

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
重要樹種調查之研究(2/2)

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 110 年 12 月 17 日

目 錄

目 錄	I
圖 目 錄	V
表 目 錄	IX
壹、前言	- 1 -
1.1、計畫名稱	- 1 -
1.2、計畫緣起	- 1 -
1.3、計畫目的	- 2 -
1.4、工作項目	- 2 -
1.5、計畫時程	- 3 -
貳、實施方法及執行流程	- 7 -
2.1、前期計畫成果	- 7 -
2.2、本年度執行方法與流程	- 8 -
參、研究文獻蒐集	- 11 -
3.1、高光譜影像之特性與常見分析方法	- 11 -
3.2、高光譜影像於森林樹種之分類	- 16 -
肆、試驗資料蒐集	- 27 -
4.1、機載高光譜影像實驗區說明	- 27 -
4.1.1、出雲山苗圃及大雪山森林遊樂區實驗區	- 27 -
4.1.2、阿里山森林遊樂區實驗區	- 28 -
4.2、機載高光譜影像（含光達資料）獲取流程	- 30 -
4.2.1、飛航掃描儀器	- 30 -
4.2.2、飛航作業申請	- 33 -
4.2.3、掃描規劃	- 33 -
4.2.4、儀器裝機	- 34 -
4.3、機載光達資料和機載高光譜影像處理流程	- 34 -
4.3.1、機載光達資料處理流程	- 34 -

4.3.2、機載高光譜影像處理流程	37 -
伍、實驗區機載高光譜歷史影像	51 -
5.1、出雲山苗圃與大雪山森林遊樂區機載高光譜影像	51 -
5.2、阿里山森林遊樂區實驗區歷史高光譜影像與處理情形	53 -
5.3、實驗區地真資料蒐集與處理	65 -
陸、提出多時期影像最適機器學習演算模式	69 -
6.1、機器學習演算法改善及優化	69 -
6.1.1、核方法與改善	69 -
6.1.2、深度學習演算法與改善	75 -
6.2、發展多時期影像最適機器學習演算模式	80 -
柒、實驗區高光譜影像多時期分類及優化成果分析	85 -
7.1、出雲山苗圃實驗區兩時期影像與統計分析	85 -
7.2、支持向量機於出雲山苗圃實驗區兩時期影像分析	92 -
7.2.1、支持向量機分類之實驗方法說明	92 -
7.2.2、兩時期影像個別分析之支持向量機分類成果	93 -
7.3、一維卷積神經網路於出雲山苗圃實驗區兩時期影像分析	101 -
7.3.1、一維卷積神經網路分類之實驗方法說明	101 -
7.3.2、兩時期影像個別分析之一維卷積神經網路分類成果	102 -
7.4、混合三維及二維卷積神經網路於出雲山苗圃實驗區兩時期影像分 析	107 -
7.4.1、混合三維及二維卷積神經網路分類之實驗方法說明	107 -
7.4.2、兩時期影像個別分析之 HybridSN 神經網路分類成果	108 -
7.5、阿里山森林遊樂區實驗區兩時期影像與統計分析	112 -
7.6、支持向量機於阿里山森林遊樂區實驗區兩時期影像分析	119 -
7.6.1、支持向量機分類之實驗方法說明	119 -
7.6.2、兩個時期影像個別分析之支持向量機分類成果	119 -
7.7、一維卷積神經網路於阿里山森林遊樂區兩時期影像分析	125 -
7.7.1、一維卷積神經網路之實驗方法說明	125 -
7.7.2、兩時期影像個別分析之一維卷積神經網路分類成果	126 -

7.8、混合三維及二維卷積神經網路於阿里山森林遊樂區影像分析	- 130 -
7.8.1、混合三維及二維卷積神經網路之實驗方法說明	- 130 -
7.8.2、阿里山森林遊樂區 HybridSN 卷積神經網路之影像分類成果	- 130 -
-	
7.9、遷移學習法於出雲山苗圃實驗區及阿里山森林遊樂區實驗區影像 分析	- 132 -
7.9.1、一維卷積神經網路遷移學習法於出雲山苗圃實驗區影像多時期影 像分析	- 132 -
7.9.2、一維卷積神經網路遷移學習法於阿里山森林遊樂區實驗區影像多 時期影像分析	- 135 -
7.9.3、一維卷積神經網路遷移學習法於出雲山苗圃、阿里山森林遊樂區 實驗區影像多區域影像分析	- 137 -
7.10、..... 應用機器學習演算法於多時期高光譜影像分析之討論 - 140 -	
捌、建立多期高光譜影像應用於重要樹種偵測自動流程.....	- 143 -
玖、結論與建議.....	- 147 -
參考文獻	- 151 -
附件 A-1、期初審查會議紀錄及處理情形回覆	- 159 -
附件 A-2、期中審查會議紀錄及處理情形回覆	- 164 -
附件 A-3、期末審查會議紀錄及處理情形回覆	- 171 -
附件 B、英文名詞縮寫對照表	- 184 -
附件 C-1、CASI-1500h 規格表及光學率定證明文件	- 186 -
附件 C-2、雷射掃描儀及數位相機規格表.....	- 188 -
附件 D-1、教育訓練.....	- 189 -
附件 D-2、成果交付.....	- 193 -

圖 目 錄

圖 2-1、本計畫執行流程.....	- 9 -
圖 3-1、成像光譜儀之成像示意圖（徐百輝，2003）	- 13 -
圖 3-2、實際高光譜影像影像立方體與相關矩陣	- 13 -
圖 4-1、出雲山苗圃及大雪山森林遊樂區實驗區位置圖	- 28 -
圖 4-2、阿里山森林遊樂區及台 18 線沿線實驗區位置圖	- 29 -
圖 4-3、高光譜成像光譜儀概念(浦瑞良和宮鵬，2002).....	- 31 -
圖 4-4、機載光達儀器規格.....	- 31 -
圖 4-5、飛航作業申請流程圖	- 33 -
圖 4-6、機載光達和高光譜裝機現況	- 34 -
圖 4-7、機載光達資料作業流程	- 35 -
圖 4-8、飛航掃描航跡示意圖	- 36 -
圖 4-9、點雲解算產製處理流程	- 36 -
圖 4-10、高光譜產製流程.....	- 37 -
圖 4-11、高光譜影像初步品管軟體.....	- 38 -
圖 4-12、輻射校正原廠軟體介面	- 40 -
圖 4-13、輻射校正前(左)和後(右)影像對照(以 109 年成果為例).....	- 40 -
圖 4-14、輻射校正前(上)和後(下)數值轉換成果(以 109 年成果為例).-	41 -
圖 4-15、輻射校正後鄰近像元波譜圖(以 109 年成果為例).....	- 41 -
圖 4-16、高光譜率定流程.....	- 43 -
圖 4-17、台中率定場過往案例	- 43 -
圖 4-18、台中率定場 PBSbund 成果	- 44 -
圖 4-19、台中率定場高光譜航線圖	- 45 -
圖 4-20、台中率定場控制點與特徵點分布範圍	- 46 -
圖 4-21、正射糾正示意圖.....	- 49 -
圖 4-22、影像鑲嵌成果示意圖(以 109 年成果為例).....	- 50 -
圖 5-1、出雲山苗圃及大雪山森林遊樂區實驗區歷史影像示意圖	- 52 -
圖 5-2、阿里山森林遊樂區實驗區歷史航線分布圖	- 54 -

圖 5-3、阿里山歷史專案(A)歷史高光譜影像產製成果	57 -
圖 5-4、阿里山歷史專案(B)歷史高光譜影像產製成果	58 -
圖 5-5、阿里山歷史專案(C)歷史高光譜影像產製成果	58 -
圖 5-6、阿里山歷史專案(B)雲洞分布位置	59 -
圖 5-7、阿里山歷史專案(C)雲洞分布位置	59 -
圖 5-8、阿里山歷史專案高光譜影像測區範圍套疊	60 -
圖 5-9、阿里山歷史專案(A)(105 年)檢核點分布圖	64 -
圖 5-10、阿里山歷史專案(B)、(C)(107 年)檢核點分布圖	64 -
圖 5-11、出雲山苗圃 2 組地真資料分布	66 -
圖 5-12、阿里山森林遊樂區地真資料分布	66 -
圖 5-13、選定之出雲山苗圃實驗區樹種類別和範圍	68 -
圖 5-14、選定之阿里山森林遊樂區實驗區樹種類別和範圍	68 -
圖 6-1、透過資料空間轉換改變資料分布特性	70 -
圖 6-2、支持向量機分類示意圖	72 -
圖 6-3、結合小波與多核學習演算法於高光譜影像分類流程	74 -
圖 6-4、卷積神經網路基本架構圖(Rawat and Wang, 2017)	76 -
圖 6-5、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 6-6、適用於高光譜影像的 CNNs 基本架構圖(Li et al., 2018)	77 -
圖 6-7、適用於高光譜影像類的一維卷積神經網路架構(Hu et al., 2015)-	79 -
-	
圖 6-8、適用於高光譜影像類的二維卷積神經網路架構(Makantasis et al., 2015).....	79 -
圖 6-9、適用於高光譜影像類的三維卷積神經網路網路架構(Li et al., 2017).....	79 -
圖 6-10、遷移學習的基本概念(Yang et al., 2020).....	81 -
圖 6-11、針對卷積神經網路模型的遷移學習過程(Lemley et al., 2017)-	82 -
圖 6-12、多時期、不同區域高光譜影像之網路學習及分類策略	83 -
圖 7-1、出雲山苗圃實驗區兩時期實驗用影像	86 -
圖 7-2、出雲山苗圃實驗區目標區域	86 -

圖 7-3、出雲山苗圃實驗區影像不同樹種平均光譜曲線	90 -
圖 7-4、出雲山苗圃不同時期各樹種高光譜影像平均光譜曲線	91 -
圖 7-5、108 年度出雲山苗圃支持向量機(RBF 核函數)分類成果圖	96 -
圖 7-6、109 年度出雲山苗圃支持向量機(RBF 核函數)分類成果圖 ...	100 -
圖 7-7、一維卷積神經網路示意圖(修改自 Hu et al.,2015).....	102 -
圖 7-8、108 年度出雲山苗圃一維卷積神經網路分類成果圖	104 -
圖 7-9、109 年度出雲山苗圃一維卷積神經網路分類成果圖	106 -
圖 7-10、HybridSN 網路架構示意圖(Roy et al., 2020).....	108 -
圖 7-11、108 年度出雲山苗圃 HybridSN 神經網路分類成果圖	110 -
圖 7-12、109 年度出雲山苗圃 HybridSN 神經網路分類成果圖	111 -
圖 7-13、阿里山實驗區兩時期實驗用影像	113 -
圖 7-14、阿里山實驗區圈選之目標區域分布	113 -
圖 7-15、阿里山森林遊樂區實驗區影像不同樹種平均光譜曲線	115 -
圖 7-16、阿里山森林遊樂區不同時期各樹種高光譜影像平均光譜曲線	116 -
圖 7-17、105 年度阿里山影像支持向量機(RBF 核函數)分類成果	122 -
圖 7-18、107 年度阿里山影像支持向量機(RBF 核函數)分類成果	124 -
圖 7-19、一維卷積神經網路示意圖(修改自 Hu et al.,2015).....	125 -
圖 7-20、105 年度阿里山影像一維卷積神經網路分類成果圖	127 -
圖 7-21、107 年度阿里山影像一維卷積神經網路分類成果圖	129 -
圖 7-22、105 年度阿里山影像 HybridSN 神經網路分類成果圖	131 -
圖 7-23、109 年度出雲山苗圃一維卷積神經網路遷移學習分類成果	134 -
圖 7-24、107 年度阿里山森林遊樂區一維卷積神經網路遷移學習分類成 果	136 -
圖 7-25、多區域一維卷積神經網路遷移學習示意圖	138 -
圖 7-26、107 年度阿里山影像一維卷積神經網路遷移學習分類成果	139 -
圖 8-1、多時期高光譜影像自動化分類分析流程圖	145 -
圖 D-1、自行開發之實際高光譜影像分類使用者介面	190 -
圖 D-2、教育訓練簽到單.....	191 -

