分類。



(a)尺度因子：600，形狀異質性指標：0.1，緊密度異質性指標：0.7



(b)尺度因子：1000，形狀異質性指標：0.1，緊密度異質性指標：0.7

圖 7-40、影像分割參數設定

表 7-29、選定之物件分類特徵

特徵性質	波段值	空間
特徵	● 平均值：特徵波段 1 至 15 平均值 ● 標準差：特徵波段 1 至 15 標準差 ● 其他：Brightness、Max. diff	● 形狀：Border index、Compactness、Density、Roundness、Shape index

二、物件導向分類法之分類成果

將物件導向分類之成果，以檢核資料進行分類結果評估，則整體分類準確度為 85.23%，Kappa 指標為 0.8228，表 7-30 為各類別的分類成果，從生產者準確度中，最差的類別為檜木的 80.67%，而杉木、柳杉及台灣杉的生產者準確度都高於 90%，在使用者準確度的評估中，則是杉木的分類結果最差，為 64.56%，則表示杉木的誤判情形較顯著，而檜木與台灣杉的使用者準確度比其他類別來的佳，分別為 100%和 98.6%，即誤判情形不顯著。圖 7-41 則是利用物件導向分類法的各類別分類圖，圖中可以看到檜木分類的成果與原始的真資料的分布情形較為相符，其他類別的分布與地真資料的分布位置也有些吻合，但有被過度分類之情形，例如影像中大部分的影像物件都被分類為選定的類別，其中又以被分為杉木的類別居多，以及分割得到的影像物件也有一部分受到地形效應之影響，而並未吻合選定的類別區域，後續如何設定合適的分割參數、以及分類特徵，也需要在後續調整的部分。

表 7-30、物件導向分類法類別成果

		OA	Kappa 指標
		85.23%	0.8228
類別	生產者準確度(%)	使用者準確度(%)	
1 檜木(紅檜、扁柏)	80.67	100.00	
2 臺灣肖楠	86.20	86.17	
3 杉木(巒大杉、杉木等)	90.47	64.56	
4 柳杉	97.90	80.60	
5 台灣杉	93.93	98.60	




圖 7-41、出雲山苗圃實驗區物件導向分類法分類類別圖

7.3.4、以機器學習為基礎之分類法於出雲山苗圃影像分析

出雲山苗圃實驗區影像利用機器學習方法進行分類，則採用了支持向量機進行影像分析，分析工具同樣利用 Python 程式中的機器學習 scikit-learn 模組搭配高光譜影像分析的 spectral 模組，以自行撰寫程式的方式操作實驗；方法主要是利用支持向量機搭配不同核函數及參數設定，以逐像元的方式進行影像分類，採用的核函數包含：

1. 線性核函數 (linear kernel)；
2. 多項式核函數 (polynomial kernel)：採用的項次為 2 至 5；
3. 輻狀基底函數 (radial basis function, RBF)：採用的 γ 為 1、5、10；
4. 採用近似係數的小波核函數 (wavelet kernel)：利用 2 次離散小波轉換，取近似係數的核函數，採用的小波基底函數為 haar、Daubechies 2、Daubechies 3。

出雲山苗圃實驗區高光譜影像利用不同支持向量機分類成果如表 7-31 所示。首先採用最簡單的線性核函數時，分類成果最好，分類準確度為 84.35%、Kappa 指標為 0.7543，表 7-32 則是利用線性核函數時各類別得分類成果，與特徵分類法的成果相似，杉木的分類結果是 5 種類別中最差，生產者與使用者準確度分別為 68.67%、67.36%，其次分類較差的類別分別是臺灣肖楠和台灣杉，柳杉的分類成果則較前述的類別佳，分類成果最佳的類別則是檜木，生產者準確度為 93.50%、使用者準確度為 91.19%。

表 7-31 中採用多項式核函數的分類成果，當項次為 2 時分類成果比其他高項次來得佳，但沒有隨著項次增加而成果變得更差的趨勢；採用輻狀基底函數時，當 γ 參數設定為 1 時的分類成果比其他 γ 參數值來得佳，在本實驗影像中可能較不適合使用太小的 γ 參數，而較大的 γ 參數會使得類別的決策邊界過於接近類別支持向量的分布範圍，使得資料無法被正確分類。而採用小波核函數的分類成果，則不像花蓮光復實驗區的成果與線性核函數相近，同時隨著小波基底函數消失動量的不同，當消失動量越大，採用基底函數為 Daubechies 3 的分類準確度為 78.12%，明顯優於其他小波基底函數。

表 7-31、不同核函數之分類成果

SVM 核函數 (參數)	Overall Accuracy(%)	Kappa 指標
線性核函數	84.35	0.7543
多項式核函數(項次=2)	74.12	0.6765
多項式核函數(項次=3)	59.37	0.4922
多項式核函數(項次=4)	64.95	0.5619
多項式核函數(項次=5)	55.79	0.4473
輻狀基底函數核函數(γ =default)	56.18	0.4522
輻狀基底函數核函數(γ =1)	79.21	0.7402
輻狀基底函數核函數(γ =5)	75.75	0.6968
輻狀基底函數核函數(γ =10)	38.04	0.2255
小波核函數(採用近似係數、haar)	24.32	0.0540
小波核函數(採用近似係數、db2)	77.81	0.7226
小波核函數(採用近似係數、db3)	78.12	0.7265

表 7-32、SVM 線性核函數類別成果

核函數		OA	Kappa 指標
linear		84.35%	0.7543
類別		生產者準確度 (%)	使用者準確度 (%)
1	檜木(紅檜、扁柏)	93.50%	91.19%
2	臺灣肖楠	78.70%	81.25%
3	杉木(巒大杉、杉木等)	68.67%	67.36%
4	柳杉	87.00%	84.09%
5	台灣杉	73.87%	77.59%

7.3.5、花蓮光復與出雲山苗圃實驗樣區機載高光譜影像分析討論

根據 7.2、及 7.3、節花蓮光復和出雲山苗圃實驗區機載高光譜影像分析結果，整體的實驗成果都比衛載高光譜影像的分類成果佳，實驗中將分類的目標設定樹種而非森林林型，則更可以透過高光譜資料光譜曲線的特性對目標的物種進行分析。在採用不同自動分類方法時，特徵分類法中 PCT、DAFE 和 DBFE 的分類結果比 2 種小波轉換特徵萃取法都來得佳，花蓮光復實驗區利用特徵分類法可以達到 85% 的分類準確度，而出雲山苗圃實驗區的成果則略差一些，可達到接近 80% 的分類準確度；在分類後的類別圖中，對於選定的類別均可以正確分類，而影像中仍有受到椒鹽效應和航帶間影像鑲嵌之影響，其中出雲山苗圃實驗區因地形變化較大，分類成果也受到地形效應之影響。利用物件導向的影像分析方法，可以避免椒鹽效應之影像，而在 2 組實驗區中都可以達到 75%~85% 的分類準確度，但是在分類的成果圖中，仍有部分影像物件分割仍需更精進、或需改善過度分類之情形。最後採用機器學習方法於高光譜影像分類時，可達到比前述方法更好的分類成果，在花蓮光復實驗區可達到約 90% 或是優於 90% 的分類準確度，部分物種的生產者或使用者準確度更可以接近 100%；出雲山苗圃實驗區雖然無法超過 90% 的整體分類準確度，但對於部分類別亦可以準確分類。

檢視本研究中整體的機載高光譜影像分類結果，與文獻回顧裡相關森林資源調查的研究相比，雖然本研究中部分方法或是物種的分類成果仍有部分提升的空間，但本研究中所採用的實驗區域範圍較大，亦或是選用的分類目標為樹種，且類別數目較過去相關文獻來得多，顯示在本研究中所採用高光譜影像分析方法，在 2 組實驗區影像分析中有相當之可靠性，可將相關經驗用於森林資源調查之應用。

7.4、高光譜影像應用於森林資源調查之討論評估

本研究利用花蓮光復大農大富平地森林園區以及出雲山苗圃 2 個實驗樣區，針對林地土地覆蓋型進行實驗與測試，透過蒐集或取像得到的衛載、機載實驗樣區高光譜影像資料，配合 3 種高光譜影像分類的演算法，即特徵分類法、結合空間資訊的特徵分類法，與以機器學習為基礎的分類法，則根據本研究成果，利用高光譜影像於森林資源調查時，需考量與探討以下之因素：

一、林地類別之選定

研究中利用衛載高光譜影像分析時，是將森林資源調查成果的「差異形態名稱」為類別選取的基準，將類別區分為竹林、針葉林樹型、闊葉樹林型、竹針闊混淆林等，分類的結果較不理想，是由於森林林型為分類類別時，同一個森林林型可能包含了不同樹種，如：針葉樹林型中又可區分成檜木、臺灣肖楠等樹種，不同樹種的光譜曲線特性會有所差異，將不同樹種混合成單一類別進行分析，則失去利用高光譜影像像元光譜曲線的優點進行資料分析。因此在機載高光譜影像分析時，將分類的類別鎖定為單一樹種，例如在花蓮光復實驗樣區的分析成果中，以不同的樹種進行分析，則可以準確分類出不同樹種的分布情形，其中像是檸檬香茅、沉香、光臘樹等類別，都可以有良好的分類結果，其生產者準確度與使用者準確度均較高。

因此利用高光譜影像資料不同物種對應的光譜曲線特性及吸收帶的變化，將分析的對象鎖定為森林樹種，而非森林林型，便有利於森林樹種的分析，獲得不同森林樹種分布後，可進一步進行森林林型或土地覆蓋型之分析。同時若有不同植物物種多時期、不同區域、不同生長狀態的高光譜影像或地面光譜資料，更可透過建立光譜資料庫的概念，輔助於森林資源調查之分析。

二、不同自動分類法的特性

研究中利用不同的自動分類演算法進行高光譜影像之分類，不同方法均有其優劣；首先特徵分類法若於特徵萃取時，將訓練資料亦加入演算中，則可以在影像分類時，獲得良好的分類成果，而因為是採用逐像元的分析方式，分類後的影像成果容易造成椒鹽現象的產生，同時當同一類別不同像元的光譜曲線差異變化較大時，或與其他類別分布重疊較大，容易造成分類成果不佳。以物件導向分類法的分析方式，則可以避免椒鹽效應的產生，並且除了影像光譜值外，還可以將物件的空間資訊，如形狀、紋理等加入分析，整合了光譜與空間的特徵，便有助於影像的分類分析，然而如何選定合適的影像分割參數、是否進行物件的再分割或合併，以及如何選定有效的物件特徵也需要反覆的探討與嘗試，才能獲取較佳的分析成果。

最後是採用機器學習演算法的高光譜影像分析方法，透過支持向量機之核方法或是近年經常被使用的深度學習演算法，較可以突破類別分布變化大、或類別間分布差異較小時，以統計分析方法之限制，利用訓練資料做資料空間的轉換，或是以反覆訓練的步驟，都可以讓高光譜影像的分類成果有所提升，而機器學習相關的演算法通常需要耗費較多的計算資源，若相關軟硬體設備可以有所提升，將可以減少限制。

因此本研究所提出之自動分類法要套用於高光譜影像在森林資源調查時，在具有完備且充足的地真資料時，採用傳統的特徵分類方法便可以獲取良好的地物類別或樹種分析成果，其中 DAFE 及 DBFE 於特徵萃取時引入訓練資料，較其他方法可以獲得更佳的成果。當有完備的軟硬體設備，例如加入 GPU 提升計算效能，則可以採用機器學習的分析方法，更可以減少訓練資料或是類別資料分布之限制，獲取更好的森林樹種分類成果，有助於森林資源調查。

三、實際影像之條件限制

本研究中利用機載高光譜儀，針對研究樣區實際進行取像，獲得良好的光譜解析度，以及較佳的地面解析度影像，本研究在分析時面臨幾個限

制條件，首先，因地面解析度為 1 公尺，則單一類別區塊中的所有像元可能會同時有目標物種的像元，以及背景像元(如樹叢之間裸露之地面或草皮)，但是以區塊的方式選擇樣本資料，會同時將背景像元一同劃分到類別樣本中，因此如何避免背景像元，而選取實際的目標類別像元作為訓練資料，是需要注意的步驟。

其次，單一個實驗樣區影像通常需要多條航帶取像後，經過前處理校正並鑲嵌成實驗區影像，但航帶之間鑲嵌區域的影像，是利用不同航帶資料重新取樣而成，不同航帶的取像條件如光線等，通常會有所不同，反而造成影像鑲嵌區域不易分析之情形。因此以單條航帶影像或是鑲嵌後影像進行高光譜影像分析，或是於影像前處理之影像鑲嵌時加入光線角度之考量，如採用雙向反射分布函數(BRDF)，獲取品質更佳的鑲嵌影像進行分析。

最後是在出雲山苗圃實驗樣區可以明顯看到地形效應影響高光譜影像分析的情形，因為出雲山苗圃實驗區的地形起伏相當明顯，加上光線入射角度，會使得單一類別不同像元之間光譜曲線亮度(即輻射強度值)的差異，甚至為陰影之影響，造成單一類別的光譜資料分布變異加大，也對於高光譜影像分類的成果有所影響。相較於出雲山苗圃實驗區的地形起伏變化，花蓮光復實驗區地形較為平坦，因此取像獲得的高光譜影像沒有受到地形效應的干擾，對於不同樹種的分類分析，便可以更精確地完成。後續實際操作時，受到地形效應或陰影影響之影像區域，若單一像元本身的輻射值仍具有一定之強度反應，則會保持所屬物種的光譜曲線特性，於資料分析時，針對陰影像元進一步分析處理，也會對於整體的森林資源調查有所幫助。

捌、評估適合農航所定翼型無人機(Sky Arrow 55)搭載之高光譜感測器

8.1、蒐集各型無人載具高光譜感測器相關資訊

本研究須評估適合農航所定翼型無人機(Sky Arrow 55)搭載之高光譜感測器，本團隊已整理國內外常見適用於無人機之高光譜儀如表 8-1 及圖 8-1 所示，以下依據不同的儀器特性及規格進行說明：



BaySpec OCI-UAV-1000



Brandywine Photonics
CHAI S-640



Firefleye S185 SE



Headwall Nano-Hyperspec



HySpex VNIR camera



MosaicMill HSC-2



Corning microHSI 425



Senop HSC-2



Photonfocus
MV1-D2048x1088-HS05-96-G2



Resonon Pika NIR-640



Surface Optics Corp.
SOC710-GX



MQ022HG-IM-LS100-NIR

圖 8-1、各式無人機高光譜儀器

表 8-1、常見 UAV 高光譜感測器

製造公司	儀器名稱	光譜範圍 (nm)	波段數	光譜 解析度 (nm)	成像 模式	取像率 (fps)	空間 解析度 (pixel)	感測元件	儲存 空間	電力 (W)	操作 溫度 (°C)	介面	尺寸(mm)	重量 (kg)
BaySpec	OCI-UAV-1000	600-1000	100	<5	P	120	2048	CMOS	500G	<4	-20~+60		100×75×30	0.45
	OCI-UAV-2000	600-1000	20-25	12-15	F	120	400×200	CMOS	500G	<4	-20~+60		100×75×30	0.45
Brandywine Photonics	CHAI S-640	825-2125	260	5	P	120	640×512	Ex-InGaAs	1TB	200	-30~+40		152×127×76	5
	CHAI V-640	350-1080 400-1000	256	2.5 5 10	P	1000	640×512	CMOS	400G	20	-20~+50		125×101×75	0.48
Corning (NovaSol)	microHSI 410 Vis- NIR	400-1000	120 240 480	5 2.5 1.25	P		320 640 1280				0~+45		152×64×61	0.45
	microHSI 425	400-2500	512	4.1	P	120	640	HgCdTe		30	sterling- cooled		105×71×37	3.5
Cubert GmbH	Firefleye S185 SE	450-950	125	4	F	15	1000×1000	Si CCD		8	0~+40			0.49
	Firefleye Q285 QE	450-950	125	4	F	20	1000×1000	Si CCD		8	-10~+50			3
	Firefleye S496 XL	370-870	125	4	F	15	1050×1050	Si CCD		8	-10~+50			1.2
Headwall Photonics Inc.	Nano-Hyperspec	400-1000	270	6	P	350	640	CMOS	480G	13	0~50		120×76×76	0.5
	Micro-Hyperspec VNIR A-Series	400-1000	324	1.9	P	90	1004	Si CCD		6.6	TE-cooled		110×93×50	0.7
	Micro-Hyperspec VNIR E-Series	400-1000	369	1.63	P	250	1600	sCMOS		13.2	TE-cooled		110×93×50	1.1
	Micro-Hyperspec NIR 640	900-1700	134	6	P	120	640	InGaAs		2.5	TE-cooled		110×93×50	0.9
	Micro-Hyperspec NIR 320	900-1700	67	12	P	346	320	InGaAs		4	TE-cooled		110×93×50	0.9
	Micro-Hyperspec Extended NIR 640	600-1700	267	4.1	P	120	640	InGaAs		4	Stirling- cooled		110×93×50	0.9
	Micro-Hyperspec SWIR 384	900-2500	166	9.6	P	450	384	MCT		14.4	Stirling- cooled		110×93×50	2.0
	Micro-Hyperspec SWIR 640	900-2500	267	6	P	>200	640	MCT		14			110×93×50	1.6

製造公司	儀器名稱	光譜範圍 (nm)	波段數	光譜 解析度 (nm)	成像 模式	取像率 (fps)	空間 解析度 (pixel)	感測元件	儲存 空間	電力 (W)	操作 溫度 (°C)	介面	尺寸(mm)	重量 (kg)
HySpex	VNIR-1024	400-1000	108	5.4	P	690	1024			~6	FPA cooling		305×99×150	4.2
	VNIR-1800	400-1000	186	3.26	P	260	1800			~30	FPA cooling		390×99×150	5.0
	VNIR-3000N	400-1000	300	2.0	P	117	3000			30			390×99×150	5.0
	HySpec SWIR-384	1000-2500	288	5.45	P	400	384			~30	FPA cooling		380×120×175	5.7
	Mjolnir V-1240	400-1000	200	3.0	P	285	1240			50			250×175×170	4.0
	Mjolnir S-620	970-2500	300	5.1	P	100	620			50			250×175×170	4.5
	Mjolnir VS-620	400-2500	490	3.0 5.1	P	100	620			50			374×200×178	6
MosaicMill	HSC-2	500-900 400-700 450-800 550-950	1000	5-10	F	74 149	1024×1024	CMOS	1TB	12	+5~+40	GigE USB 2.0 Mini- Display	200×131×97	0.986
NovaSol (Corning)	vis-NIR microHSI	400-800 400-1000 380-880	120 180 150	3.3	P	86 66 76	1360							0.45
	Alpha-vis micro HSI	400-800 350-1000	40 60	10	P	1280 800	2560							2.1
	SWIR 640 microHSI	850-1700 600-1700	170 200	5	P	640	320 220							3.5
	Alpha-SWIR microHSI	900-1700	160	5	P	640	640							1.2
	Extra-SWIR microHSI	864-2400	256	6	P	200	320							2.6
Opto- Knowledge	HyperScan VNIR Micro (Low Noise)	400-1000	399	1.5	P		2560×2160	sCMOS		<30	TE-cooled	USB Camera Link	203×127×113	2.5
	HyperScan VNIR Micro (High Dynamic Range)	400-1000	337	1.5	P		2080×2080	CMOSr		<20	TE-cooled	USB GigE	178×127×113	2.0
PhotonFocus	MV1-D2048x1088- HS05-96-G2	470-900	150	10-12	P	42	2048×1088	CMOS		5.1	0~+50	RJ-45	55×55×52	0.265

製造公司	儀器名稱	光譜範圍 (nm)	波段數	光譜 解析度 (nm)	成像 模式	取像率 (fps)	空間 解析度 (pixel)	感測元件	儲存 空間	電力 (W)	操作 溫度 (°C)	介面	尺寸(mm)	重量 (kg)
Quest Innovations	Hyperea 660 C1	400-1000	660	1.55	P	50	1280×1024	sCMOS		8	-20~+50	Camera link	60×60×260	1.25
	Hyperea 660 C2, C3	400-1000	660	1.55	P	50	1280×1024	sCMOS		8	-20~+50	Camera link	80×100×300	1.65
	Hyperea 128 C1	400-1000	128	8	P	50	640×512	sCMOS		8	-20~+50	Camera link	60×60×260	1.25
	Hyperea 128 C2. C3	400-1000	128	8	P	50	640×512	sCMOS		8	-20~+50	Camera link	80×100×300	1.65
Resonon	Pika XC2	400-1000	447	1.3	P	165	1600			3.4	+5~+40	USB 3.0	101×275×74	2.2
	Pika L	400-1000	281	2.1	P	249	900			3.4	+5~+40	USB 3.0	100×125×53	0.6
	Pika NIR 320	900-1700	328	2.5	P	249	640				+5~+40	GigE	110×296×89	2.7
	Pika NIR 640	900-1700	164	4.9	P	520	320				+5~+40	GigE	110×296×89	2.7
	Pika NUV	350-800	196	2.3	P	165	1600			3.4	+5~+40	USB 3.0	100×264×73	2.1
SENOP	HSC-2	500-900 400-700 450-800 550-1000	up to 1000	5-15	F	74 149	1024×1024	CMOS	1TB		+5~+40	GigE Mini- Display	199×131×97	0.99
SPECIM	SPECIM FX10	400-1000	224	5.5	P	330	1024	CMOS		4	+5~+40	GigE Camera Link	150×85×71	1.26
	SPECIM FX17	900-1700	224	8	P	670	640	InGaAs		24	+5~+40	GigE Camera Link	150×85×75	1.56
Surface Optics	SOC710-GX	400-1000	120	4.2	P	90	640			10	0~+50	GigE	103×200	1.25
XIMEA	MQ022HG-IM- LS100-NIR	600-975	100	4	P	1360	2048×8	CMOS		1.6	<50	USB 3.1	26×26×31	0.032
	MQ022HG-IM- LS150-VISNIR	470-900	150	3	P	850	2048×5	CMOS		1.6	<50	USB 3.1	26×26×31	0.032