圖 D-3、教育訓練現場相片	- 192 -
----------------------	---------

表 目 錄

表 1-1、工作時程表(甘特圖).....	- 5 -
表 3-1、高光譜影像於森林研究文獻彙整表	- 21 -
表 3-2、高光譜影像於森林樹種分類文獻彙整表	- 22 -
表 4-1、機載高光譜儀規格.....	- 32 -
表 4-2、高光譜航拍作業系統設備明細	- 32 -
表 4-3、高光譜飛航記錄範例	- 39 -
表 4-4、本次率定所使用之內方位參數及幾何偏移參數	- 47 -
表 5-1、機載高光譜規格歷史影像資料	- 52 -
表 5-2、阿里山森林遊樂區實驗區歷史影像拍攝年份與月份	- 55 -
表 5-3、阿里山森林遊樂區實驗區歷史影像含雲量	- 55 -
表 5-4、阿里山歷史專案(A)航線列表	- 55 -
表 5-5、阿里山歷史專案(B)航線列表	- 56 -
表 5-6、阿里山歷史專案(C)航線列表	- 57 -
表 5-7、阿里山歷史專案(A)(105 年)精度檢核表	- 61 -
表 5-8、阿里山歷史專案(B)、(C)(107 年)檢核精度表	- 62 -
表 5-9、本計畫各實驗區選定之樹種	- 67 -
表 7-1、出雲山苗圃實驗區各類別之像元數	- 87 -
表 7-2、108 年度出雲山苗圃各類別間之類別分離度	- 89 -
表 7-3、109 年度出雲山苗圃各類別間之類別分離度	- 89 -
表 7-4、108 年度出雲山苗圃影像不同支持向量機之分類成果	- 94 -
表 7-5、108 年度出雲山苗圃支持向量機(RBF 核函數)分類成果	- 95 -
表 7-6、109 年度出雲山苗圃影像不同支持向量機之分類成果	- 98 -
表 7-7、109 年度出雲山苗圃支持向量機(RBF 核函數)分類成果	- 99 -
表 7-8、108 年度出雲山苗圃一維卷積神經網路分類成果	- 103 -
表 7-9、109 年度出雲山苗圃一維卷積神經網路分類成果	- 105 -
表 7-10、108 年度出雲山苗圃 HybridSN 神經網路分類成果	- 109 -
表 7-11、109 年度出雲山苗圃 HybridSN 神經網路分類成果	- 109 -

表 7-12、阿里山實驗區各類別之像元數	114 -
表 7-13、105 年度阿里山實驗區各類別間之類別分離度	118 -
表 7-14、107 年度阿里山實驗區各類別間之類別分離度	118 -
表 7-15、105 年度阿里山影像不同支持向量機之分類成果	120 -
表 7-16、105 年度阿里山影像支持向量機(RBF 核函數)分類成果	121 -
表 7-17、107 年度阿里山影像不同支持向量機之分類成果	123 -
表 7-18、107 年度阿里山影像支持向量機(RBF 核函數)分類成果	124 -
表 7-19、105 年度阿里山影像一維卷積神經網路分類成果	127 -
表 7-20、107 年度阿里山影像一維卷積神經網路分類成果	128 -
表 7-21、105 年度阿里山影像 HybridSN 神經網路分類成果	131 -
表 7-22、109 年度出雲山苗圃一維卷積神經網路遷移學習分類成果	133 -
表 7-23、107 年度阿里山一維卷積神經網路遷移學習分類成果	136 -
表 7-24、107 年度阿里山影像一維卷積神經網路遷移學習分類成果	139 -
表 D-1、教育訓練項目及時數分配	189 -
表 D-2、交付成果及繳交日期時程表	194 -

壹、前言

1.1、計畫名稱

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重要樹種調查之研究(2/2)」計畫（以下稱本計畫）。

1.2、計畫緣起

臺灣地處亞熱帶，森林分布超過國土面積之 60%以上，所涵蓋區域自平地至最高山區，其高差超過 3000 公尺以上，因此在森林組成上相較於其他國家複雜，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率與速度，曾委託相關學術單位研究及評估採航攝影像(aerial images)及衛星遙測影像(spaceborne remote sensing images)自動分類方法，如航照數位多光譜影像(airborne multispectral images)應用於林地分類研究(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)，然此類採傳統 4 波段或 8 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。

貴所於 108 年度辦理「應用高光譜航遙測影像於土地覆蓋型調查之研究」案（以下簡稱 108 年研究案），經初步利用高光譜影像(hyperspectral images, HSI)評估三類自動分類演算法（含特徵分類法、結合空間資訊的特徵分類法、以機器學習(machine learning, ML)為基礎的分類法等），不同分類演算法中另包含不同特徵萃取方法，以及各種參數調變，可組合為多種不同的分類程序，於實驗區之樹種辨識均有相當程度之分類準確度，其中位於平地區域之大農大富森林園區樹種分類準確度可達 90%以上。

受限於樣區範圍及樹種資料之不足，108 年研究案所獲得之演算法及成果尚無法直接應用於其他區域之高光譜影像。為儘量避免有限樣本與時間

對相關演算法之影響，及延伸高光譜影像在森林調查之可能應用，本計畫自 109 年度起，規劃針對臺灣山區進行多期高光譜影像之蒐集與自動分類演算法研究，除了持續優化 108 年研究案相關演算法成果外，並將目標設定於臺灣地區重要或特殊樹種之自動偵測及分類，同時，亦希藉由蒐集不同時期之高光譜影像，將不同物候在光譜上之表現差異因素納入考量，期能以一致的方法進行影像自動辨識及偵測，減少人為影像判釋主觀意識之影響，達到降低森林特定資源調查成本與風險之目的。

1.3、計畫目的

本計畫延續 109 年度研究之階段性成果，將基於以機器學習為基礎之分類法，在提升分類準確度的目標前提下，持續針對具地形因素之森林區域，進行不同樹種高光譜分類演算法之研究與擴展，藉由延伸機載高光譜影像及光達(LiDAR)資料蒐集之時間向度，將物候變化之影像差異因素納入考量，精進並發展適用於臺灣地區重要樹種偵測的自動演算法與流程。

110 年度工作除了相關研究文獻收集外，亦須進行歷史高光譜影像資料之蒐集，並就所獲得之多期高光譜影像進行相關分類演算法之驗證與改進，藉以掌握機器學習相關分類演算法在高光譜影像應用之可能極限及改良可行性，並提出後續應用建議，以為貴所後續引進高光譜掃描儀之發展基礎。

1.4、工作項目

本計畫相關工作包括「研究文獻收集」、「試驗資料獲取」、「提出多時期影像最適機器學習演算模式」、「建立多期高光譜影像應用於重要樹種偵測自動流程」及「教育訓練」等工作項目。說明如下：

一、研究文獻蒐集

- (一) 蒐集國內外應用衛載及機載高光譜影像於林業應用及樹種分類實際案例文獻。
- (二) 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。

二、試驗資料蒐集

(一) 歷史機載影像資料蒐集：

1. 參考台灣地區森林分布相關圖資與歷史機載高光譜影像挑選實驗區域，並蒐集該區域之歷史機載高光譜影像，應包含至少 2 個時期之高光譜影像，多時期影像重疊面積至少 25 平方公里，總涵蓋面積至少超過 100 平方公里。
2. 機載高光譜影像規劃之平均地元尺寸應達或優於 2 公尺。
3. 機載高光譜影像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，原始輻射解析度至少應達 12bits。
4. 光達資料取樣規格須符合試驗所需。
5. 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。

三、提出多時期影像最適機器學習演算模式

以 109 年研究案成果最佳之機器學習相關演算法為基礎，應用不同時期影像及光達資料，評估演算法、分類數、類別定義等不同組合及其對分類準確度之影響，找出最適之演算模式。

四、建立多期高光譜影像應用於重要樹種偵測自動流程

- (一) 評估適合不同時期高光譜影像於臺灣地區重要樹種於高光譜影像自動化偵測之演算法。
- (二) 建立適合不同時期高光譜影像於臺灣地區重要樹種於高光譜影像自動化偵測之流程。

五、教育訓練

包含進階航遙測影像及分類原理介紹，研究使用之自動化演算法、使用之軟體或工具、高光譜影像分類處理實作等課程。

1.5、計畫時程

本計畫之執行時程為 110 年 3 月 6 日(決標次日)至 110 年 12 月 17 日，共 287 個日曆天。表 1-1 為本專案工作時程表(甘特圖)，以下針對表中之查

核點及重要時間點進行說明：

一、重要查核點

- (1) 工作計畫書：自決標日次日起 20 個日曆天，即 110 年 3 月 25 日前繳交工作計畫書。
- (2) 修正後工作計畫書：於期初會議審查通過後限期內繳交修正後之工作計畫書。
- (3) 期中報告書：於 110 年 7 月 9 日繳交期中報告書。
- (4) 修正後期中報告書：於期中會議審核通過後限期內繳交修正後之期中報告書。
- (5) 期末報告書：於 110 年 11 月 12 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後限期內繳交修正後之期末報告書。
- (7) 成果交付：於 110 年 12 月 17 前繳交，包括成果報告書及外接式儲存裝置 1 份，後者含成果報告書電子檔、各期會議及工作會議之簡報檔、及本計畫試驗相關影像檔案、成果及其清單。

二、重要時間點

- (1) 第一次工作會議：已於 110 年 3 月 30 日召開。
- (2) 第二次工作會議：已於 110 年 7 月 5 日召開。
- (3) 第三次工作會議：已於 110 年 9 月 23 日召開
- (4) 教育訓練：已於 110 年 10 月 15 日及 10 月 22 日於農林航空測量所 201 會議室進行教育訓練。

表 1-1、工作時程表(甘特圖)

工作內容項目		110 03	110 04	110 05	110 06	110 07	110 08	110 09	110 10	110 11	110 12
1	撰寫及繳交工作計畫書	■	★3/25								
2	繳交修正後工作計畫書		■								
3	研究文獻收集	■	▲3/30	■							
4	歷史機載影像資料蒐集	■	■	■	■						
5	地真及其他研究測試資料蒐集	■	■	■	■	■					
6	發展多時期影像最適機器學習演算模式	■	■	■	■	■					
7	撰寫及繳交期中報告書				■	▲7/5					
8	繳交修正後期中報告書					■	★7/9				
9	建立多期高光譜影像應用於重要樹種偵測自動流程				■	■	■	▲9/23	■		
10	教育訓練						■	■	▲10/15		
11	撰寫及繳交期末報告書						■	■	▲10/22	■	
12	繳交成果報告書初稿									■	★11/12
13	成果交付										■
預定進度累積百分比(%)		10%	20%	30%	40%	50%	65%	75%	85%	95%	100%

備註：

1. 本計畫重要查核點如下(即表中標示為★者)：

- 工作計畫書：自決標日次日起 20 個日曆天(110 年 3 月 25 日)前繳交工作計畫書。
- 修正後工作計畫書：期初會議審查通過後限期內。
- 期中報告書：於 110 年 7 月 9 日前繳交期中報告書。
- 修正後期中報告書：期中會議審查通過後限期內。
- 期末報告書：於 110 年 11 月 12 日前繳交期末報告書。
- 成果報告書初稿：期末會議審查通過後限期內。
- 成果項目：於 110 年 12 月 17 日前繳交所有成果。

2. 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 110 年 3 月 30 日召開。
- 第二次工作會議：已於 110 年 7 月 5 日召開。
- 第三次工作會議：已於 110 年 9 月 23 日召開。
- 教育訓練：已於 110 年 10 月 15 日及 10 月 22 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

2.1、前期計畫成果

本團隊於 108 年度執行貴所「應用高光譜航遙測影像於土地覆蓋型調查之研究」案，針對花蓮大農大富平地森林園區及台中出雲山苗圃兩個實驗區蒐集衛載及機載高光譜影像，分別於 108 年 6 月 30 日和 7 月 13 日完成夏季機載高光譜影像取像作業，獲取 1 公尺地元尺寸之實驗區高光譜影像；研究中利用光譜特徵分類法、結合空間資訊的特徵分類法(基於物件的影像分析法)、及以機器學習為基礎的分類法等三類分類演算法，透過不同特徵萃取方法與不同的參數調變組合多種分類程序，進行上述兩個實驗區之高光譜影像分類，對於樹種辨識具有相當程度之分類準確度。其中光譜特徵分類法於出雲山苗圃實驗區及大農大富平地森林園區分別達到約 80%及 85% 的整體分類準確度(overall accuracy, OA)，基於物件的影像分析法雖然整體分類準確度較差於光譜特徵分類法，但可改善分類後的影像椒鹽現象(salt and pepper effect)，採用機器學習分類法更提升了分類成果的整體分類準確度，大農大富平地森林園區整體分類準確度可達 90%以上，沉香等部分樹種的分類準確度更可接近 100%，然該案的研究成果仍有部分提升空間。為了延續相關實驗區、樹種資料，以及研究現有演算法和成果，是否可以應用於其他區域或不同時間拍攝之高光譜影像，本計畫自 109 年度起，規劃針對臺灣山區進行多期高光譜影像之蒐集與自動分類演算法研究，除了持續優化原 108 年度研究案相關演算法外，並將目標設定於臺灣地區重要或特殊樹種之自動偵測及分類，同時於 109 年 10 月 28 日完成出雲山苗圃及大雪山森林遊樂區兩個實驗區之冬季機載高光譜影像與光達資料之取像作業，希望藉由蒐集不同時期之高光譜影像，將不同物候在光譜上之表現差異因素納入考量，期能以一致的方法進行影像自動辨識及偵測，減少人為影像判釋主觀意識之影響，達到降低森林特定資源調查成本與風險之目的。根據本計畫 109 年度之實驗結果，以機器學習方法的卷積神經網路(convolutional neural networks, 簡稱 ConvNet 或 CNNs)用於重要樹種調查偵測時，所需

要的處理流程最為簡化，適合建立自動化流程。

2.2、本年度執行方法與流程

根據本計畫之作業項目、內容以及上述之前期研究成果，規劃本年度之計畫執行流程如圖 2-1 所示，首先進行研究文獻蒐集，了解國內外高光譜相關研究及高光譜影像於林業應用及樹種分類之實際案例文獻，同時蒐集及彙整最新高光譜技術發展及資料處理演算法之研究文獻。在試驗資料收集方面，因國內唯一通過 CASI-1500h 高光譜儀適航認證之飛行器無法飛行，今年度改為蒐集阿里山森林遊樂園區及鄰近台 18 線沿線之歷史高光譜影像，選定範圍約 100 平方公里，其中約有 25 平方公里的面積範圍有至少 2 期歷史影像，並且於夏季和秋季不同季節拍攝，除了蒐集歷史高光譜影像外，同時須蒐集本計畫研究所需之其他測試資料及地真資料等。

在影像辨識演算法的發展方面，本年度以機器學習演算法為主，針對 108 年及 109 年研究案所提支持向量機(support vector machines, SVM)及深度學習(deep learning, DL)演算法進行改善及優化；同時針對多時期高光譜影像分析提出適用之機器學習演算模式，並根據試驗結果建立多期高光譜影像應用於樹種自動偵測之流程。除此之外，本計畫執行期間亦於 110 年 10 月完成 2 場次各 4 小時之教育訓練，教育訓練時程安排、現場照片如附件 D-1 所示，而本計畫成果交付之情形則如附件 D-2。以下章節說明本計畫的實施方法與目前之成果。




圖 2-1、本計畫執行流程

參、研究文獻蒐集

本章根據工作項目蒐集高光譜影像相關研究及應用文獻，其中高光譜影像特性與分析方法之文獻，包含高光譜影像特性、相關特徵萃取及分類演算法；林業應用及樹種分類之文獻則包含高光譜影像應用於森林分析、樹種分類的相關研究方法與成果，以及國內外公部門應用高光譜資料於森林相關之研究，簡單說明如下。

3.1、高光譜影像之特性與常見分析方法

高光譜影像由成像光譜儀（imaging spectrometer）拍攝而成，透過精密的光學技術，可將可見光、近紅外光、短波紅外光、中紅外光及其他光譜波長範圍切分為數十至數百個連續的光譜波段，每一波段區間通常約10nm (Goetz et al., 1985)，因為其狹窄且連續的波段資訊，即可以提供光譜變化的細節；成像光譜儀的成像示意圖如圖 3-1 所示，掃描目標後的反射光線透過分光鏡的分光技術，根據儀器設備或場景的不同，可能被分為數十或數百個波段，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），影像中的每一像元沿著波段軸向記錄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反應，形成該地物獨特的光譜反射曲線。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準確度（徐百輝，2003），近年亦有許多森林資源調查的相關文獻，提出高光譜影像所獲取的細微光譜變化可利於森林樹種的分類(Ballanti et al., 2016; Hycza et al., 2018)。

由於高光譜影像具有較高的光譜解析度，單一影像的波段數增加至數百波段，使得影像的資料量顯著增加，且每一波段區間連續且狹窄，不同波段間的光譜反射值具有高相關性，在光譜資料量增加的同時，並無等量增加影像分析所需的資訊，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 (Airborne Visible/Infrared Imaging Spectrometer) 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)為以灰階影像表示該高光譜影像之相關矩陣 (correlation matrix)，顯示出高光譜影像不同波段之間具有高冗餘量。而利用以傳統統計理論為基礎的影像分類方法時，也由於高光譜影像的高維度資料統計特性及有限的訓練樣本數之限制，無法直接適用於高光譜影像分類，即是無法正確估算類別的相關統計量，使得分類成果不可靠、準確度不佳，甚至無法分類的情形，通常將此問題稱為維度的詛咒 (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分轉換法 (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，我們稱此類方法為光譜特徵分類法。前述之光譜特徵分類法多是針對單一時期高光譜影像分類，Jiang et al. (2020)則是針對多時期的高光譜影像，分別萃取出各類別的光譜端元(spectral endmember)，之後利用光譜角映射法 (spectral angle mapping, SAM) 進行分類，而利用多時期之平均端元可以獲得較佳的分類成果。




圖 3-1、成像光譜儀之成像示意圖（徐百輝，2003）




圖 3-2、實際高光譜影像影像立方體與相關矩陣

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)。而隨著影像空間解析度的提升，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、粗糙度或規律性等做為特徵，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 (minimum noise fraction, 最小噪聲分離) 進行維度縮減後，再加入 Haralick et al. (1973)提出的紋理指標，引入物件的概念，先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高光譜影像的分類準確度。李庭誼 (2011)結合高光譜影像的光譜特徵及空間紋理特徵，建立以物件為基礎的分類流程，研究中利用小波光譜分解縮減高光譜影像的維度，將小波光譜特徵進行空間紋理分析，混合光譜與紋理特徵進行以物件為基礎的分類，實驗結果顯示結合光譜及紋理的以物件為基礎分類流程可以達到 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。

近年機器學習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, RF)、支持向量機、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、集群分析 (clustering analysis) 或資料迴歸(regression)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，資料的分布也不一定必須是常態分布，此點頗能符合實際的遙測影像資料分布狀況；相對而言，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)將機器學習方法運用於高光譜影像分類，包含了線性判別分析（linear discriminant analysis, LDA）及支持向量機等方法，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與計算量，其透過 AVIRIS 影像之實驗結果顯示以支持向量機的方法最佳。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 AVIRIS 影像分類實驗顯示採用小波-支持向量機的分類成果更佳。Jia et al. (2019)提出因地物的空間分布通常具有規則性及區域連續性，故結合 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，再利用主成分轉換法降低維度並利用支持向量機分類，在實際高光譜影像實驗中，其成果均有良好的表現。Chen et al. (2011)則是利用稀疏表示於高光譜影像分類，透過已知訓練樣本建構字典，並額外加入像元鄰近資訊於稀疏表示中，同時運用聯合稀疏模式（joint sparse model, JSM）整合空間資訊於高光譜影像分類中。近年受矚目的深度學習方法也被廣泛用於遙測影像分析中，其中卷積神經網路為有利於影像處理的架構；Hu et al.(2015)利用卷積神經網路建立一個 5 層之神經網路架構，其中將高光譜影像之光譜曲線採用一維卷積分析，已可以達到比支持向量機分類更好的分類準確度，且比其他深度學習網路有更佳的效率。若同時考量高光譜影像的空間資訊，可將影像切割為多個小區塊後，建構網路並學習，針對高光譜影像更可分別就光譜及空間特徵，同時進行學習網路的訓練 (Li et al., 2018)。

本計畫蒐集及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，並以文獻為基礎探討相關分類演算法的優化方式。

3.2、高光譜影像於森林樹種之分類

利用高光譜影像於森林資源調查其主要可以歸類兩個方向，其中一方是應用高光譜影像調查森林之葉綠素、含水量及氮含量，或是計算植生指標以及推求單一樹木生長情形等森林資源指標的相關議題探討，如 Cho et al. (2009)、Gholizadeh et al. (2016)是利用機載 HyMap 高光譜影像將不同光譜組合計算植生指標或計算 Red-Edge Position(REP)參數，以及利用迴歸分析等方法，分析森林資源的結構、特徵等調查森林資源。另一方向則是利用高光譜影像於農業或森林地物調查，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，以主成份分析與最小噪聲分離轉換做為影像融合的基礎，融合後以最大似然法進行森林、水體、建地和草地等地物分類，其結果顯示分類準確度可達到 93.82%。陳正杰 (2018) 利用 CASI 高光譜影像依據地面調查樹種資料，研究中將高光譜影像以最小噪聲分離轉換前處理降低資料維度並進行物件分割，再配合支持向量機分類法可達到最佳的地類分類成果，其整體分類準確度可達到 95.3%，Kappa 指標為 0.95。因高光譜影像技術發展，高光譜影像的空間和光譜解析度提升，近年有較多文獻針對高光譜影像於森林樹種分類的探討。

國外政府部門亦有使用高光譜影像於森林資源管理，加拿大自然資源部 (Natural Resources Canada) (2019)運用遙感探測技術於蒐集森林的資訊，利用不同波段的反射特徵調查森林資源與健康狀況，並可以進一步分析氣候變遷對於加拿大森林與生物多樣性的影響。其中就曾針對英屬哥倫比亞省 (British Columbia) 海岸區域利用衛載高光譜影像進行樹種分析，也利用機載高光譜影像針對樹冠層樹葉的葉綠素、含水量以及氮含量等進行調查。美國國家農業部森林局(Forest Service, U.S. DEPARTMENT of AGRICULTURE) (2021) 針對森林環境健康監測與保護建立的 The Forest Health Protection(FHP)任務，其中透過航空計畫 (aviation program) 進行森林疾病和昆蟲調查，並且以航測方法蒐集資料，以協助各州的森林健康監測，該團隊在 2014 年至 2018 年的政策規劃文件中提及，研發部

門透過蒐集各種遙測資料(含高光譜影像)並且用於森林的監測、分析以及森林火災監測，相關資料也會用於合作單位或是平台的建置展示中。Fricker et al. (2019) 利用機載高光譜影像配合現地調查資料利用卷積神經網路(CNNs)，針對內華達山脈南部的一處針葉混合林選擇 7 種針葉樹種及枯木進行分析；其中取 3 個代表紅、綠、藍的波段進行 CNNs 分類時，個別樹種的 F1-score 介於 0.65 到 0.87 之間，相較於利用高光譜影像結合光達資料於 CNNs 分析時，個別樹種的 F1-score 介於 0.67 到 0.95 間，有更好成果，同時該研究提出透過分類可以獲得更精細的樹種分布地圖，有助於森林環境的監測與管理。