一、成像模式：

圖 8-2 為遙測感測器常見的成像模式，其中 A 為單點掃描(point scanning) 模式、B 為線掃描 (line scanning) 模式，或稱推帚式 (pushbroom) 掃描、C 為面掃描 (plane scanning) 模式、D 為單照 (single shot) 模式，或稱快照 (snapshot) 模式，其主要以框幅方式 (frame-based) 成像。從表 8-1 可以發現，大部分可搭載於無人機之高光譜儀主要採推帚式成像 (P)，如 Headwall、HySpec、Resonon、及 SPECIM 等系列高光譜儀；少部分則採框幅式成像(F)，如 Cubert 及 SENOP 高光譜儀。通常推帚式的感測器可獲得較佳的空間解析度及較多的波段數，如 BaySpec 的 OCI-UAV-1000 (推帚式) 即具有比 OCI-UAV-2000 (框幅式) 較高的空間解析度及波段數。若欲提升框幅式感測器之空間解析度或波段數，則必須採其他的快照方式，如 SENOP HSC-2 採波段分別成像，其每一框幅影像可獲得 1024×1024 的解析度。此外，不同的成像方式必須採不同的幾何改正方法，此處不再贅述影像幾何改正方法。




圖 8-2、不同的高光譜成像模式(Adão, et al., 2017)

二、感測器感光元件：

與一般相機的感光元件相類似，高光譜感測器的感光元件可分成兩種類型，即感光耦合元件 (Charge Coupled Device, CCD) 及互補性氧化金屬半導體 (Complementary Metal-Oxide Semiconductor, CMOS)，不同的感光元件類型將造成感光度、解析度、雜訊、耗電量、及成本上的差別。

從表 8-1 可以發現大部分的無人機高光譜儀主要以 CMOS 為主。

此外，不同光譜波長範圍的感光材質亦有所差別，如圖 8-3 所示。通常可見光 (VIS) 及近紅外光 (NIR) 的感光材質以矽 (Silicon, Si) 為主；近紅外線至短波紅外線 (SWIR) 則以砷化鎵銦 (InGaAs) 為主，波長範圍約在 900 nm 至 2600 nm 之間；若要感測波長更長的輻射則必須採用碲鎘汞 (HgCdTe)，或稱 MCT (Mercury Cadmium Tellurium)。這是為何同一廠牌的光譜儀在 VIS-NIR 及 SWIR 光譜範圍會有不同規格的感測器設計。表 8-1 中有少數可以掃描 400 至 2500 nm 波譜範圍的高光譜儀係整合了兩種不同的感光元件，因此通常會有比較大尺寸及重量。




圖 8-3、不同的高光譜感測器感光元件(Adão, et al., 2017)

三、波段數及光譜解析度：

從表 8-1 可以發現大部分無人機高光譜儀之波段數介於 100 至 300 之間，光譜解析度則介於 2 至 10 nm 之間，此可滿足許多高光譜影像應用之需求。

四、控制介面：

欲將高光譜感測器搭載於無人機上，兩者之間必須具有能互相溝通的介面以進行無人機操作及資料傳輸等工作。目前大部分的無人機高光譜儀皆有提供符合國際傳輸標準的介面，如 GigE (Gigabit Ethernet)、USB 或

是 Camera Link 等，因此欲進行無人機與高光譜儀器之間的整合基本上不會有太大問題。

五、定向定位系統的整合

定向定位系統 (Position and Orientation System, POS) 整合了 GPS 及 IMU 等儀器，其同時提供感測器成像時的位置及姿態，有助於高光譜影像的幾何校正，尤其是推帚式影像更需要定向定位系統資料的輔助才能精確地進行幾何改正，因此定向定位系統的整合成為無人機搭載高光譜儀時必須考量的一項重要因素。現已有許多無人機高光譜儀的製造商提供了無人機、定向定位系統、以及高光譜儀的整合方案，如圖 8-4 為 Headwall 公司整合自家的 Nano-Hyperspec、GPS/IMU 系統、以及儲存設備的整合航空套件 (airborne package)，一般而言同一廠商的儀器理應有較佳的整合效果。



圖 8-4、Headwall 高光譜儀航空整合套件 (Headwall, 2016)

六、溫度控制：

高光譜儀成像時，通常會產生極高的操作溫度，因此大部分儀器必須限制操作溫度的範圍，目前有許多較新的高光譜儀具有降溫（cooling）的功能，能增加成像的品質及穩定性。

8.2、評估適合農航所定翼型無人機(Sky Arrow 55)搭載之高光譜感測器

本項工作將就定翼型無人機 Sky Arrow 55 之性能規格及本研究之成果，評估適合之高光譜感測器，提供該機後續擴充參考。Sky Arrow 55 屬於汽油引擎推動之中型定翼型無人機，同時搭載高精度戰術級定位定向系統(POS)，具有長滯空、高航程、高抗風、及高精度的特性。本團隊已於 108 年 7 月 9 日前往 Sky Arrow 55 製造商經緯航太科技股份有限公司進行訪談，了解該無人機之基本規格，以及安裝高光譜儀時須進行評估之項目，以下將針對 Sky Arrow 55 機構安裝及高光譜儀器運作需求兩方面，說明相關評估結果，並提出後續進行酬載擴充高光譜儀器時的參考建議。

8.2.1、Sky Arrow 55 機構安裝及儀器運作需求分析

以下分別針對 Sky Arrow 55 的機構需求，及酬載高光譜之運作需求進行說明：

一、機構安裝方面

1. 酬載尺寸要求：

各機型皆有其機艙尺寸限制，選擇時需考量尺寸是否符合如圖 8-5 所示 Sky Arrow 55 酬載艙尺寸限制。無論是量產型酬載艙(220 × 200 × 210 mm)或客製型(280 × 200 × 210 mm)，從表 8-1 中可以發現除了 HySpex 公司的系列產品外，其他廠牌高光譜儀器皆可符合 Sky Arrow 55 酬載艙尺寸限制的要求。

2. 重量要求：

Sky Arrow 55 的酬載重量（包含主儀器、電池、支架及線束等）需低於允許最大酬載重量，而 Sky Arrow 55 最大載重為 6kg。表 8-1

所列高光譜儀重量最重的為 HySpex 的 Mjionlnir VS-620，其重量為 6 公斤。也就是說，若無需再附掛其他元件，表 8-1 所列儀器皆可滿足 Sky Arrow 55 的酬載重量需求。

3. 抗震動要求：

定翼機飛行中會有機體震動，一般可搭配減震墊等機構來做防震，但如為實驗室超精密儀器可能不適合安裝於定翼機。表 8-1 中所列高光譜儀大都可搭載於具有穩定雲台的旋翼機，因此對於儀器防震或耐震程度大都沒有明確描述，然而進行資料蒐集中亦發現有些將高光譜儀搭載於中、大型定翼機中的範例，如圖 8-6 所示為 Opto-Knowledge 公司以客製化的方式將 HyperScan VNIR Micro 高光譜儀搭載於 NASA Sierra UAV 之情形；其他如 Headwall 公司的 Nano-Hyperspec 高光譜儀亦可搭載於定翼型 UAV 上。經與 Sky Arrow 55 製造商經緯航太公司進行討論，若透過不同光譜儀客製化的方式，再搭配減震墊等機構應可達到防震的目的。




圖 8-5、定翼型無人機 Sky Arrow 55 酬載艙示意圖



圖 8-6、NASA Sierra UAV 搭載 HyperScan VNIR Micro 示意圖

二、高光譜儀器運作之需求

1. 散熱問題：

高光譜儀器運轉時通常會產生高熱，因此安裝於無人機上時需解決散熱的問題。從表 8-1 中可發現許多光譜儀儀器本身的感測器即具有降溫的機制，如 HeadWall 公司的 MicroHyperspec 系列及 Opto-Knowledge 公司的 HyperScan VNIR Micro 皆採熱電冷卻技術（thermoelectrically cooled, TE-cooled），可有效降低感測器的溫度。另外如 HySpex 公司部份的產品則採焦平面陣列冷卻技術（focal plane array cooling, FPA cooling），亦具有冷卻感測器的效果。

2. 儀器運轉之環境溫度：

定翼機一般可飛行高度較高，可達海拔 1000 公尺以上，且飛行速度快，故機艙內部溫度會較低，有可能在 10°C 以下，因此需確認欲酬載之高光譜儀器之可操作環境溫度是否合適。從表 8-1 中可發現各式光譜儀的環境溫度最低為攝氏零下 20 度至攝氏 5 度，最高

則為攝氏 50 度至 60 度之間，應可容忍 1000 公尺航高時環境溫度的變化。

3. 無線電波：

無人機本身存在通訊用之電波，其頻率一般為 2.4GHz、900mHz、及 5GHz 等，需確認高光譜儀本身是否會被無線電波等訊號所干擾。因為大部分高光譜儀皆採用有線的方式（如 GigE 網路或 USB 介面）進行操作，並無使用無線電波進行操作或資料傳輸，因此應不會對無人機本身通訊用之電波產生干擾。

4. 高光譜作業前校正問題：

高光譜儀如每次作業前須進行輻射校正（如拍攝地面校正色板），因此需確認不同儀器的校正程序。如高光譜儀器已安裝於機艙內，航拍前可能需取出儀器進行校正後再裝回機艙，此時必須考量儀器拆裝之方便性。由於不同高光譜儀器各有其拆裝方式，此部分尚無法於此處一一確認。

5. 供電規格：

高光譜有其供電的基本需求，從表 8-1 中可發現除了 Brandywine Photonics 公司的 CHAIS-640 短波紅外高光譜儀需要 200 瓦特的電力之外，其他儀器皆小於 50 瓦特。由於 Sky Arrow 55 酬載高光譜儀時，係另以獨立的方式供應電源（如圖 8-5 酬載艙中所標示的電池盒），因此尚需根據所需電力設計電池組，此時即必須考量電池重量的影響。經與經緯公司討論確認，若高光譜儀主體小於 3 公斤，且用電量不大於 50 瓦特時，總重量還在 Sky Arrow 55 的承載能力內。

6. 介面規格及通訊協定：

如非採用原廠已整合好定位定向系統（POS），而是需整合 Sky Arrow 55 之定向定位系統（POS），則需確認兩者間的介面是否可以連結及溝通，亦需確認相互通訊上是否可行。由於此部分涉及較詳細的電路及連結介面細節，大部分的儀器並無對外公開。本團隊

在蒐集各儀器規格時，曾詢問過部分原廠及國內代理商，大都表示此部分可透過客製化方式進行處理，並不會有太大的問題。另外許多無人機高光譜儀器製造商可提供無人機、定向定位系統、以及高光譜儀的系統整合方案，此時即無須考量無人機與高光譜儀之間的介接及通訊問題，惟必須額外再考量 POS 系統的重量、所占空間及所需電力。

8.2.2、Sky Arrow 55 搭載之高光譜感測器之評估建議

本小節根據 8.1、節所蒐集各型無人載具高光譜感測器之規格及 8.2 節各項目之評估結果，針對貴所可能的應用需求及 Sky Arrow 55 的限制要求提出以下建議：