NASA JPL 實驗室所新發展的 AVIRIS-NG(AVIRIS-Next Generation)(2021)，相較於原有 AVIRIS 感測器有較高的訊號-雜訊比，且有更細緻的光譜波段區間和較高的地元尺寸。印度太空研究組織(Indian Space Research Organization, ISRO)則與 NASA JPL 實驗室建立合作計畫(ISRO, 2017)，在 2015 年 12 月至 2016 年 3 月間利用 AVIRIS-NG 感測器在印度完成 57 個實驗區超過 22,840 平方公里資料蒐集，並整合地面觀測，處理成不同等級之高光譜影像資料，以應用於農作物、土壤、森林以及地質等不同領域之研究。該計畫在研究議題中，針對森林研究包含利用高光譜影像配合地面調查資料，透過計算生態歧異度與光譜角映射分類，產製森林樹種的分布地圖；以及利用高光譜影像於印度紅樹林的生態分析跟紅樹林樹種分類。Kumar et al.(2020)利用 AVIRIS-NG 高光譜影像分析印度西孟加拉邦落錫安島(Lothian Island)的熱帶濕地森林的紅樹林樹種，其研究方法是將原始 425 個光譜波段，透過波段縮減與特徵萃取後，利用支持向量機、光譜角映射和物件分類等方法用於 10 種紅樹林樹種分類，實驗結果顯示支持向量機的分類準確度為 99%，優於光譜角映射與物件分類法 70%和 67%的分類準確度，同時也計算植生指標，分析森林樹木的健康度，研究指出透過高解析度的高光譜影像可以更有效率地建置紅樹林樹種與健康度的分布地圖。Hati et al.(2021)同樣針對相同區域的紅樹林，分別利用 AVIRIS-NG 機載高光譜影像、Hyperion 衛載高光譜影像、Landsat 8 影像及 Sentinel-2 影像，配合樹種光譜資料庫的資訊，AVIRIS-

NG 高光譜資料特徵萃取後，以支持向量機進行分類，得到 87.61%的分類準確度，比 Hyperion(81.98%)、Landsat 8 (76.42%)及 Sentinel-2(79.81%)的成果佳，則該文獻提出利用 AVIRIS-NG 高光譜影像於複雜的紅樹林分析時，可以得到樹種層級的良好分類成果，同時在時間、成本上也更加有效率。

除了政府部門利用高光譜影像於森林資源調查或森林地物分類外，近年也有許多學術文獻針對高光譜影像於森林樹種分類的探討；George et al. (2014)利用 EO-1 Hyperion 影像分析印度喜馬拉雅西部的森林樹種，該研究中 Hyperion 影像經過前處理去除雜訊波段、FLAASH (Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes) 大氣校正和條紋雜訊改正，而後採用統計方法選取 29 個波段，再分別利用光譜角映射與支持向量機選取針葉及闊葉樹種 6 種進行分類，其結果顯示採用支持向量機的分類準確度為 82.27%，優於採用光譜角映射的分類準確度，另外也比較當採用 Landsat TM 影像進行分類，分類準確度只有 69.62%，該研究提出利用部分 Hyperion 影像即可有效進行森林樹種分辨之研究。Dian et al. (2015)利用機載 CASI-1500 高光譜影像，同時結合空間與光譜特徵進行分類，實驗區域為中國黑龍江省涼水自然保護區 (Liangshui National Natural Reserve)，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、雲做為類別進行分類，研究方法先利用最小噪聲分離轉換提取光譜特徵並降低資料維度，再以灰階共生矩陣 (GLCM) 計算紋理特徵，最後採用支持向量機分類，其中支持向量機利用線性核函數分類準確度達 85.92%為最佳，因此整合高光譜影像的光譜及空間特徵確實可提升樹種分類成果。Baldeck et al. (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，並且最後獲得目標樹種的位置，可有助於熱帶雨林多變的生態系統研究。Lim et al. (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；該研究中除了利用光譜資料，亦逐步加入地形和紋理資料，分別利用隨機森林、支持向量機等方法進行樹種分類，隨著加入的地形、紋理資訊增多，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%。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，以及將兩個實驗區域的訓練資料結合進行分析，隨機森林和支持向量機的分類準確度可以達到 99%及 97%，因此在該研究中可看出不同資料類型、特性及訓練資料的整合對於高光譜影像於樹種分類上的助益。Hycza et al. (2018)利用 AISA(Airborne Imaging Spectrometer for Application)機載高光譜影像針對波蘭北部的森林林分進行分析，其目標是分類出 7 種樹種，利用 192 波段全部波段影像、波段選取出 36 個波段，以及主成分轉換與最小噪聲分離轉換等不同資料組成，配合最大似然法、光譜角映射、類神經網路、支持向量機等 9 種不同資料分類方法，可以獲得最佳的成果為 90.3%的分類準確度，並且該研究提出高光譜影像對於森林主要樹種的分析有相當之幫助，同時提升時間效率，文章中也提到高光譜影像資料和分析軟體的取得仍需要較高的成本。

Ballanti et al. (2016)也利用高光譜影像進行樹種的分類分析，研究中分別利用支持向量機及隨機森林兩個分類演算法，配合最小噪聲分離轉換降低資料維度選定 27 個波段，再分割為物件進行分類，並且將訓練資料分別採用像元式訓練資料，或以物件式訓練資料進行測試，該文獻的研究區域為美國加州馬林郡(Marin County)的穆爾伍茲國家紀念森林(Muir Woods National Monument)，選定該區域主要樹種加州紅木(Coast Redwood)和北美黃杉(Douglas Fir)等 8 種樹種分類，其實驗成果顯示利用支持向量機或是隨機森林所得到的成果都可以得到 90%以上的分類準確度，兩個分類演算法於各類別的成果差異也不大；而採用像元式的訓練資料可以提供較多的光譜資訊，對於分類演算法較有幫助，特別是採用支持向量機分類時，物件式的訓練資料量較為不足，無法顯示森林地物的異質性，同時文獻中也指出雖然分類準確度評估結果良好，但分類圖的成果較

差，可能是檢核樣本不足或不具有代表性造成，此外陰影、太陽角度、坡度及航帶的差異，會使得同一樹種的光譜變異增加，並與其他樹種光譜重疊，造成分類錯誤。

亦有越來越多的文獻利用高光譜影像以卷積神經網路等深度學習方法於森林樹種分析；Zhang et al.(2020)蒐集中國廣西的高峰林場機載高光譜影像資料，利用三維卷積神經網路(3D CNN)進行 9 種樹種與其他地物之分類，可以得到 93.14%的分類準確度，分類後樹種分布的地圖可以提供做為森林資源調查的基礎。Mäyrä et al.(2021)同樣利用機載高光譜影像針對芬蘭一處森林中歐洲雲杉(Norway spruce)、樺木(birch)、歐洲赤松(scots pine)和歐洲山楊 (European aspen)等 4 種樹種，分別利用支持向量機、隨機森林、神經網路與三維卷積神經網路進行分類，以三維卷積神經網路可以獲得最好的分類準確度(87%)，其中經濟價值最高的歐洲山楊的 F1-score 為 0.91，比其他分類方法可以更有效率進行針葉樹種的分類，所獲得的樹種分布地圖可用於林業的永續性、生物多樣性保育之應用。

上述為本團隊彙整之高光譜影像於森林應用相關文獻，包括許多利用高光譜影像於森林樹種分類之研究，高光譜影像於森林研究及森林樹種分類之文獻彙整列於表 3-1 及表 3-2 中，同時可以看出文獻多以機器學習方法用於高光譜影像樹種分析，其中多以採用支持向量機可以獲得較佳的分類成果，而近期文獻的研究方法則多為採用深度學習方法中的卷積神經網路，與前期計畫採用機器學習方法可獲得較佳的成果相似，相關之文獻蒐集成果可做為本計畫高光譜資料分析與演算法優化的依據。

表 3-1、高光譜影像於森林研究文獻彙整表

應用面向	作者(年份)	研究目標	研究方法	成果
高光譜應用於樹木健康情形分析及森林資源管理	Cho et al. (2009)	利用高光譜影像分析森林資源的結構。	透過高光譜資料的波段資訊，計算不同的植生指標與 REP，並且利用偏最小二乘迴歸(Partial least squares regression, PLS)方法計算植生指標與樹木胸高直徑(DBH)的關係。	透過 PLS 迴歸分析，預測得到的樹木胸高直徑地圖可以有效用於森林資源管理。
	Gholizadeh et al. (2016)	利用 HyMap 高光譜影像與 Sentinel-2 計算 REP 並與傳統計算方法比較，以用於森林資源管理。	透過 HyMap 和 Sentinel-2 影像資料計算 REP 各項指標。	由機載高光譜影像和衛載多光譜影像計算得到的 REP 各項指標，具有用來估算葉綠素等資訊的潛力。
	印度太空研究組織(ISRO)(2017)	與 NASA JPL 實驗室合作，利用 AVIRIS-NG 感測器，或許印度各區域高光譜影像，應用於不同領域。	利用高光譜影像配合地面調查資料，透過計算生態歧異度與光譜角映射分類，產製森林樹種的分布地圖；以及紅樹林的生態分析。	
	加拿大自然資源部 (2019)	利用不同波段的反射特徵於森林資源與健康狀況的清查。	機載高光譜影像針對樹冠層樹葉葉綠素、含水量和氮含量等進行調查。	
	美國國家農業部森林局(2021)	蒐集高光譜影像用於森林健康監測、政策規劃。	利用遙測資料(含高光譜影像)用於森林健康或森林火災監測，並提供合作單位或展示平台使用。	
高光譜應用於地物分類分析	王驥魁等 (2012)	結合全波形光達及高光譜影像資料應用於地物分類。	以主成分分析與最小噪聲轉換做為影像融合的基礎，融合後以最大似然法進行森林、水體、建地和草地等地物分類。	分類準確度達到 93.82%；結合高光譜與全波形光達資料，可獲得高精度高光譜資訊並提升影像分類準確度。

表 3-2、高光譜影像於森林樹種分類文獻彙整表

應用 面向	作者(年份)	研究國家(區域)/研究目標	研究方法	成果
		高光譜影像種類	波段數/波長涵蓋範圍	地元尺寸
		分類方法	樹種對象	
高光 譜應 用於 森林 樹種 分類 分析	George et al. (2014)	(印度) 利用 Hyperion 影像分析喜馬拉雅西部的森林樹種。	Hyperion 影像經前處理後以統計方法選取 29 波段，分別利用光譜角映射、支持向量機針對 6 種針闊葉樹種分類。	採用支持向量機的分類準確度為 82.27%，優於採用光譜角映射，也比採用 Landsat TM 影像佳。
		衛載 EO-1 Hyperion	242 波段/357-2576 nm	30 公尺
		光譜角映射、支持向量機	6 種針闊葉樹種：Grey oak、Brown oak、Chir pine、Blue pine、Western Himalayan fir、Cedar	
	Baldeck et al. (2015)	(巴拿馬巴羅科羅拉多島) 以機載高光譜影像針對熱帶雨林樹種分析。	分別採用 binary 和 biased 兩種支持向量機針對熱帶雨林內 3 種樹種分類，並繪製樹種位置。	透過 biased 支持向量機可以獲得 94-97%分類準確度，並獲取目標樹種位置，有助熱帶雨林多變的生態系統研究。
		機載 CAO AToMS system-HiFIS	167 波段/380-2512 nm	1.12 公尺
		支持向量機	3 種樹種：D. panamensis、H. guayacan、J. copaia	
	Dian et al. (2015)	(中國黑龍江省) 利用 CASI-1500 高光譜影像分析黑龍江省自然保護區的森林樹種。	利用最小噪聲分離轉換提取光譜特徵並降維，再以 GLCM 計算紋理特徵，最後採用支持向量機進行 3 種針葉樹、2 種闊葉樹及其他地物分類。	支持向量機分類後準確度為 85.92%，整合高光譜影像的光譜與空間特徵，可提升樹種分類準確度。
		機載 CASI-1500	144 波段/350-1050 nm	1.5 公尺
		支持向量機	3 種針葉樹、2 種闊葉樹：fir、red pine、larch、birch、willow，其他地物：水	

			體、建物	
Ballanti et al. (2016)	(美國加州) 利用高光譜影像針對美國加州的穆爾伍茲國家紀念森林 8 種樹種分類。	透過最小噪聲分離轉換降低資料維度為 27 個波段，分別利用隨機森林及支持向量機進行分類，其中資料訓練的方式分別採用像元式和物件式分析。	根據實驗結果利用支持向量機或隨機森林都可以得到 90%分類準確度，採用像元式分析可以獲得較多光譜資訊，成果較佳，但容易受陰影、坡度等影響，造成分類圖成果較差。	
	機載 AISA Eagle	128 波段/397.78–997.96 nm	2 公尺	
	隨機森林、支持向量機	8 種樹種：Arroyo Willow、California Bay Laurel、California Buckeye、Coast Live Oak、Coast Redwood、Douglas Fir、Eucalyptus、Red Alder		
Hycza et al. (2018)	(波蘭) 利用 AISA 機載高光譜影像分析波蘭北部森林林分中 7 種樹種分類。	除利用 192 個全部波段，亦透過波段選取 36 波段、主成分轉換和最小噪聲分離轉換特徵萃取，並透過最大似然法、光譜角映射、類神經網路與支持向量機等 9 種分類方法。	採用較少特徵波段配合最大似然法分類可獲得最佳成果 90.3%的分類準確度，但文獻中提出以高光譜分析仍需要較高成本。	
	機載 AISA Eagle	129 波段/400-970 nm	1.5 公尺	
	平行分類法、最小距離法、馬氏距離法、最大似然法、光譜角映射、類神經網路與支持向量機等	7 種樹種：European beech、Birch、Oak、Hornbeam、European larch、Scots pine、Norway spruce		
陳正杰(2018)	(台灣) 利用 CASI 高光譜影像於台中鴻禧高爾夫球場及周圍山區的 4 種非植生與 18 種植生進行分類。	波段特徵萃取分別採用主成分轉換、最小噪聲分離轉換、獨立成分轉換，分類方法包含光譜角映射、光譜資訊散度(SID)與支持向量機，針對影像以像元式與物件式進行分類。	透過降低資料維度並以物件分割處理，有利於地類和樹種分類，其中最小噪聲分離轉換加上支持向量機可獲得最佳成果。	
	機載 CASI-1500	72 波段/368.8-1046.4 nm	1 公尺	

		光譜角映射、光譜訊息離散度(SID)、支持向量機、物件分類法	植生 18 種：草地、果嶺、大葉山欖、血桐、構樹、相思樹、小葉欖仁、樟樹、海欖果、中東海棗、茄苳、緬梔、黑板樹、印度紫檀、榕樹、龍眼、荔枝、竹子，非植生：建物、水體、道路、砂地	
	Lim et al. (2019)	(南韓江原道、中國長白山) 同時利用 Hyperion 高光譜與 Sentinel-2 多光譜資料針對 2 種針葉樹種分類。	研究依序利用光譜、地形和紋理資訊，分別以隨機森林和支持向量機進行紅松與日本落葉松 2 種樹種分類。	採用的特徵資訊越多可提升 5-6% 分類準確度，支持向量機分類準確度為 90%，並且結合多個實驗區域資料進行分析可以對研究樹種分類成果有所提升。
		衛載 EO-1 Hyperion	242 波段/357-2576 nm	30 公尺
		隨機森林、支持向量機	2 種樹種：Korean pine、Japanese larch	
	Fricker et al.(2019)	(美國) 利用機載高光譜影像針對內華達山脈南部的針葉混合林進行樹種分類。	以全部高光譜波段或 3 波段利用卷積神經網路進行 7 種針葉樹種和枯木進行分析。	採用全部高光譜波段資料可以獲得較佳的個別樹種分類成果，並建置樹種分布地圖。
		機載 NEON AOP	426 波段/280-2510 nm	1 公尺
		卷積神經網路	7 種針葉樹和枯木：White fir、Red fir、Incense cedar, Jeffrey pine、Sugar pine、Black oak、Lodgepole pine	
	Kumar et al. (2020)	(印度西孟加拉邦) 利用 AVIRIS-NG 高光譜影像分析印度西孟加拉邦落錫安島的熱帶濕地森林的紅樹林樹種。	將原始 425 個光譜波段透過波段縮減與特徵萃取後，利用支持向量機、光譜角映射和物件分類法等方法用於 10 種紅樹林樹種分類。	支持向量機分類準確度可達到 99%，同時計算植生指標分析森林樹木的健康度，可以更有效率地建置紅樹林樹種與健康度的分布地圖。
		機載 AVIRIS-NG	425 波段/376-2500 nm	5 公尺
		光譜角映射、支持向量機、物件分類法	10 種紅樹林樹種：Aegialitis rotundifolia、Aegialitis-Excoecaria mixed、Avicennia alba、Avicennia marina、Excoecaria agallocha、Phoenix paludosa、Phoenix-Avicennia-Excoecaria mixed、Marsh vegetation、Saline blank、Beach vegetation	

	Zhang et al. (2020)	(中國廣西省) 針對中國廣西的高峰林場機載高光譜影像資料，進行樹種分類分析。	利用三維卷積神經網路進行 9 種樹種與其他地物之分類。	可得到 93.14%的分類準確度，分類後樹種分布地圖可做為森林資源調查的基礎。
		機載 AISA Eagle II	125 波段/400-1000 nm	1 公尺
		三維卷積神經網路	9 種樹種：Cunninghamia lanceolata、Pinus massoniana、Pinus elliottii、Eucalyptus grandis x urophylla、Eucalyptus urophylla、Castanopsis hystrix、Mytilaria laosensis、Camellia oleifera 和其他闊葉樹，其他地物：道路、空地、建物	
	Hati et al. (2021)	(印度西孟加拉邦) 針對紅樹林區域，分別利用機載、衛載高光譜或多光譜影像，進行樹種分類分析。	配合樹種光譜資料庫的資訊，AVIRIS-NG 高光譜資料特徵萃取後，以支持向量機進行分類。	支持向量機分類可得到 87.61%的分類準確度，比其他資料類型佳。
		機載 AVIRIS-NG	425 波段/376-2500 nm	5 公尺
		支持向量機	實驗區中光譜資料庫共 24 種樹種。	
	Mäyrä et al. (2021)	(芬蘭) 利用機載高光譜影像針對芬蘭一處森林樹種進行分類。	針對 4 種針葉樹種，分別採用支持向量機、隨機森林、類神經網路與三維卷積神經網路為分類演算法。	三維卷積神經網路可以獲得最好的分類準確度(87%)，其中經濟價值最高的歐洲山楊的 F1-score 為 0.91，所獲得的樹種分布地圖可用於林業的永續性、生物多樣性保育之應用。
		機載 HySpex 1800 (VNIR)、HySpex 384 me (SWIR)	186 波段/406-995 nm、288 波段/956-2525 nm	0.5 公尺、1 公尺
		支持向量機、隨機森林、類神經網路、三維卷積神經網路	4 種樹種：Scots pine、Norway spruce、Birch、European aspen	

肆、試驗資料蒐集

本章 4.1 節說明本計畫選定的實驗區，延續 109 年研究案之出雲山苗圃實驗區和大雪山森林遊樂區實驗區，可將實驗區資料用於多時期和多區域分析，本年度試驗資料蒐集則為蒐集阿里山森林遊樂區鄰近區域之多時期歷史影像，並加入影像分析。現有出雲山苗圃與大雪山森林遊樂區機載高光譜影像、阿里山森林遊樂區鄰近區域的歷史影像蒐集成果，以及對應之地真資料將於第伍章進行說明，後續將利用各實驗區高光譜影像進行多時期和多區域的森林樹種分析。本章 4.2 至 4.3 節簡略說明本計畫所採用的歷史機載高光譜影像之飛航拍攝流程和高光譜影像產製方法。

4.1、機載高光譜影像實驗區說明

4.1.1、出雲山苗圃及大雪山森林遊樂區實驗區

本年度延續 109 年研究案之實驗區，包含出雲山苗圃及大雪山森林遊樂區實驗區，兩個區域面積分別約 25 平方公里，合計面積至少 50 平方公里，實驗區位置圖如圖 4-1 所示，其中底圖影像為 109 年所拍攝的實驗區高光譜影像自然彩色影像。出雲山苗圃實驗區高程約在 700 至 1000 公尺，實驗區的主要樹種包含臺灣肖楠、杉木、柳杉、臺灣杉、孟宗竹、臺灣檫、檜木等，其他則有小區塊的牛樟、烏心石、松、桂竹等，另有許多區塊無法歸納成單一樹種之闊葉樹林型；大雪山森林遊樂區實驗區高程則大約在 2000 至 3000 公尺，實驗區內的樹種主要為松樹、檜木、鐵杉、臺灣杉、香杉和赤楊等樹種。此兩實驗區於 108 年度與 109 年度進行機載高光譜影像拍攝，其中出雲山苗圃實驗區取得 108 年夏季和 109 年冬季高光譜影像，可進行多時期影像分析，而大雪山森林遊樂區實驗區則有 109 年度冬季影像，雖然僅有一期資料，該實驗區內仍有檜木、臺灣杉等樹種，可以用於多區域的高光譜資料分析；此外獲取高光譜影像時，亦同時蒐集光達點雲 (LiDAR point cloud) 資料，以獲取地形資訊做為高光譜影像幾何改正之用，詳細影像資訊將於 5.1 節進行說明。




圖 4-1、出雲山苗圃及大雪山森林遊樂區實驗區位置圖

4.1.2、阿里山森林遊樂區實驗區

本年度以蒐集多時期的歷史機載高光譜影像為替代方案，經過本團隊與貴所討論後，選定台 18 線沿線及阿里山森林遊樂區做為實驗區，區域範圍如圖 4-2 所示，此實驗區涵蓋範圍約 100 平方公里，高程約在 1200 至 2200 公尺，其中以阿里山森林遊樂區中阿里山火車站為中心的鄰近範圍，可蒐集 105 年夏季及 107 年秋季 2 個時期影像，阿里山森林遊樂區鄰近的重疊範圍約 25 平方公里。實驗區內主要的單一樹種林型為針葉樹的檜木與柳杉，其他則有少部分的松樹和杉木分布，以及小區塊的臺灣肖楠和臺灣櫟分布，且實驗區域包含台 18 線等道路沿線以及阿里山森林遊樂區主要設施區域，對於現地地真資料蒐集較容易抵達，選擇此實驗區除了有多時期歷史高光譜影像，且區域內樹種分布與 109 年研究案相似，除了可以進行多時期高光譜影像分析，亦可進行多區域的高光譜影像樹種分析，有助於研究之進行。詳細阿里山森林遊樂區實驗區歷史高光譜影像蒐集成果將於 5.2 節進行說明。




圖 4-2、阿里山森林遊樂區及台 18 線沿線實驗區位置圖

4.2、機載高光譜影像（含光達資料）獲取流程

本計畫中採用的前期計畫 108 年度高光譜影像和阿里山森林遊樂區歷史高光譜影像是採用 Itres CASI-1500 高光譜儀拍攝，前期計畫之 109 年度高光譜影像則是利用更新後高光譜儀 Itres CASI-1500h 拍攝，是同一儀器經過軟硬體之更新，因此報告書內以 Itres CASI-1500(h)高光譜儀做為說明，本節後續說明計畫中採用的機載高光譜影像獲取與產製流程。