1. 光譜範圍需求：從表 8-1 中可以發現各廠牌高光譜儀器的光譜感測範圍大致區分為兩個區段，第一個區段涵蓋可見光及近紅外線區域（以 VNIR 表示），第二個區域則涵蓋短波紅外光範圍（以 SWIR 表示），若從森林應用的角度來看，VNIR 可以呈現植物葉綠素的變化，SWIR 的光譜變化則主要與植物含水量有關，因兩種波段範圍的儀器價格差距頗大，未來可依據貴所的實際應用需求選擇合適光譜感測範圍的儀器。
2. 影像解析度需求：高光譜儀可蒐集豐富的地物光譜資訊，若能搭配空間資訊將可提升地物分析或分類的效益，表 8-1 中各類儀器依成像模式的差異而具有不同的空間解析度，一般推帚式的感測器可獲得較佳的空間解析度。從森林應用的角度來看，較高空間解析度的影像可獲取單棵樹種的位置、樹冠範圍及大小等資訊，對於貴所未來的應用應有所助益。
3. Sky Arrow 55 的限制要求：如前所述，表 8-1 中所列大部分的高光譜儀器大都可滿足 Sky Arrow 55 的酬載艙尺寸限制及載重限制。若考量包含 POS 系統及供電的整合方案，可省去自行系統整合及介接的工作，也會有比較好的整合效果，但將會額外占用酬載艙的空間及可承載重量。本團隊建議可參考如圖 8-6 所示 NASA Sierra UAV

搭載 HyperScan VNIR Micro 高光譜儀的案例，未來可與高光譜廠商共同討論後，以客製化的方式將整合後具有 POS 系統的高光譜儀器酬載於 Sky Arrow 55 上。

玖、成果交付

本案全部工作項目需於 108 年 12 月 16 日前完成，成果分為三期繳交，各期應交付成果項目(含書面及電子檔)及繳交期限如表 9-1 所示。

一、第 1 期

自決標次日起 20 日曆天內(即 108 年 4 月 18 日前)，繳交此工作計畫書一式 12 份及電子檔 1 份，說明本計畫工作項目執行內容、程序與時程、組織與權責、人力配置、工作協調等規劃內容。貴所據以召開期初審查會議，並由本團隊簡報及說明。經會中審核通過後，將於期初會議審查通過次日起 10 日內，繳交修正後計畫書電子檔。

二、第 2 期

於 108 年 7 月 15 日前繳交期中報告書一式 12 份及電子檔 1 份，經貴所據以召開期中審查會議，由本團隊簡報及說明。經會議審核通過後，本團隊將於期中會議審查通過次日起 10 日內繳交修正後之期中報告書電子檔。

三、第 3 期：

1. 期末報告書：於 108 年 11 月 15 日前繳交期末報告書一式 12 份及電子檔 1 份。由貴所據以召開期末審查會議，並由本團隊簡報及說明。
2. 成果報告書初稿：經期末審查會議通過後，於會議次日起 10 日內繳交修正後之成果報告書初稿電子檔送貴所審核同意，如未依期末審查意見修改，應限期再修正。
3. 教育訓練：預計於 108 年 12 月 5 日辦理 1 場至少 4 小時的教育訓練。
4. 成果交付：成果報告書初稿經貴所審核同意，於 108 年 12 月 16 日前繳交成果。
5. 成果項目包括：

- (1) 成果報告書：一式 12 份，報告中照片、影像或需以彩色方能辨識者，以彩色列印。
- (2) 外接式儲存裝置 1 份(USB3.0，容量 2TB 以上)，包含下列內容：
 - (a) 成果報告書電子檔(以 Microsoft Word(docx)及 PDF 檔儲存)。
 - (b) 簡報檔：各期會議及工作會議之簡報(PowerPoint 檔)。
 - (c) 本案試驗相關影像檔案及其清單。

表 9-1、交付成果及繳交日期時程表

階段	項次	成果繳交項目	規格及數量	成果繳交日期
第 1 期	1	期初工作計畫書	書面資料 12 份 電子檔 1 份	108 年 4 月 18 日
	2	修正後期初工作計畫書	電子檔 1 份	108 年 5 月 13 日
第 2 期	1	期中報告書	書面資料 12 份 電子檔 1 份	108 年 7 月 15 日
	2	修正後期中報告書	電子檔 1 份	108 年 8 月 26 日
第 3 期	1	期末報告書	書面資料 12 份 電子檔 1 份	108 年 11 月 15 日
	2	修正後成果報告書初稿	電子檔 1 份	期末會議審查通過次日起 10 日內
	3	教育訓練	1 場至少 4 小時	108 年 12 月 5 日辦理
	4	成果報告書	書面資料 12 份	108 年 12 月 16 日前
	6	外接式儲存裝置，內含 A. 成果報告書電子檔(以 Microsoft Word(docx)及 PDF 檔儲存)。 B. 簡報檔：各期會議及工作會議之簡報(PowerPoint 檔)。 C. 本案試驗相關影像檔案及其清單。	電子檔各 1 份	108 年 12 月 16 日前

參考文獻

1. Adão, T., J. Hruška, L. Pádua, J. Bessa, E. Peres, R. Morais, and J. J. Sousa, 2017. Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. *Remote Sensing* 2017, 9, 1110.
2. Aronoff, S., 2005. *Remote sensing for GIS Managers*, 1st edition, ESRI Press, New York Street, Redlands, California.
3. Baldeck, C. A., G. P. Asner, R. E. Martin, C.B. Anderson, D. E. Knapp, J. R. Kellner and S. J. Wright, 2015. Operational Tree Species Mapping in a Diverse Tropical Forest with Airborne Imaging Spectroscopy, *PLoS One*, 10 (7): e0118403.
4. Banki, M. H. and A. A. B. Shirazi, 2009. Using Wavelet Support Vector Machine for Classification for Hyperspectral Images, 2009 Second International Conference on Machine Vision, 28-30 December, Dubai, United Arab Emirates, pp. 154-157.
5. Bellman, R., 1961. *Adaptive Control Processes: A Guided Tour*: Princeton University Press.
6. Berger, C., 2014. From a Competition for Self-Driving Miniature Cars to a Standardized Experimental Platform: Concept, Models, Architecture and Evaluation. *Journal of Software Engineering for Robotics* 5, 63-79.
7. Camps-Valls, G. and L. Bruzzone, 2005. Kernel-Based Method for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 43(6): 1351-1362.
8. Cao, J., W. Leng, K. Liu, L. Liu, Z. He and Y. Zhu, 2018. Object-Based Mangrove Species Classification Using Unmanned Aerial Vehicle Hyperspectral Images and Digital Surface Models, *Remote Sensing* 2018, 10, 89.
9. Cho, M. A., A. K. Skidmore, and I. Sobhan, 2009. Mapping beech (*Fagus sylvatica* L.) forest structure with airborne hyperspectral imagery, *International Journal of Applied Earth Observation and Geoinformation*, 11(3): 201-211.
10. Cortes, C. and V. Vapnik, 1995. Support-vector Networks, *Machine-Learning*, 20:273-297.

11. Dalponte, M., L. Bruzzone and D. Gianelle, 2012. Tree Species Classification in the South Alps Based on the Fusion of Very High Geometrical Resolution Multispectral/ Hyperspectral Images and LiDAR Data, *Remote Sensing of Environment*, 123:258-270.
12. Demir, B. and S. Ertürk, 2008. Empirical Mode Decomposition Pre-Process for Higher Accuracy Hyperspectral Image Classification, 2008 International Geoscience and Remote Sensing Symposium, 6-11 July, Boston, Massachusetts (John B. Hynes Veterans Memorial Convention Center), pp.II-939 -941.
13. Dian, Y., Z. Li and Y. Pang, 2015. Spectral and Texture Features Combined for Forest Tree species Classification with Airborne Hyperspectral Imagery, *Journal of the Indian Society of Remote Sensing*, 43(1): 101-107.
14. Dian, Y., Z. Li, and Y. Pang, 2015. Spectral and Texture Features Combined for Forest Tree species Classification with Airborne Hyperspectral Imagery, *Journal of the Indian Society of Remote Sensing*, 43(1): 101-107.
15. Farabet, C., Couprie, C., Najman, L., LeCun, Y., 2013. Learning Hierarchical Features for Scene Labeling. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 35, 1915-1929.
16. Fukunaga, K., 1990. *Introduction to Statistical Pattern Recognition*, Second edition, San Diego: Academic Press, Inc.
17. Ganesh, B. P., S. Aravindan, S. Raja and A. Thirunavukkarasu, 2013. Hyperspectral Satellite Data (Hyperion) Preprocessing – a Case Study on Banded Magnetite Quartzite in Godumalai Hill, Salem, Tamil Nadu, India, *Arabian Journal of Geosciences*, 6 (9): 3249-3256.
18. George, R., H. Padalia and S.P.S. Kushwaha, 2014. Forest Tree Species Discrimination in Western Himalaya Using EO-1 Hyperion, *International Journal of Applied Earth Observation and Geoinformation*, 28:140-149.
19. Gholizadeh, A., J. Misurec, V. Kopackova, C. Mielke, and C. Rogass, 2016. Assessment of Red-Edge Position Extraction Techniques: A Case Study for Norway Spruce Forests Using HyMap and Simulated Sentinel-2 Data, *Forests*, 7(10): 226.
20. Goetz, A. F. H., G. Vane, J. E. Solomon, and B. N. Rock, 1985. *Imaging Spectrometry for Earth Remote Sensing*, Science, 228:1147-1153.
21. Gómez-Chova, L., J. Muñoz-Marí, V. Laparra, J. Malo-López and G. Camps-Vall, 2011. A Review of Kernel Methods in Remote Sensing Data Analysis,

- Augmented Vision and Reality Volume 3 Optical Remote Sensing Advance in Signal Processing and Exploitation Techniques (S. Prasad, L. M. Bruce and J. Chanussot, editors), Springer-Verlag, Berlin Heidelberg, Germany, pp. 171-206.
22. Gonzalez, R. C., and R. E. Woods, 2002. Digital Image Processing. Upper Saddle River, N.J.: Prentice Hall.
 23. Haralick, R. M., Shanmugam, K., & Dinstein, I. H., 1973. Textural Features for Image Classification. Systems, Man and Cybernetics, IEEE Transactions on, 3(6), 610-621.
 24. He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep Residual Learning for Image Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016). IEEE, Las Vegas, NV, USA, pp. 770-778.
 25. Headwall, 2016. Nano-Hyperspectral Airborne Package, Operation Manual. Available from https://cdn2.hubspot.net/hubfs/145999/Product%20Manuals%202018/Airborne_Operations.pdf?t=1540298336947
 26. Hsu, P.-H., 2007. Feature extraction of hyperspectral images using wavelet and matching pursuit, ISPRS Journal of Photogrammetry and Remote Sensing, 62(2):78-92.
 27. Hsu, P.-H., Y.-H. Tseng, and P. Gong, 2002. Dimension Reduction of Hyperspectral Images for Classification Applications, Geographic Information Sciences, 8(1):1-8.
 28. Jia, S., K. Wu, J. Zhu, and X. Jia, 2019. Spectral-Spatial Gaber Surface Feature Fusion Approach for Hyperspectral Imagery Classification, IEEE Transaction on Geoscience and Remote Sensing, 57(2):1142 – 1154.
 29. Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012. ImageNet classification with deep convolutional neural networks, in: Pereira, F., Burges, C.J.C., Bottou, L., Weinberger, K.Q. (Eds.), Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1. Curran Associates Inc., Lake Tahoe, Nevada, pp. 1097-1105.
 30. Kubat, M., 2015. An Introduction to Machine Learning. Springer, Cham.
 31. Landgrebe, D. A., 2003. Signal Theory Methods in Multi-spectral Remote Sensing. New Jersey: John Wiley & Sons.
 32. LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep Learning. Nature 521, 436-444.
 33. LeCun, Y., Boser, B.E., Denker, J.S., Henderson, D., Howard, R.E., Hubbard,

- W.E., Jackel, L.a.D., 1990. Handwritten Digit Recognition with a Back-Propagation Network, in: Touretzky, D.S. (Ed.), Neural Information Processing Systems 1998, Denver, CO, pp. 396-404.
34. Lee, C. and D. A. Landgrebe, 1993. Analyzing High-Dimensional Multispectral Data, IEEE Transactions on Geoscience and Remote Sensing, 31: 792-800.
35. Li, Y., Zhang, H., Xue, Z., Jiang, Y., Shen, Q., 2018. Deep Learning for Remote Sensing Image Classification: A Survey, Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 8(6): e1264.
36. Lim J., K.-M. Kim and R. Jin, 2019. Tree Species Classification Using Hyperion and Sentinel-2 Data with Machine Learning in South Korea and China, International Journal of Geo-Information, 8: 150.
37. Long, J., Shelhamer, E., Darrell, T., 2015. Fully convolutional networks for semantic segmentation, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2015). IEEE, Boston, MA, USA, pp. 3431-3440.
38. Mitchell, Tom M., 1997. Machine Learning. Mc Graw Hill, 414 pages.
39. Natural Resources Canada, 2019. <https://www.nrcan.gc.ca/forests/measuring-reporting/remote-sensing/13437>.
40. Noh, H., Hong, S., Han, B., 2015. Learning Deconvolution Network for Semantic Segmentation, 2015 IEEE International Conference on Computer Vision (ICCV 2015). IEEE, Santiago, Chile, pp. 1520-1528.
41. Rawat, W., Wang, Z., 2017. Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. Neural Computation 29, 2352-2449.
42. Richards, J. A. and Xiuping Jia, 2006. Remote Sensing Digital Image Analysis: An Introduction, 4th ed, Springer-Verlag, Berlin Heidelberg, Germany.
43. Saito, S., Li, T., Li, H., 2016. Real-Time Facial Segmentation and Performance Capture from RGB Input, European Conference on Computer Vision (ECCV 2016). Springer, Amsterdam, The Netherlands, pp. 244-261.
44. Sankey, T., J. Donager, J. McVay, and J. B. Sankey, 2017. UAV Lidar and Hyperspectral Fusion for Forest Monitoring in the Southwestern USA, Remote Sensing of Environment, 195: 30-43.
45. Sarkar, D., Bali, R., Sharma, T., 2018. Practical Machine Learning with Python: A Problem-Solver's Guide to Building Real-World Intelligent

- Systems. Apress, Berkeley, CA.
46. Schowengerdt, R. A., 1997. Remote Sensing, Models and Methods for Image Processing, Second ed. San Diego: Academic Press.
 47. Sermanet, P., Kavukcuoglu, K., Chintala, S., LeCun, Y., 2013. Pedestrian Detection with Unsupervised Multi-stage Feature Learning, Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, pp. 3626-3633.
 48. Shang, X., and L. A. Chisholm, 2014. Classification of Australian Native Forest Species Using Hyperspectral Remote Sensing and Machine-Learning Classification Algorithms, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7(6): 2481 – 2489.
 49. Sommer, C., S. Holzwarth, U. Heiden, M. Heurich, J. Muller and W. Mauser, 2015. Feature-Based Tree Species Classification Using Hyperspectral and LiDAR Data in the Bavarian Forest National Park, 9th EARSeL Imaging Spectroscopy Workshop 2015, EASReL eproceeding 14, Special Issue 2.
 50. Waske Björn, Jon Atli Benediktsson, Kolbeinn Árnason and Johannes R Sveinsson, 2009. Mapping of hyperspectral AVIRIS data using machine-learning algorithms, Canadian Journal of Remote Sensing, 35:sup1, S106-S116, DOI: 10.5589/m09-018.
 51. Zhang, L., and X. Huang, 2010. Object-Oriented Subspace Analysis for Airborne Hyperspectral Remote Sensing Imagery, Neurocomputing, 73(4-6):927-936。
 52. 王驥魁，朱宏杰、林志交、曾義星，2012。全波型光達與高光譜影像融合於地物分類應用，「101年度發展高光譜與光達技術結合之應用工作案」精簡報告。
 53. 行政院農業委員會林務局，2015。第四次森林資源調查報告。民108年2月28日，取自<https://www.forest.gov.tw/File.aspx?fno=66716>。
 54. 李庭誼，2011。結合光譜與空間特徵之高光譜影像物件分類，國立臺灣大學土木工程學系碩士論文。
 55. 林金樹，2013。高解析度多光譜影像於森林資源調查之應用，林務局農林航空測量所研究計畫成果報告。
 56. 邱立文、黃群修、吳俊奇、謝小恬，2015。第4次全國森林資源調查成果

概要，台灣林業，第41卷，第4期，pp. 3-13。

57. 徐百輝，2003。小波轉換應用於高光譜影像光譜特徵萃取之研究，國立成功大學測量工程學系博士論文。
58. 徐百輝與張嘉玳，2010。物件導向分類演算法於衛星影像分析之應用：中央大學前瞻通訊實驗室九十九年度專案研究計畫。
59. 陳朝圳，2011。航照數位多光譜影像於林地經營管理上之應用，林務局農林航空測量所研究計畫成果報告。
60. 楊琇涵，2007。應用小波神經網路於高光譜影像分類，國立臺灣大學工學院土木工程學系碩士論文。

附件 A-1、期初報告審查會議紀錄及處理情形回覆

行政院農業委員會林務局農林航空測量所 應用高光譜航遙測影像於土地覆蓋型調查之研究 期初審查會議紀錄			
壹、時間：	中華民國 108 年 5 月 1 日（星期三）上午 10 時		
貳、地點：	農航所和平辦公大樓 201 會議室		
參、主席：	管所長立豪	記錄：	傅淑瑋
肆、出席人員：	詳如簽到表		
伍、會議結論	今日期初審查會議通過，請研究團隊依委員建議修正，並於 5/13 前將修正後工作計畫書電子檔函送本所，據以辦理第一期請款事宜。		
陸、散會：	上午 11 時 45 分		
柒、委員意見：			
審查意見		研究團隊處理情形回覆	
李委員龍正	1. 因植物的生長有季節變化，且機載航拍費用較高，若以一次機載高光譜拍攝成果進行林地分類較為困難，建議在經費有限的狀況下，可評估租借搭載高光譜感測器的無人機進行 3~4 次拍攝。 2. 根據過去經驗，定翼型無人機搭載高光譜儀器飛行時較容易晃動，建議可加雲台改善。 3. 考量林業領域之應用，建議無人機評估之感測器可同時兼具「高光譜」加「光達」之機型。	1. 感謝委員意見，本研究已規劃採用機載高光譜影像拍攝，因經費有限，恐無法另行租借搭載高光譜感測器的無人機進行拍攝 3-4 次。但本研究將另外拍攝具紅外線的無人機多光譜影像輔助地真資料之調查。 2. 感謝委員意見，本研究進行定翼型無人機搭載高光譜儀器之評估時，會將雲台的影響列入評估項目中。 3. 本研究仍以定翼型無人機搭載高光譜感測器可行性評估為主，若時間及經費許可，再針對同時搭載光達之可行性進行評估。	
柯委員正浩	1. 本計畫規劃合理，與目前學界主流「深度學習應用於光學遙測」之趨勢相符，在林業亦屬首次應用案例，意義重大，期待有好的成果並在林業可推展更廣域的應用。	1. 感謝委員給予肯定	
陳委員	1. 地真資料將由本案執行收集?或使用既有資料?建議盡量詳細建立並將高光譜影像之幾何、輻射校正	1. 感謝委員建議，地真資料將會參考現有資料，並由本案進行收集。本案所有高光譜影像皆會完成幾何及	

繼 藩	做好，並可考慮如同普渡大學之公開資料模式開放學界共同測試研究，以找出適當的分類方法。 2. 本案重點雖在高光譜影像資料的收集，但應不設限於光譜資訊的分析，影像紋理、高度及 1 公尺空間解析度等特徵亦可納入分析方法中考慮，以達到最佳效果。	輻射校正，是否對外開放仍以農航所的政策及規劃為主。 2. 感謝委員意見，本研究所採用分析方法將同時考量空間及光譜特徵，以提升分類之準確度。
鄭 委 員 祈 全	1. 本計畫題目為高光譜影像應用於「土地覆蓋型」調查，工作項目為「評估應用於全國森林資源調查之可行性」，但樣區之一挑選大農大富平地森林園區，為地勢平坦、不同闊葉樹種的人工造林地，係指要分類到「不同樹種」階層？若以森林資源調查之分類層級，試驗林場的地點較為適宜。建議應釐清研究以「土地覆蓋型分類」或「森林覆蓋分類」為主軸，會影響最終影像分類準確度之計算。 2. 有關山區拍攝影像經常有陰影？請問陰影的處理方式？	1. 感謝委員意見，本研究針對大農大富平地森林園區，將會針對不同樹種之光譜反射特性進行分析，並評估分類之可行性。另出雲山苗圃區域將同時涵蓋不同之「土地覆蓋類型」及「森林覆蓋類型」，亦將為本研究之研究目標。 2. 陰影區域若完全無光譜反射資訊，則將歸類為「陰影」或「未分類」；若仍呈現部分光譜資訊，則仍將依據光譜變化資訊嘗試進行分類。
任 委 員 玄	1. 植物生長因季節、落葉樹種之不同階段而有不同光譜反射資訊，請問本案機載影像預計拍攝的季節與拍攝次數？ 2. 根據太空中心機載高光譜拍攝 70 公分解析度影像應用於農作物分類，是看不到紋理特徵，因此若以本案規劃影像解析度為 1 公尺，應用於林木分類也可能有看不到紋理特徵的情況。 3. 評估 Sky Arrow55 無人機搭載高光譜感測器工作項目，應考慮機內空間、載重，另經費編列 20 萬之用途是指採購亦或是評估之費用？ 4. 教育訓練課程「高光譜影像分類演算法介紹」規劃 2 小時應無法	1. 感謝委員意見，植物確實會因為不同季節而導致不同之光譜反射。本研究受限於時間及經費，機載影響僅拍攝一次，時間為 7/15 之前(視飛航申請及天候狀況而定)，屬於夏季。 2. 相對於農作物，森林樹冠有較大的空間涵蓋範圍及變化，因此本研究將針對 1 公尺解析度的空間紋理資訊是否有助於分類進行分析及評估。 3. 感謝委員意見，本研究進行 Sky Arrow55 無人機搭載高光譜感測器之嫗估時，將考慮機內空間、載重。另經費編列 20 萬為評估之費用。 4. 關於教育訓練，本案將視實際情況增加教育訓練之時數。 5. 幾何校正所使用之檢核點將採人工