4.2.1、飛航掃描儀器

本計畫中使用的實驗區高光譜影像均採用 Itres CASI-1500(h)高光譜儀拍攝，Itres CASI-1500(h)高光譜儀為成熟且廣泛使用之商用機載光譜儀，其規格如表 4-1 所示，其具有最高可達 288 波段之可記錄波段數，以及 380 至 1050 nm 之波長範圍，實際取像時量需搭配現地航高以及飛行航速之規劃，才能決定最終之波段數量，Itres CASI-1500(h)高光譜儀拍攝規格詳見附件 C-1。

Itres CASI-1500(h)高光譜儀屬於推帚式(pushbroom)掃描儀，其工作原理如圖 4-3 所示，沿飛機飛行方向一維是線性陣列紀錄像對應的一列地面影像，另一維則是光譜軸紀錄光譜值，感測器使用的二維 CCD 面陣列感測元件被分布在光譜儀的焦平面上，地面目標物的輻射能透過指向鏡，由物鏡蒐集並透過狹縫增強照射到散色元件上。在這種情況下，成像裝置測量橫向 m 個像元上逐像元 n 個波段上的輻射強度，因此掃描每一個地面網格有相應 n 個探測元件，面陣列式橫向寬度(m 個像元)由確定景寬的狹縫增強測定。掃描原理透過前快門在一定的曝光時間(滯留時間)內積聚輻射能，然後充足的輻射能很快地傳輸到移位暫存器，並讀取探測器陣列所截獲的地表輻射能。使用的光電探測器材料亦與線性方式相同，即可見光-近紅外(VNIR, 0.4~1.1 μm)區用矽片(CCD)，而短波紅外(SWIR)區則用汞-鎘-碲/CCD 混合元件。像元的攝像時間長，這樣系統的靈敏度和空間分辨率均可以得到提高。在可見光波段由於 CCD 元件材料技術成熟，集成程度高，光譜分辨率可以達到 1~2nm 量級。

拍攝高光譜影像時，亦同時蒐集光達點雲資料，以獲取地形資訊做為高光譜影像幾何改正之用，故搭配使用的機載光達儀為加拿大 Optech 公司 ALTM Pegasus 雷射掃描儀，雷射掃描系統結合雷射測距、光學掃描、衛星導航系統(GNSS)及慣性感測器(IMU)等技術，能快速獲得掃描點三維坐標及反射強度，其規格如圖 4-4 所列，雷射掃描系統硬體及數位相機規格詳見附件 C-2。表 4-2 為機載高光譜影像航拍作業系統資訊，包含雷射掃描系統硬體元件、飛行載台、衛星導航系統與慣性感測器元件，與數據處理軟體等整合構成一航拍作業系統。




圖 4-3、高光譜成像光譜儀概念(浦瑞良和宮鵬，2002)

機載光達 Optech ALTM Pegasus HA500	
	· 航高：離地高 150~5000 公尺 · 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,航高 1200 米 · 水平精度：1/7,500 航高 · 衛星導航系統：Trimble · 定位系統：POS AV™ AP50 (OEM) · 全波形：支援全波形記錄

圖 4-4、機載光達儀器規格

表 4-1、機載高光譜儀規格

項目	本團隊儀器規格	是否符合規範要求	CASI-1500h
光譜波長範圍(nm)	380~1050	是	
原始波段數	288	是	
頻寬(nm)	2.4	是	
原始輻射解析度(bit)	14	是	

表 4-2、高光譜航拍作業系統設備明細

用途	設備名稱	設備廠牌、型式	數量
機載設備	飛航載具(租用)	前進航空 B-23062、B-23063	2
	航空數位相機	PhaseOne iXU-RS1000	1
	定位及姿態系統	Applanix POSAV510	3
	機載光達掃描儀	Optech Pegasus HD400	1
		Optech Pegasus HA500	1
	全波形光達	Optech WF	1
	機載高光譜儀	CASI-1500h	1

4.2.2、飛航作業申請

執行影像拍攝飛航作業必須依照「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飛航掃描作業案，並依內政部審核成果，由航空公司於飛航掃描前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，也就是禁航區域進行飛航影像獲取任務，飛航作業申請流程示意圖如圖 4-5。



圖 4-5、飛航作業申請流程圖

4.2.3、掃描規劃

掃描事前規劃需考慮掃描區範圍、實施地區的高程、預定規劃的載體航高、掃描儀視角(field of view, FOV)、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。掃描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，量測區面積和分析測區地形特徵。
- (2) 決定航帶之間的重疊率(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率的調整，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、視角(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) 考量不同拍攝需求，如影像解析度、波譜寬度。
- (6) 參考光達掃描公式及以往豐富執行經驗，以規劃軟體試算設計參

數，規劃求出視角(FOV)、航高、雷射發射頻率、掃描頻率、航高、航向和航帶重疊率參數組合，確保點雲品質符合所需。在臺灣地區，一般實務高光譜影像作業將以離地高約 2000 m，視角為 40° 之掃描參數進行作業。

飛航操控人員因藉由定位及姿態系統的輔助，可直接於飛機上了解高光譜影像即時狀況，包含資料品質及影像重疊率等資訊，遇突發狀況時，能立刻決定是否補飛作業。

4.2.4、儀器裝機

經縝密飛航規劃後，飛行前須確保儀器裝置於載具上安全無誤，包括機載光達掃描儀和機載高光譜安置在攝影窗、控制組件安置於機艙座、衛星導航系統天線以及電力系統介面安裝等，參考圖 4-6，安裝完後必須由航空公司再次進行安全檢查，方可執行任務。



圖 4-6、機載光達和高光譜裝機現況

4.3、機載光達資料和機載高光譜影像處理流程

完成影像獲取後，將進行機載光達資料處理和高光譜影像產製。

4.3.1、機載光達資料處理流程

處理機載光達資料前處理作業包括原始資料整理備份、飛航掃描航跡 POS 解算及光達原始點雲產出。雷射掃描資料作業流程如圖 4-7 所示。




圖 4-7、機載光達資料作業流程

利用軌跡解算軟體將地面主站資料及機載光達系統的 GNSS 資料進行結合，過程中需輸入地面主站之坐標值，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光達掃描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衛星導航系統坐標結合於三維航跡上，求解出光達掃描時掃描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，如圖 4-8 所示。再將 Sbet 飛航軌跡資料，結合雷射掃描測距(掃描角與距離)，逐條航線求解原始點雲和影像，如圖 4-9 所示。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。

4.3.2、機載高光譜影像處理流程

高光譜資料獲取後則依照圖 4-10 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，包含飛航掃描檔案品管、輻射校正、正射糾正以及影像正射鑲嵌，以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 4-10、高光譜產製流程

一、飛航影像品管與飛航掃描參數與資料整理

於飛機上執行掃描時，需針對拍攝的高光譜影像進行初步的品管，已確定影像有接收到衛星定位系統訊號及影像資料品質為原廠建議無壞軌或破損紀錄等。機上操作人員可利用原廠 Quick look 軟體人工檢查每條掃描航帶，透過初步讀取影像掃描成果，檢查影像是否有大面積損壞或有突發狀況造成影像毀損，圖 4-11 為軟體檢查介面，可查看影像波段、影像明亮程度、以及快速查看影像的速度調整等初步功能。

完成高光譜影像飛航拍攝後須進行資料備份和資料建檔，建檔資料包含作業地點、飛行方向、飛行參數、高光譜航帶編號和順序等相關儀器設定之記錄資料，這些資料將於資料產製過程輸入對應欄位，也做為飛航記錄之封存，透過資料建檔及基礎品管後，飛航相關記錄表範例如表 4-3 所示，後續可輸出高光譜原始檔案進行產製流程。




圖 4-11、高光譜影像初步品管軟體

表 4-3、高光譜飛航記錄範例

日期	線路	地點	Tape Letter	開始時間	結束時間	飛行軌跡	方向	AGL(m)	Heading(deg.)	PDOP	G/S(航速)	SVs
2020/10/28		台中牽定	181354	1:12:23	1:15:40	6	→	1517	90	0.83	99	31
2020/10/28		農航所(-50316)-出雲山	182444	1:23:05	1:28:37	5	↑	2586	15	0.91	87	31
2020/10/28		農航所(-50316)-出雲山	183255	1:31:15	1:36:13	4	↓	2588	195	0.93	93	27
2020/10/28		農航所(-50316)-出雲山	184007	1:38:35	1:43:52	3	↑	2587	15	0.9	87	31
2020/10/28		農航所(-50316)-出雲山	184755	1:46:17	1:50:12	2	↓	2586	195	0.92	89	26
2020/10/28		農航所(-50316)-出雲山	185615	1:54:32	1:58:20	2短	↑	3042	15	0.94	93	28
2020/10/28		農航所(-50316)-出雲山	190623	2:05:46	2:10:49	10	↓	4257	195	1	90	26
2020/10/28		農航所(-50316)-出雲山	191425	2:12:49	2:17:24	7	↑	4259	15	0.99	89	27
2020/10/28		農航所(-50316)-出雲山	192131	2:19:56	2:24:42	6	↓	4257	195	0.97	89	26
2020/10/28		農航所(-50316)-出雲山	192805	2:26:32	2:31:05	9	↑	4254	15	0.97	91	26
2020/10/28		農航所(-50316)-出雲山	193457	2:33:19	2:38:16	8	↓	4256	195	0.99	93	26
2020/10/28		農航所(-50316)-出雲山	194303	2:41:25	2:47:36	11	→	2600	293	0.86	91	28
2020/10/28		農航所(-50316)-出雲山	195312	2:52:21	2:57:21	1	↓	2612	195	1.09	91	27

二、輻射校正(Radiometric Correction)

輻射校正是利用 Itres 公司原廠輻射轉換處理軟體(RCX)進行(如圖 4-12)，該軟體將取得原始高光譜影像檔(RAW 檔)後，將飛行儀器設定參數一併輸入，軟體會自動選擇原廠校正之輻射轉換檔，只需要選擇轉換校正的模式和輸出檔案設定即可完成輻射校正，並輸出成 PIX 檔，減少人為輸入造成之設定錯誤。校正後獲得原始航帶資料數位值(digital number Value, DN 值)影像轉換為輻射值(spectral radiance)影像，光譜輻射值的單位為 $\mu W \cdot cm^{-2} \cdot sr^{-1} \cdot nm^{-1}$ 。圖 4-13 為輻射校正前後的參考範例，圖中原始影像中因 CCD 結構造成的條紋，透過輻射校正後也會被改正消除，圖 4-14 則可以看出範例中，經過校正影像的輻射值單位變化。最後則需檢查校正後影像輻射值相同地物且相鄰像元的波譜，雖然波譜並未完全一致，但考量每個地物在不同大氣條件、光線和溼度等影響仍會有些許差異，波譜值相當接近，符合原廠建議的轉換成果，如圖 4-15 所示。此外，輻射校正後亦會產出記錄飛航資料的 ATT 檔，用於後續產製流程。




圖 4-12、輻射校正原廠軟體介面



圖 4-13、輻射校正前(左)和後(右)影像對照(以 109 年成果為例)




圖 4-14、輻射校正前(上)和後(下)數值轉換成果(以 109 年成果為例)




圖 4-15、輻射校正後鄰近像元波譜圖(以 109 年成果為例)

三、影像率定作業

高光譜影像率定作業主要目的是為了確定執行攝像任務時，高光譜相機參數(內方位與畸變參數)以及高光譜成像系統與 POS 系統(直接定向定位系統)之軸角與軸臂關係，以利後續利用影像進行高品質三維空間定位任務。為達至此一目標，需藉由一幾何率定場(geometric calibration site)來完成參數率定工作。

為降低相機參數與軸角軸臂參數之相互影響，率定作業採行兩階段式，率定流程(含相關檔案文件之需求)如圖 4-16 所示。首先，於率定場拍攝之影像中，藉由量測影像特徵點(做為連結點)及控制點並施以自率光束法，求算內方位與畸變參數；接著，透過 POS 系統提供影像線列外方位參數以及前項率得之相機參數，再一次施行自率光束法，不過此時率定之目標參數為軸角及軸臂參數。換句話說，率定程序包含兩步驟：先率定內方位及畸變參數後再率定軸角及軸臂參數。搭配 PBSbund 軟體進行光束法平差演算，在以一個像元為量測標準差以及提供支援正射影像物空間定位誤差小於 1 公尺之設想下，改正數大於 3 像元之像點觀測量會標註為錯誤（如圖 4-17 所示，該次率定作業中高光譜影像 1 個像元(pixel)對應之地元尺寸為 1 公尺），經剔除及重新平差，直至無任何觀測量改正數大於 3 個像元，同時，物空間由控制點提供之檢核 RMSE 小於 1 公尺(如圖 4-18)，在此品質下所獲致之率定參數提供後續高光譜影像物像對應相關任務使用。




圖 4-16、高光譜率定流程

PHOTO: CASI_2013_07_01_014939.pix (strip: NOSTRIP, No. 3, Index 24)

ID	TYPE CHANNEL	--- X --- (m)	--- Y --- (m)	--- Z --- (m)	-- rx -- (pix)	-- ry -- (pix)	Parallax (m)
03	GCP NAD	215888.311	2670669.112	97.464	0.376	0.743	
04	GCP NAD	215799.184	2670657.967	94.649	1.237	-0.661	
05	GCP NAD	215698.677	2670652.736	93.636	-1.089	-1.020	
12	GCP NAD	216119.804	2671843.869	107.936	-3.181*	1.562	
13	GCP NAD	215832.917	2671739.787	103.137	-1.989	1.447	
14	GCP NAD	215920.747	2671558.420	100.468	-0.676	0.580	
17	GCP NAD	215657.983	2671011.374	95.083	0.935	1.254	
24	GCP NAD	215788.039	2669726.697	83.649	1.985	1.209	
TP04	PAS NAD	215768.925	2671529.559	118.616	-0.545	0.824	
TP05	PAS NAD	215681.250	2671192.701	120.842	-1.571	1.424	
TP06	PAS NAD	215932.397	2669750.482	112.721	-1.563	-1.626	
TP07	PAS NAD	215919.017	2670064.101	111.659	-0.711	-0.870	
TP09	PAS NAD	215633.520	2670309.082	108.399	0.383	-0.291	
TP10	PAS NAD	215949.600	2670532.220	119.079	0.216	0.288	
TP102	PAS NAD	215919.137	2672438.297	145.128	-0.054	-0.104	
TP103	PAS NAD	215947.763	2672104.651	135.105	-0.060	-0.072	
TP104	PAS NAD	215705.310	2672428.547	134.392	-0.253	0.577	
TP11	PAS NAD	215940.568	2670329.776	127.262	-3.178*	-3.594*	
TP21	PAS NAD	215937.209	2671109.507	111.295	-0.509	0.246	
TP25	PAS NAD	215661.744	2671641.908	120.296	-0.992	1.227	
TP34	PAS NAD	215662.724	2672006.119	126.764	1.069	-1.247	
RMS					1.392	1.246	0.000

圖 4-17、台中率定場過往案例

PHOTO: CASI_2020_10_27_174254.cc.dc.sl.fss.so.rc.sc.rY.pix (strip: NOSTRIP, No. 1, Index 30)

ID	TYPE CHANNEL	--- X --- (m)	--- Y --- (m)	--- Z --- (m)	-- rx -- (pix)	-- ry -- (pix)	Parallax (m)
HS01	GCP NAD	216540.004	2670984.065	95.390	0.551	0.122	
HS02	GCP NAD	216538.829	2670969.253	95.654	-0.015	-0.150	
HS04	GCP NAD	215798.304	2670659.027	91.790	0.338	-0.844	
HS05	GCP NAD	215697.953	2670654.177	92.254	0.489	0.818	
HS06	GCP NAD	216298.220	2670439.049	89.534	-1.669	0.639	
HS09	GCP NAD	216218.823	2671821.688	102.134	1.508	-0.779	
HS10	GCP NAD	216173.549	2671851.125	103.571	-0.972	-0.526	
HS11	GCP NAD	216234.354	2671840.073	102.150	1.458	-0.992	
HS12	GCP NAD	216118.304	2671844.194	103.632	0.304	0.421	
HS17	GCP NAD	215657.655	2671012.214	91.900	-1.602	-0.260	
HS19	GCP NAD	216607.010	2671050.672	95.375	0.307	-0.788	
HS25	GCP NAD	216378.250	2669708.458	84.947	-1.567	-1.284	
TP05	TIE NAD	215679.796	2671192.425	101.123	-0.973	1.008	
TP06	TIE NAD	215933.817	2669751.093	108.664	0.198	-0.518	
TP07	TIE NAD	215918.389	2670063.164	90.643	0.182	-0.602	
TP08	TIE NAD	216072.240	2671156.703	97.401	-0.453	0.889	
TP09	TIE NAD	215635.749	2670309.109	100.903	0.000	-0.002	
TP11	TIE NAD	215941.984	2670328.714	93.186	-0.121	0.315	
TP12	TIE NAD	216418.395	2670786.570	103.974	0.134	0.209	
TP15	TIE NAD	216376.163	2670506.946	103.463	-0.211	0.210	
TP36	TIE NAD	216492.498	2670214.884	113.671	0.200	-0.952	
RMS					0.855	0.681	0.000

圖 4-18、台中率定場 PBSbund 成果

(1) 率定場規劃

本計畫 109 年度實驗區域為例，高光譜影像率定場為台中市區，率定場面積大小為 2 公里×1 公里，飛航日期為 109 年 10 月 28 日，中午 11 點開始進行飛航掃描作業，其中飛航高度與地元尺寸分別為 1200 公尺和 60 公分，一共 7 條航帶，南北向 5 條、東西向 2 條，航帶重疊率約 40%，掃描波段數為 72，其航帶分布範圍如圖 4-19。現地控制點與特徵點分布參考圖 4-20，一共布設 15 個地面控制點，並挑選 32 個特徵點進行率定作業。




圖 4-19、台中率定場高光譜航線圖




圖 4-20、台中率定場控制點與特徵點分布範圍

(2) 率定成果

根據前述幾何率定程序並於率定場所收集高光譜影像進行像點量測及光束法平差計算，獲致之內方位、軸臂與軸角參數請參考表4-4。

表 4-4、本次率定所使用之內方位參數及幾何偏移參數

內方位 參數	像主距(pixel)			像主點(pixel)*		
	-2092.862			751.141		
幾何偏 移參數	軸臂(level arms)參數			軸角(boresight angles)參數		
	X(m)	Y(m)	Z(m)	ω (deg)	ϕ (deg)	κ (deg)
	0.034	-0.067	0.037	0.549	0.263	0.221

註：線列式像主點位移只在線列方向，本次率定所拍攝高光譜影像地元尺寸為 60 公分，詳細儀器規格參數可參考附件 C-1。

四、GNSS 資料格式轉換及正射糾正

利用 Itres 原廠軟體讀取高光譜掃描儀掃描時之瞬間三維位置與姿態資訊(POS)的飛航軌跡資料(Sbet)，將 Sbet 檔紀錄格式轉換成後續 Itres 軟體中標準檔案格式(Sbet 轉換成.gps 檔案)，並將這些資訊轉換至 WGS84 坐標系統，轉換後提供正射糾正使用。

未經正射糾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，正射糾正前之影像為扭曲變形沒有正確方向和坐標，正射糾正後為一般常見之正確並具地理坐標之影像，圖 4-21 為正射糾正示意圖。而正射糾正需搭配機載光達產製之網格高程資料、影像外方位參數，針對所拍攝的影像作進行正射糾正，使影像具有絕對坐標資訊。最後利用 Itres 軟體產生程式(Geocor.exe)之批次執行檔案，執行後產製出之.pix 檔案即為正射糾正後影像檔案，單一航帶校正後為一條航帶的一張影像，而產出的影像地元尺寸則根據該飛行任務設定的需求和光達點雲解析度而定，以 109 年高光譜影像為例，任務規劃取得 1 公尺或優於 1 公尺地元尺寸之影像，且光達資料為 1 公尺網格高程資料，因此可產出 1 公尺地元尺寸的高光譜影像。




圖 4-21、正射糾正示意圖

五、影像正射鑲嵌

影像正射鑲嵌為將單條航帶正射影像拼接成同幅或同測區影像所需進行之步驟，通常可利用 Itres 軟體或目前市面常見影像軟體(ENVI、ArcGIS)進行影像鑲嵌工作，本計畫的歷史影像則是採用 ENVI 進行影像正射鑲嵌，產製鑲嵌後的圖幅資料，計畫中相鄰航帶重疊部分的高光譜影像鑲嵌沒有進行航帶之間光譜值內插，而是選擇主要航帶的光譜值填入鑲嵌影像，以減少對於分類的影響，鑲嵌後影像地元尺寸會與拍攝時需求規劃相同，以 109 年實驗區影像為例，其地元尺寸為 1 公尺，圖 4-22 為最後影像正射鑲嵌圖成果示意圖。





圖 4-22、影像鑲嵌成果示意圖(以 109 年成果為例)

伍、實驗區機載高光譜歷史影像

本章說明本計畫中現有的出雲山苗圃、大雪山森林遊樂區實驗區機載高光譜影像，及所蒐集的阿里山森林遊樂區實驗區歷史高光譜影像，並說明資料處理現況，並根據對應的森林樹種圖資說明地真資料的處理情形。

5.1、出雲山苗圃與大雪山森林遊樂區機載高光譜影像

本計畫應用前期計畫獲取之出雲山苗圃和大雪山森林遊樂區機載高光譜影像進行多時期和多區域的森林樹種分析。出雲山苗圃實驗區有夏季與冬季 2 期高光譜影像，分別於 108 年 6 月和 109 年 10 月拍攝，影像示意圖如圖 5-1(a)、(b)所示，表 5-1 則簡述影像之規格，在出雲山苗圃實驗區 2 期高光譜影像拍攝均 5 條航帶、波段數目為 96 波段、地元尺寸為 1 公尺，波長涵蓋範圍大約從 364.5nm 至 1054.8nm，兩期影像每一波段對應的波長則有些微差異，目前可將兩期光譜影像用於多時期分析。大雪山森林遊樂區實驗區影像則為 109 年 10 月所拍攝的冬季影像，影像示意圖如圖 5-1(c)，拍攝時亦採用 5 條航帶，並解算鑲嵌為整幅高光譜影像，因該實驗區的高程較高和高程變化限制，光譜波段數為 72 波段，同樣獲取 1 公尺地元尺寸之影像，而波長涵蓋範圍為 377.2nm 至 1053.6nm，如表 5-1 所示，大雪山森林遊樂區實驗區之資料則可用於多區域研究分析。



(a)108 年 6 月出雲山 苗圃實驗區 (b)109 年 10 月出雲山 苗圃實驗區 (c)109 年 10 月大雪山森林遊樂區實驗區

圖 5-1、出雲山苗圃及大雪山森林遊樂區實驗區歷史影像示意圖

表 5-1、機載高光譜規格歷史影像資料

影像資料	108 年 6 月出雲山苗圃實驗區	109 年 10 月出雲山苗圃實驗區	109 年 10 月大雪山森林遊樂區實驗區
航帶數目	5 條航帶	5 條航帶	5 條航帶
高光譜波段數	96 波段	96 波段	72 波段
地元尺寸	1 公尺	1 公尺	1 公尺
波長涵蓋範圍	364.5nm – 1042.6nm	376.0nm – 1054.8nm	377.2nm – 1053.6nm