	完整介紹完畢，建議再增加時數。 5. 有關品質管制及檢核一章，請問幾何校正將使用外業檢核點資料，是人工測量還是用既有檢核點？並請詳述輻射校正以「同一類別影像」進行校正的意思？此外執行本案地真資料非常重要，將需要大量樣本才可能有好的成果。 6. 樹種分類的成果為面積還是株數？ 7. 陰影因高度而產生，是否輻射校正轉換為反射率可處理陰影的問題？ 8. 交付成果中提供之影像會包括那些？煩請說明。 9. 有關衛載高光譜 Hyperion 目前已無新攝影像，是否可以其他多光譜衛載影像取代進行比對，減省無人機拍攝之工時？	方式實地測量；輻射校正將採大氣校正模式將輻射量轉換為反射率，相關內容已於期初計畫書中進行描述及修正。 6. 樹種分類的成果將以為面積為主。 7. 感謝委員建議，本研究將評估是否能以大氣校正(即將輻射量轉換為反射率)的方式解決陰影的問題。 8. 本研究交付成果主要為衛載及機載高光譜影像。 9. 感謝委員意見，本研究將盡量蒐集實驗區內之多光譜影像，以作為比對分析之用。
吳委員淑華	1. 地真資料可評估林務局、農航所現有圖資是否可輔助佐證，減少人力重複作業。 2. 本案採用「相對輻射校正」之程序不同於其他案例以布設地面反射板進行校正，請於報告書中詳細說明。 3. 本計畫為初期試驗，原規劃之「高光譜影像應用於全國森林資源調查之可行性評估」目標過於遠大，建議針對現有樣區修正較為明確之內容。	1. 感謝委員建議，本研究地真資料除了人工調查之外，亦將請農航所提供現有圖資以增加地真資料之豐富度及減少人工調查之時間。 2. 輻射校正將採大氣校正模式，將輻射量轉換為反射率，相關內容已於期初計畫書中進行描述及修正。 3. 感謝委員建議，本研究將視實際分析情況，與農航所討論評估成果之討論範圍。
苗委員中信	1. 計畫中採用演算法之軟體為何？ 2. 計畫結案的演算方法或程式是否會轉移本所，由同仁另行輸入資料求得成果？另所內同仁需具備那些技能因應？	1. 本研究所採用之分析演算法大都為自行撰寫之程式，另少數將採用開源程式碼。 2. 本研究所所有演算程式將移交農航所使用，另程式將設計 UI 介面，以利農航所同仁使用。
吳委員	1. 感謝所內提出航遙測技術應用於林業調查之計畫，有關第四次森	1. 感謝委員建議，本研究將持續與農航所同仁討論了解森林資源調查製圖

員 俊 奇	林資源調查製圖流程請農航所同仁協助對台大團隊說明。 2. 有關森林資源調查分類表建議可呈現於報告書中供參。 3. 光達技術於本案之應用為何?	流程。 2. 已於修正後之期初計畫中增加相關內容。 3. 光達資料主要應用於幾何改正，並無用於分類。若時間允許，本研究將另行評估整合高光譜及光達資料於林型分類之可行性。
-------------	---	---

附件 A-2、期中報告審查會議紀錄及處理情形回覆

行政院農業委員會林務局農林航空測量所 應用高光譜航遙測影像於土地覆蓋型調查之研究 期中審查會議紀錄			
壹、時間：	中華民國 108 年 8 月 15 日（星期四）下午 2 時 30 分		
貳、地點：	農航所和平辦公大樓 201 會議室		
參、主席：	管所長立豪	記錄：	蔡仲涵
肆、出席人員：	詳如簽到表		
伍、會議結論	今日期中審查會議通過，請研究團隊依委員建議修正，並於 8 月 26 日前將修正後期中報告書電子檔函送本所，據以辦理第二期請款事宜。		
陸、散會：	下午 16 時 20 分		
柒、委員意見：			
	審查意見	研究團隊處理情形回覆	
陳 委 員 繼 藩	4. 請將期中報告之結果、討論請重新整理完整敘述，並將每種分析方法之結果完整表列，包含各項目類別之分類準確度及小結。 5. 請說明衛載高光譜影像之物件式分類為何無相關成果呈現？ 6. 期末繳交成果建議將重點放在機載高光譜影像，避免花費太多時間在已除役之衛載影像。 7. 有關農航所無人機未來搭載高光譜儀器之評估，應協助農航所篩選機型並給予建議。 8. 簡報中 2 樣區之 false color 的波段呈現順序不同，應特別註明。 9. 請說明總樣本數、訓練樣本數及檢核樣本數如何選取，並請以圖示呈現及空間分布。	4. 感謝委員意見，已將期中報告之結果與討論重新檢視並調整，同時加入不同分析方法的各類別分類準確度與說明。 5. 因 Hyperion 衛載高光譜影像地面解析度為 30 公尺，不適合進行空間紋理之分析，因此未採用物件式分類方法。 6. 感謝委員意見，機載高光譜影像於 7 月中旬取像完成，後續會將重點放在機載高光譜影像之分析。 7. 感謝委員建議，無人載具高光譜儀之評估會根據蒐集之資訊與經緯航太科技股份有限公司之研發團隊進行討論。 8. 感謝委員意見，已將假色影像之波段呈現調整為常見之使用波段，並註明波長。 9. 總樣本數是將地真資料與影像對位後，選取各類別所涵蓋的最大範圍，同時避免選擇交界處之像元，訓練樣本與檢核樣本則是以總樣本為基礎，	

		利用隨機選取的方式採用 7:3 之比例設定樣本數。
李委員龍正	1. 請問本案之分析軟體為何？或是由團隊自行撰寫？ 2. 建議農航所無人機適宜搭載高光譜儀器評估之載具雲台應納入考量。 3. 建議可比較機載及衛載高光譜影像分析結果，若機載成效好，再考慮無人機影像。 4. 農航所亦可考慮拍完 1 個小區塊，開放各界挑戰影像分類準確度，藉此取得最好的分類方法。	1. 本研究所採用之分析演算法大都為自行撰寫之程式，另少數將採用開源程式碼。 2. 感謝委員建議，農航所無人機適合搭載之高光譜儀器會考量無人機之雲台特性，並與無人機研發團隊討論。 3. 感謝委員建議，本研究仍以機載與衛載高光譜影像分析為基礎，並根據成果提出合適的分析流程。 4. 感謝委員建議，本案所有高光譜影像皆會完成幾何及輻射校正，是否對外開放仍以農航所的政策及規劃為主。
柯委員正浩	1. 建議直接與目前蒐集到無人機高光譜儀器之原廠聯絡，將農航所無人機機型等資料提供給廠商評估，以有無人機搭載經驗之廠商為優先，以確保後續裝卸、測試等環節之零失誤。	1. 感謝委員建議。
鄭委員祈全	1. 就報告中衛載出雲山高光譜影像分類準確度不及 60%，請評估準確度低之原因，並將其改進於機載高光譜影像分析上。 2. 請確認 PCT 及 DAFE 之分析方法，在使用 7 個波段時準確度皆為 59.87%之真實性。 3. 如何解決影像陰影之問題，是否有先歸類？ 4. 因目前僅有 2 試驗區，應審慎考量本案研究方法及結論，是否可擴及全國森林資源調查可行性。	1. 感謝委員意見，衛載高光譜影像成果不及 60%，其原因包含影像之地面解析度為 30 公尺，會有明顯光譜混合的情形，樣本選取時的細緻度以及同類別中不同樹種的差異均會對成果造成影像，後續會進行調整與精進。 2. 感謝委員意見，已重新確認 PCT 及 DAFE 之分析方法，並修正期中報告之成果。 3. 感謝委員意見，本次衛載高光譜影像之分析未將影像問題納入考量，後續會修正此問題，陰影區域若完全無光譜反射資訊，則將歸類為「陰影」或「未分類」；若仍呈現部分光譜資訊，則仍將依據光譜變化資訊嘗試進行分類。 4. 感謝委員建議。
任委	1. 輻射校正採大氣校正模式將輻射校正轉換為反射率，應需收集地	1. 將輻射較整轉換反射率是採用原廠軟體與相關建議設定，亦有採用手持

員 玄	真資料方可執行，是否有手持光譜儀於現場量測地面的光譜資料？ 2. 若無人機僅搭配高光譜儀器，請評估無人機在未搭配光達之幾何校正誤差會達多少？ 3. 請說明出雲山及大農大富試驗區利用高光譜蒐集影像波段數不同之原因。 4. 取得之地真資料精細程度為何？是否有區分到樹種？ 5. 有關本案教育訓練之部分，因涉及應用層面，建議可納入上機操作。	光譜儀於現地取得部分之地面光譜資料。 2. 根據機載高光譜影像之處理經驗，在校正時仍會著重於 POS 系統提供的資訊，是否搭配光達之幾何校正的成果差異不大，此外地形資料之取得亦可以採用政府公開的地形資料，後續會再討論此問題。 3. 因為2個樣區的高程與地形變化都有顯著的差異，已根據兩區域的地形針對高光譜儀的限制設定最高標準，大農大富樣區的地形較平坦，可以獲取較多的波段數，出雲山樣區則因為有明顯的地勢起伏，在儀器使用的限制，所能獲取的波段數較少。 4. 根據農航所提供之地真資料，大致上資料都具有樹種之資訊，以及不同樹種比例之資訊。 5. 感謝委員建議。
吳 委 員 淑 華	1. 建議報告內容以表格方式呈現較為清楚。 2. 本案研究項目有關應用於全國森林資源調查之可行性評估，建議在用字及敘述上應保守審慎。	4. 感謝委員建議，會調整報告呈現方式更為清晰易讀。 5. 感謝委員建議。
苗 委 員 中 信	1. 請修正 P16 圖 3-1 之「本計畫執行流程」最後一個程序。 2. 因本案影像已蒐集完成，請修正報告書中有關影像蒐集狀態之敘述。 3. 請修正報告書中之 CASI1500 光譜範圍誤植問題。 4. 請以表呈現衛載高光譜影像可用之特徵波段。 5. 請修正 P77 小結漏字部分。	1. 感謝委員意見，已修正流程圖，本計畫的最後程序為彙整期末成果並撰寫研究報告。 2. 感謝委員意見，已修正報告內機載與衛載高光譜影像蒐集狀態之描述。 3. 感謝委員意見，已將 CASI-1500 的光譜範圍修正並統一描述。 4. 感謝委員意見，已將高光譜影像無法使用之波段表列呈現，後續會進一步說明可用之特徵波段。 5. 感謝委員意見，已將小結之內容修正。
管 委 員	1. 因研究文獻蒐集為本案工作項目之一，請於報告中將文獻逐一列出。	4. 感謝委員建議，已修正缺漏之部分，列於參考文獻中。 5. 感謝委員建議，本次期中報告已蒐集

立 豪	2. 請團隊先行篩選適合本所無人機高光譜儀器機型及波段。	無人機高光譜儀之機型做為討論之基礎，後續將與無人機之研發團隊進行討論。
林 務 局 潘 科 長 德 發	1. 期待本案成果於全國森林資源調查之應用。 2. 有關文獻回顧高光譜可達 80%以上之分類準確度，請研究團隊瞭解該分類方法是否可用於臺灣，或有資源調查分類項目改善之建議可提供。	1. 感謝委員給予肯定。 2. 感謝委員建議，會再深入了解不同方法的特性。
其 他 意 見	1. 是否可提供機載高光譜儀對於農地、林地等最佳解析度之建議，供本所未來機載航線規劃之參考。 2. 因衛載高光譜影像解析度較差，各分類方法及成果應於機載高光譜影像重新測試。 3. 請問訓練樣區之選擇方式為何？以像元或面積？ 4. 在分類準確度的評估上，建議可以嘗試就森林資源調查資料分類之最低層次資作為訓練主體及進行精度評估，或可得到較佳訓練成果，層次較高的分類只需依照分類準則再合併即可。 5. 若時間上允許，建議大農大富之 144 波段可重新取樣同出雲山之 96 波段，再進行比較分析。 6. 請再重新檢視參考文獻之格式。 7. 建議有關無人機高光譜儀器請將「儀器拆卸」難易程度納入評估。 8. 請比較無人機高光譜感測器像元式及推掃式之優缺點及感光元件有何差異，以利本所後續評估。	1. 感謝委員意見，本研究會以目前選定兩個實驗樣區進行相關的分析，並可將相關之經驗作為後續之參考。 2. 感謝委員意見，目前已完成機載高光譜取像，待整體影像處理完成，將會進行機載高光譜影像的分析。 3. 訓練樣區的選擇是根據地真資料的位置，盡可能涵蓋最大的範圍，以像元為選擇的基礎，後續再利用隨機方式選擇訓練樣本。 4. 感謝委員建議。 5. 感謝委員建議，將會根據兩組資料之差異進行相關的比較分析。 6. 感謝委員意見，已將參考文獻之格式修正。 7. 感謝委員建議，會將相關儀器拆卸之情形納入評估並與無人機研發團隊討論。 8. 感謝委員建議，後續將會比較各式無人機高光譜儀之成像方式、感光元件及優缺點，並以無人機研發團隊討論。

附件 A-3、期末報告審查會議紀錄及處理情形回覆

行政院農業委員會林務局農林航空測量所 應用高光譜航遙測影像於土地覆蓋型調查之研究 期末審查會議紀錄			
壹、時間：		中華民國 108 年 12 月 9 日（星期一）上午 10 時 00 分	
貳、地點：		農航所和平辦公大樓 201 會議室	
參、主席：		管所長立豪	記錄：蔡仲涵
肆、出席人員：		詳如簽到表	
伍、會議結論		今日期末審查會議通過，請研究團隊依委員建議修正，並儘速繳交修正後成果報告書初稿電子檔函送本所，經本所審查確認後，於 12 月 16 日前將相關成果函送本所，據以辦理驗收及相關事宜。	
陸、散會：		下午 12 時 15 分	
柒、委員意見：			
審查意見		研究團隊處理情形回覆	
柯委員正浩	10. 因計畫含光達資料，其於本計畫中扮演的角色為何？未來是否有對成效再提升的空間？	10. 本次計畫內的光達資料主要使用於高光譜影像幾何校正，後續分類分析並未將光達資料加入分析。未來若考量光達資料，並從中獲取樹高資料或其他幾何資料，在特徵分類或物件導向分類法應有成效提升之空間。	
李委員龍正	5. 因固定翼型無人機高光譜雲台之精度及穩定度仍有進步空間，建議農航所應先測試載具雲台之穩定度，並以搭配原有無人機之相機，經確認穩定度後再添購高光譜儀器。 6. 本研究測試的影像分類方法很多，然並未測試較簡易之 SAM(Spectral Angle Mapper) 的方法，是否因此方式受植物於不同季節、生長期、影像拍攝時間而影響分類結果，或有其他未採用此法之原因？請說明之。	5. 感謝委員建議。 6. 本案根據資料蒐集以及過去研究成果，選定特徵分類法、物件導向法和機器學習法作為分析方法，同時根據過去研究時的經驗，以 SAM 方法的成果較不理想，未來也可以測試 SAM 方法與其他自動分類法比較。	
鄭委員	5. 以出雲山為例，用機載及衛載之 DAFE 及 DBFE 效果還不錯，是否可以再補充本報告之結果討論，以	5. 感謝委員意見，已將結果討論補充於成果報告書。 6. 感謝委員建議。	

祈全	免使讀者誤解這些分類方法及參數僅能適用於特定測試樣區。 6. 建議可於未來將農航所之前 ADS40 於森林資源調查分類研究的成果納入比較。 7. 在全國森林資源調查應用上，航遙測影像陰影所佔的比例高，請說明如何解決於高光譜影像分類。 8. 建議可以利用階層式（Hierarchical）分類方式，先使用衛星影像將針、闊葉林區分出來，再逐層利用不同的航遙測影像特性往下層分類，以節省大面積以高光譜儀器取樣之成本。 9. 請再次確認各表格之波段數、以 OA 以百分比表示方式；另生產者精度、分類準確度等用法亦請於報告書統一。 10. 建議就報告內之各種分類方式與傳統光譜分類的方式，評估何者較有效率。 11. 建議報告書應調整成一致之彩色內頁。 12. 建議可以多撰述一些結論及建議。	7. 本次高光譜影像分析，未針對陰影區域進行深入探討，主要仍選定非陰影區作為訓練資料；若實際陰影區像元若非完全沒有輻射強度值，其實光譜曲線仍保有對應物種的特性，可依據其光譜曲線特性進行分析。 8. 感謝委員建議。 9. 感謝委員意見，已重新檢視報告書內準確度之表現方式並修正，以及統一用詞為分類準確度、生產者準確度和使用者準確度。 10. 感謝委員意見，已補充相關內容於成果報告書中。 11. 感謝委員意見，後續成果報告書紙本將會一致以彩色頁呈現圖片。 12. 感謝委員意見，已補充相關內容於成果報告書中。
任委員玄	6. 以大農大富樣區的長方形樹種區塊，請說明 rounded shape index 等規則套到其他區域森林使用之可能結果。 7. 光達所獲得的資料可用來產製 DTM 及 DSM，是否對本案研究分類有所幫助。 8. 目前機載獲得的高光譜影像地面解析度為 1m，若以 UAV 影像拍攝即可能獲得更高解析度之影像，日後是否可能以樹葉生長方式等參數設定其他規則，而大幅提升各樹種判釋之準確度。 9. Headwall 之光譜範圍有涵蓋到 1700nm，請說明這段波長區間是否	6. 大農大富樣區雖然樹種多屬長方形區塊，但實際影像分割時獲得的影像物件行裝多以樹木實際生長狀況，而非規則區塊，相關規則與經驗仍可用於其他區域，但仍須針對不同區域實際情形做調整。 7. 本案於高光譜影像分類分析未加入 DTM、DSM 作為考量，未來若考量光達資料，並從中獲取樹高資料，在物件導向分類法會有成效提升之空間。 8. 若有更佳的地面解析度，樹葉生長方式等參數，也可視為不同物種的空間紋理變化，對各樹種判識應有所幫助。


	對本案有幫助。 10. 請再確認報告書 P153 中之 SENOP UAV 高光譜儀，其波段數達 1000、光譜解析度為 5-10nm 之數據是否正確。 11. 本案是否有機會提供所列無人機高光譜儀器之相關報價？	9. SWIR 的波段主要為水或是氣體吸收帶，若不同樹種的生長狀態不同，對於吸收帶的反應有所不同，應對本案相關分析也有所幫助。 10. 根據 SENOP UAV 高光譜儀的產品手冊，其說明波段數可根據需求最多達到 1000、光譜解析度為 5-10nm，後續會再蒐集其他資料，確定是否有其他細節說明。 11. 不同儀器廠商的原廠或代理商往往有不同的作業方式，相關報價差異很大，建議於實際作業時，再詢問報價會較為準確且適宜。
吳委員淑華	3. 樹種辨識之相關研究應持續研究進行，建議未來公部門亦可建立各樹種之 Spectrum Library，以自動化的方式取代人為主觀作業。 4. 請說明土地覆蓋型高光譜資料條帶間鑲嵌的問題應如何解決。	6. 感謝委員建議。 7. 影像條帶間鑲嵌問題，若將航帶間光線反射角度加入考量，如採用雙向反射分布函數(BRDF)，可以進一步處理相關問題，原廠軟體後續亦有考量 BRDF 之操作方式，可進一步了解。
苗委員中信	6. 請問各特徵萃取之波譜範圍為何？可做為未來本所增購高光譜儀器之參考依據。 7. P158 提及高光譜儀最重的為 HySpex 之 5.7 公斤，但表 8-1 最重者有 6 公斤，請將前後論述修正一致。 8. P160 本所 SA55 需求為高光譜儀主體小於 3 公斤，且用電量不大於 50 瓦特時為承載範圍，建議可將表 8-1 超出前述範圍者予以不列。 9. 建議於繳交成果時，說明本案會使用到的程式及說明。	6. 因特徵萃取是將原有的光譜波譜關係打散並且轉換，單一特徵波段的資訊可能是由多個不同波長波段計算所得，特徵萃取後的特徵波段並無法跟原始的光譜波段做直接連結。 7. 感謝委員意見，已於成果報告書中修正相關內容。 8. 感謝委員意見，已於成果報告書中調整相關內容，但因為並非所有機型的資訊都能夠完整蒐集，已將超出需求範圍之機型以灰色字體呈現。 9. 感謝委員意見，後續成果繳交會檢附相關說明。
管委員立豪	3. 結論的部分請團隊就本案補充建議何種分類演算法為較佳之方案。 4. 針對林型的部分，是否可先分闊葉樹、針葉樹、竹林等個別特徵再往下分析。 5. 若分析陰影中仍有其光譜趨勢，建議未來可以再測試判釋的解決方	1. 感謝委員意見，已於成果報告書補充內容。 2. 單一林型包含多個樹種較不利於光譜曲線的特性分析，若是採用單一樹種分析，再往上整合分析林型，則是較可行之方法。 3. 感謝委員建議。

	法。	
林務局吳技正俊奇	3. 建議結論可以增列往後可能的研究方向。 4. 建議未來可以持續針對森林資源調查之闊葉樹林型，再細分出較易辨識之樹種如相思樹；亦可針對大面積的造林樹種進行相關分類研究，如檜木、竹林（單桿竹、叢生竹）等，對全國森林資源調查將會極有幫助。	3. 感謝委員建議，以於成果報告書中調整相關內容。 4. 感謝委員建議。
其他意見	9. 是否曾評估本案人工林的分類設定參數應用於天然林？ 10. 建議未來可利用高光譜影像找尋珍貴樹，如檜木、扁柏等分布，以利後續林業調查作業。 11. 建議未來可以針對外來樹種進行監測，並建構完整基礎分析資料（含不同季節之影像蒐集）。 12. 是否有國外文獻提及如何處理高光譜影像之陰影分析？ 13. 簡報中有多處新增說明，請團隊一併於成果報告書修正。 14. 因本案業進行到期末及成果報告階段，報告書前段的敘述請以結案之角度一併修正用語。 15. 請團隊封面的「期末報告書」修正為「成果報告書」以符合合約規定。 16. 提供大農大富的地真資料約有 20 種樹種，請說明本案成果選擇其中 10 種樹種之原因。	9. 本案無直接評估人工林與天然林之參數設定，而所提出的方法特徵分類法與機器學習法主要是透過樹種本身的光譜曲線特性配合訓練資料進行分析，天然林亦可直接適用，物件導向分析方法則需要根據不同影像的實際狀況進行參數之微調。 10. 感謝委員建議。 11. 感謝委員建議。 12. 關於高光譜影像之陰影分析於國內外文獻中都較少討論到，後續會持續關注相關的文獻討論。 13. 感謝委員意見，已於成果報告書補充內容。 14. 感謝委員意見，已於成果報告書修正相關內容。 15. 感謝委員意見，已於成果報告書修正相關內容。 16. 大農大富地真資料雖有 20 多種樹種，但約有一半以上的樹種分布區域很小，不易獲取足夠的訓練或檢核資料，因此選擇主要的 10 種樹種進行分析。

附件 B-1、高光譜儀

About us

儀器設備 數位影像儀器



本公司擁有2套中像幅航拍專用數位相機及1套高光譜影像掃描系統（是目前國內唯一商業化之高光譜系統），可提供不同需求與目的之飛航資料蒐集服務。

高光譜影像掃描系統：為提供更多及更廣的服務項目，本公司於2012年1月購置全台灣首套商業化之高光譜（Hyperspectral）影像掃描系統；由加拿大ITRES公司製造之CASI 1500系統，其光譜波長介於308nm~1050nm之間（相當於可見光至近紅外光波段範圍），最多可獲取288個波段之光譜資訊，像元（pixel）大小為20.0 μ m。航拍後之光譜影像可提供森林分估計、精緻農業計畫、特殊物種分類辨識、河川海洋水質分析、植物葉綠素含量分析、地表岩層礦物質分析、土壤重金屬污染等服務。



1台

地面光譜儀

PSR-1100

- 視野（橫向）：4度
- 光譜範圍：320~1100nm
- 光譜分辨率：3.2nm
- 光譜抽樣間隔：1.5nm
- 重量：1.4kg



1台

高光譜影像掃描

ITRES CASI1500 (SN:2528)

- 視野（橫向）：40度
- 空間抽樣：1500像元
- 光譜抽樣：288波段
- 光譜範圍：380~1050 nm
- 光譜分辨率：<3.5 nm
- 光譜抽樣間隔：2.4 nm
- 孔徑：f/3.5
- 輻射精度：470~900 nm，絕對值 $\pm 2\%$ ，<470或>900 nm，絕對值 $\pm 5\%$
- 電源支持：28VDC 13.5 A
- 溫度範圍：0~35度 重
- 重量：25 kg

附件 B-2、雷射掃描儀及數位相機

About us

儀器設備 空拍儀器



數位相機

PhaseOne iXU-R1000

- CCD-chip: 53.4*40.0mm
- 像幅大小: 11608x8708 pixels
- 像素大小: 4.6μm
- 鏡頭焦距: 50 mm
- 鏡頭FOV: 28.1
- 快門速度: 1/1600秒
- 作業用途: 航空攝影測量



全波形

Waveform Digitizer(SN:10DIG021)

- 取樣間隔: 1ns
- 最大紀錄頻率: 125kHz
- 可記錄回波長度: 440ns

空載雷射掃描儀

Optech PegasusHA 500(SN: 14SEN333)



- 掃描旋角視域FOV: 0~75度
- 脈衝率PRF: 100~500kHz
- 掃描鏡頻率: 0~140Hz
- 掃描形式: Oscillating, Mirror, Z-shaped
- 高程精度: <5-20公分(1σ)
- 水平精度: 1/7,500航高(1σ)
- 雷射波長: 1064 nm
- 光束發散角度: 0.25 mrad (1/e)
- GPS: Trimble
- Position Orientation System: POS AV™ AP50 (OEM)
- 作業用途: 獲取高精度密佈於地表之三維點位

附件 C、飛航掃描申請函文

檔號：
保存年限：

中興測量有限公司 函

公司地址：403台中市西區向上路一段11號8樓
傳 真：(04) 23014708
承 辦 人：李仲軒
電 話：(04) 2301-0616#56

受文者：內政部

速別：普通件
密等及解密條件：
發文日期：中華民國 108 年 4 月 30 日
發文字號：(108)中興測字第 1080000125 號
附件：如主旨

主旨：檢送本公司承辦行政院農業委員會林務局農林航空測量所「應用高光譜
航遙測影像於土地覆蓋型調查之研究」案航攝實施計畫書三份，請 核
備。

說明：

- 一、依據「實施航空測量攝影及遙感探測管理規則」規定，檢附航攝實
施計畫書各三份，供貴部審核，並懇請准予辦理。

正本：內政部

副本：台灣大學、本公司光達室(副本皆不含附件)

總經理 林東裕

檔 號：
保存年限：

內政部 函

地址：10017臺北市中正區徐州路5號
聯絡人：連以諾
聯絡電話：02-23565272
傳真：02-23976875
電子信箱：moi1912@moi.gov.tw

受文者：中興測量有限公司

發文日期：中華民國108年6月3日
發文字號：台內地字第1080121507號
速別：普通件
密等及解密條件或保密期限：
附件：

主旨：貴公司受國立臺灣大學委託辦理行政院農業委員會林務局農林航空測量所「應用高光譜航遙測影像於土地覆蓋型調查之研究案」案，申請實施航空測量攝影1案，原則同意，請查照。

說明：

- 一、依國土測繪法第55條規定及國防部108年5月27日國情整備字第1080001392號函辦理，並復貴公司108年4月30日(108)中興測字第1080000125號函。
- 二、貴公司實施航空測量攝影期間為核准次日起至108年12月16日止，本案實施航空測量攝影獲取成果，請依「實施航空測量攝影及遙感探測管理規則」第8條及第9條規定，於沖洗或影像處理後，提送本部會同國防部審查，以完備程序；並請於執行任務完竣後60日內編製相關文件送本部備查。
- 三、請依「普通航空業管理規則」第9條規定於執行航空攝影作業5工作日前，檢附相關文件向交通部民用航空局申請核



准，並應依據飛航規則、飛航指南等相關規定飛航。

四、另請於執行航空攝影任務時，勿涉軍事機敏設施，並於任務前2日通知國防部、空軍司令部、空軍作戰指揮部及軍事飛航單位，以維飛安。

五、貴公司對本處分如有不服，應於接到本處分書次日起30日內，繕具訴願書送由本部陳轉行政院提起訴願。

正本：中興測量有限公司

副本：國防部、交通部民用航空局、國立臺灣大學



檔號：
保存年限：

中興測量有限公司 函

公司地址：403台中市西區忠仁街159號
傳 真：(04) 2224-2168
承 辦 人：王星為
電 話：(04) 2301-0616#53

受文者：前進航空股份有限公司

速別：普通件

密等及解密條件：

發文日期：中華民國 108 年 6 月 6 日

發文字號：(108)中興測字第 1080000209 號

附件：

主旨：本公司接受國立臺灣大學委託辦理行政院農業委員會林務局農林航空測量所辦理-「應用高光譜航遙測影像於土地覆蓋型調查之研究案」案飛航掃瞄任務，需租用貴公司定翼機進行空載光達地形測繪系統(Pegasus)及高光譜儀器(CASI)掃瞄作業，請惠予協助飛行申請事宜，請查照。

說明：作業時間為 108 年 6 月 4 日至 108 年 12 月 16 日，位置區域台中市及花蓮縣地區。拍攝成員名單如下：

姓名	身分證字號	出生日期	性別	任職單位
李仲軒	E124400310	80.06.13	男	中興工程師
王星為	Q123801170	81.09.30	男	中興工程師
林志交	L122201994	67.06.05	男	中興光達系統室經理
王偉群	R121319483	64.08.28	男	中興工程師

正本：前進航空股份有限公司

副本：本公司光達室

總經理 林東裕

檔 號：
保存年限：

交通部民用航空局 函

地址：台北市敦化北路340號
傳真：(02)23496050
聯絡人：游孟晴
聯絡電話：23496347
電子郵件：meng0818@mail.caa.gov.tw

受文者：中興測量有限公司

發文日期：中華民國108年6月27日
發文字號：空運管字第1080015319號
速別：普通件
密等及解密條件或保密期限：
附件：如文(申請書及搭載名冊) (1080015319-0-0.tif)

主旨：貴公司使用C208B型機（國籍編號為：B-23062、B-23063）於臺中市及花蓮縣地區執行中興測量有限公司委託之「應用高光譜航遙測影像於土地覆蓋型調查之研究案」所需航空測量攝影作業一案，同意自本局核准次日起
至108年12月16日止辦理，請查照。

說明：

- 一、復貴公司108年6月12日019前字第083號申請書。
- 二、請依據「航空器飛航作業管理規則」、「航空產品與其各項裝備及零組件適航維修管理規則」、「飛航規則」、「飛航指南」等相關規定作業，作業前應先與相關航管單位協調並保持密切聯繫；另各項飛航作業紀錄應每架次詳實管制登載備查。
- 三、作業範圍應符合內政部同意之航攝區域，另執行作業1工作日前務必將飛航作業地區簡圖（應附有比例尺之簡圖，包



括：飛行路徑及作業範圍）送交本局飛航服務總臺，並通知空軍司令部、當地軍方起降基地、當地航空站及飛航管制聯合協調中心（JCC）等單位。

四、本案因涉及航空測量作業，請依「國土測繪法」、「實施航空測量攝影及遙感探測管理規則」相關法規及內政部108年6月3日台內地字第1080121507號函辦理。

五、作業時請勿涉及軍事及機密敏感設施，並請將空照成果送交國防部情報參謀次長室檢查。如涉機密資料部分，請按「國家機密保護法」、「要塞堡壘地帶法」及其相關法規之規定妥慎處理。

六、嚴禁未依核准之作業項目實施作業、無故在未經核准之臨時性起降場所起降或搭載未經核准之乘員，否則依民用航空法第112條之6規定，處新臺幣6萬元以上30萬元以下罰鍰。

正本：前進航空股份有限公司

副本：中興測量有限公司、國防部參謀本部情報參謀次長室、國防部參謀本部作戰及計畫參謀次長室（戰情中心）、國防部陸軍司令部戰備訓練處、陸軍航空特戰指揮部、國防部海軍司令部戰備訓練處、海軍艦隊指揮部、海軍陸戰隊指揮部、海軍反潛航空大隊、國防部空軍司令部、空軍作戰指揮部、空軍松山基地指揮部、內政部地政司、內政部警政署、內政部警政署航空警察局、飛航管制聯合協調中心、桃園國際機場股份有限公司、交通部民用航空局飛航服務總臺、交通部民用航空局臺北國際航空站、交通部民用航空局花蓮航空站、本局飛航標準組、飛航管制組（以上均含附件）

2019/06/27 15:45:55 文交換章