5.2、阿里山森林遊樂區實驗區歷史高光譜影像與處理情形

本計畫已完成阿里山森林遊樂區及鄰近區域歷史機載高光譜影像原始影像蒐集、解算及產製高光譜正射影像。計畫中歷史機載高光譜影像為研究團隊中興測量有限公司於過去伴隨著空載光達相關專案一併獲取之影像，相關飛航參數如光達資料的點雲密度和重疊率，主要以歷史專案的需求為考量，本計畫利用歷史機載高光譜影像和光達資料產製高光譜正射影像。

歷史飛航任務中共有 3 次專案之影像涵蓋阿里山森林遊樂區實驗區，分別為曾文水庫空載光達掃描數值地形案、台 18 線 34K~96K 路段光達於公路邊坡掃描案、和 LiDAR 技術更新數值地形模型案，於本計畫中依序編列為阿里山歷史專案(A)、(B)、(C)，航線位置分布參考圖 5-2 所示，其中阿里山歷史專案(A)(曾文水庫空載光達掃描數值地形案)航線涵蓋了本計畫中阿里山森林遊樂區實驗區的大部分範圍(圖 5-2 中藍色航線)，而阿里山歷史專案(B)(台 18 線 34K~96K 路段光達於公路邊坡掃描案)航線主要分布於台 18 線(阿里山公路)沿線和阿里山森林遊樂區(圖 5-2 中黃色航線)，阿里山歷史專案(C)(LiDAR 技術更新數值地形模型案)則僅有較少航帶涵蓋本實驗區的右側(圖 5-2 中桃紅色航線)，航線拍攝時間可參考表 5-2。

表 5-4 至表 5-6，包含航線列表、航帶編號、實際飛航日期、航高、預計空間解析度與波段數所示，其中阿里山歷史專案(A)的高光譜影像拍攝時間為 105 年 4 月和 7 月，共有 9 條航帶，阿里山歷史專案(B)高光譜影像拍攝時間主要為 107 年 9 月、11 月，共有 26 條航帶，阿里山歷史專案(C)高光譜影像拍攝時間同樣為 107 年 9 月和 11 月，共有 7 條航帶，列表中主要為本實驗區所蒐集到的歷史高光譜影像原始資料，並且以本計畫的規範需求產製高光譜影像。

產製後的阿里山歷史高光譜影像如圖 5-3、圖 5-4、圖 5-5 所示；阿里山歷史專案(A)產製後的高光譜影像涵蓋面積為 118.41 平方公里；由表

5-4 可以看到專案(A)的實際航線獲取原始影像的地元尺寸為 1 至 1.5 公尺，其中又以 1 公尺地元尺寸之影像的航線數量較多，考量最佳解析度可用的影像面積較大，因此最終產製地元尺寸為 1 公尺的影像，且整個測區為無雲狀態(如圖 5-3)。阿里山歷史專案(B)產製後的高光譜影像涵蓋面積為 83.19 平方公里，地元尺寸為 1.5 公尺，含雲量約為 4.5%(如圖 5-4 和圖 5-6)。阿里山歷史專案(C)產製後的高光譜影像涵蓋面積為 32.91 平方公里，地元尺寸為 1.5 公尺，含雲量約為 1.5%(如圖 5-5 和圖 5-7)，詳細含雲量可參考表 5-3。而阿里山歷史高光譜影像的波段數皆為 72 個波段，波長涵蓋範圍為 365.7-1041.4nm，兩年期影像重疊大於 25 平方公里，符合規範，兩年期影像範圍套疊參考圖如圖 5-8 所示。




圖 5-2、阿里山森林遊樂區實驗區歷史航線分布圖

表 5-2、阿里山森林遊樂區實驗區歷史影像拍攝年份與月份

年份	月份	專案
105 年	4 月、7 月	曾文水庫空載光達掃描數值地形案
107 年	9 月	台 18 線 34K~96K 路段光達於公路邊坡掃描案
107 年	9 月、11 月	LiDAR 技術更新數值地形模型案

表 5-3、阿里山森林遊樂區實驗區歷史影像含雲量

年份	專案	測區面積(km ²)	雲洞(km ²)	含雲量(%)
107 年	台 18 線 34K~96K 路段光達於公路邊坡掃描案	83.19	3.75	4.5
107 年	LiDAR 技術更新數值地形模型案	32.91	0.49	1.5

表 5-4、阿里山歷史專案(A)航線列表

原專案名：曾文水庫空載光達掃描數值地形案								
航線 編號	地形 最高(m)	地形 最低(m)	離地高 (m)	航高 (m)	航速 (KTS)	重疊 帶寬(%)	波段數	地元尺寸 (m)
223334	2000	200	1500	2500	125	10	72	1
230437	2000	200	1500	2500	120	10	72	1
225016	2000	200	1500	2500	120	10	72	1
233642	2000	200	1500	2500	104	10	72	1
232021	2000	200	1500	2500	120	10	72	1
235406	2000	200	1500	2500	125	10	72	1
182102	2300	1800	2000	2800	105	10	72	1.5
184150	2300	1800	2000	2800	105	10	72	1.5
185109	2300	1800	2000	2800	107	10	72	1.5

表 5-5、阿里山歷史專案(B)航線列表

原專案名：台 18 線 34K~96K 路段光達於公路邊坡掃描案								
航線 編號	地形 最高(m)	地形 最低(m)	離地高 (m)	航高 (m)	航速 (KTS)	重疊 帶寬(%)	波段數	地元尺寸 (m)
111024	2000	900	1500	2996	95	56	72	1.5
112443	2000	900	1500	2996	93	56	72	1.5
113313	2000	900	1500	2998	97	56	72	1.5
111650	2000	900	1500	2997	101	56	72	1.5
110415	2000	900	1500	2995	93	56	72	1.5
110746	2000	900	1500	2990	101	56	72	1.5
110023	2000	900	1500	2997	99	56	72	1.5
111354	2000	900	1500	2988	91	56	72	1.5
112619	2400	1300	1500	2991	89	無	72	1.5
115510	2500	1600	900	3005	109	50	72	1.5
120426	2500	1600	900	3004	99	50	72	1.5
121349	2500	1600	900	3001	101	50	72	1.5
114958	2000	1240	1000	2809	97	55	72	1.5
113859	2000	1240	1000	2808	95	55	72	1.5
112815	2000	1240	1000	2806	95	55	72	1.5
111746	2000	1240	1000	2804	95	55	72	1.5
114429	2000	1240	1000	2807	93	55	72	1.5
113345	2000	1240	1000	2807	97	55	72	1.5
112256	2000	1240	1000	2804	91	55	72	1.5
111214	2000	1240	1000	2805	97	55	72	1.5
121828	2500	1600	900	3003	99	50	72	1.5
120009	2500	1600	900	3002	103	50	72	1.5
112842	2500	1600	2100	2995	103	50	72	1.5
113344	2500	1600	2100	2996	103	50	72	1.5
124411	2000	1240	1000	3201	93	55	72	1.5
123818	2000	1240	1000	3202	105	55	72	1.5

表 5-6、阿里山歷史專案(C)航線列表

原專案名：LiDAR 技術更新數值地形模型案								
航線編號	地形最高(m)	地形最低(m)	離地高(m)	航高(m)	航速(KTS)	重疊帶寬(%)	波段數	地元尺寸(m)
122738	2000	400	1900	2994	95	65	72	1.5
125058	2100	760	2100	3197	105	70	72	1.5
132848	2100	760	2100	3201	86	70	72	1.5
131641	2100	760	2100	3197	105	70	72	1.5
130231	2100	760	2100	3201	87	70	72	1.5
21527	2000	400	1900	3000	107	70	72	1.5
22805	2000	400	1900	2999	99	70	72	1.5




圖 5-3、阿里山歷史專案(A)歷史高光譜影像產製成果




圖 5-4、阿里山歷史專案(B)歷史高光譜影像產製成果




圖 5-5、阿里山歷史專案(C)歷史高光譜影像產製成果




圖 5-6、阿里山歷史專案(B)雲洞分布位置




圖 5-7、阿里山歷史專案(C)雲洞分布位置




圖 5-8、阿里山歷史專案高光譜影像測區範圍套疊

為了確定歷史高光譜影像正射糾正後的成果，初步針對測區範圍內及測區附近點選檢核點，利用 1 公尺高光譜影像與 25 公分航拍正射影像進行檢核，挑選容易辨識之地物交界處，並且避開建築物的角點，參考表 5-7 和表 5-8。檢核點分布如圖 5-9 和圖 5-10 所示，檢核精度成果高光譜影像與航拍正射影像差量約略差 1-2 公尺內，大約是 1-2 個像元，根據過往經驗像元差量落在 1-2 公尺內為正常情況。

精度檢核除了以檢核點單點差量質評估，也使用常見的均方根誤差 (root mean square error, RMSE) 和平均絕對誤差 (mean absolute error, MAE) 兩項統計值進行評估，其公式如式(5-1)和式(5-2)所示：

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (X_i - X'_i)^2} \quad (5-1)$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |X_i - X'_i| \quad (5-2)$$

其中， m 為觀測量個數， X_i 和 X'_i 分別為第 i 個觀測量參考值與第 i 個觀測值，此處則分別代表航拍影像坐標值與高光譜影像坐標值。RMSE 是觀測值與真值差量的平方和取平均後的平方根。對同一物理量進行多次測量時，各次測量值及其絕對誤差不會相同，將各次測量的絕對誤差取絕對值後再求平均值，並稱其為平均絕對誤差。與平均誤差相比，平均絕對誤差由於誤差被絕對值化，不會出現正負相抵消的情況，結合 MAE 及 RMSE 有助於誤差量級及變化之分析，倘 MAE 與 RMSE 之差異越大，代表誤差之變異越大，這當中也可能隱含有較大的誤差偏差量(即粗差)。

表 5-7、阿里山歷史專案(A)(105 年)精度檢核表

檢核點 編號	高光譜影像坐標		航拍影像坐標		差量	
	E(m)	N(m)	E(m)	N(m)	E(m)	N(m)
1	231880	2600995	231881.28	2600994.40	-1.28	0.60
2	224576	2594943	224574.07	2594943.34	1.93	-0.34
3	219632	2597363	219631.09	2597366.43	0.91	-3.43
4	220342	2596291	220340.50	2596289.58	1.50	1.42
5	215284	2592255	215285.61	2592254.29	-1.61	0.71
6	226273	2595134	226271.85	2595132.29	1.15	1.71
7	219063	2596025	219065.49	2596023.46	-2.49	1.54
8	227208	2595049	227209.88	2595046.56	-1.88	2.44
9	215541	2591757	215542.88	2591757.01	-1.88	-0.01
10	224411	2593058	224410.16	2593057.34	0.84	0.66
MAE					1.55	1.29
RMSE					1.62	1.63

表 5-8、阿里山歷史專案(B)、(C)(107 年)檢核精度表

檢核點 編號	高光譜影像坐標		航拍影像坐標		差量	
	E(m)	N(m)	E(m)	N(m)	E(m)	N(m)
111024_1	219127.5	2595696.0	219126.95	2595695.55	-0.55	-0.45
111024_2	219169.5	2595655.5	219169.24	2595655.72	-0.26	0.22
112443_1	224952.0	2598813.0	224951.43	2598812.70	-0.57	-0.3
112443_2	220402.5	2595916.5	220402.97	2595917.27	0.47	0.77
113313_1	220339.5	2595186.0	220339.74	2595186.05	0.24	0.05
113313_2	220630.5	2595441.0	220630.73	2595441.51	0.23	0.5
111650_1	226618.5	2597379.0	226618.49	2597379.52	-0.01	0.52
110415_1	226575.0	2597356.5	226575.49	2597355.51	0.48	-0.99
110415_2	226912.5	2597167.5	226912.00	2597168.04	-0.5	0.54
110746_1	219810.0	2598307.5	219810.03	2598307.53	0.03	0.03
110746_2	219553.5	2597854.5	219553.61	2597854.18	0.11	-0.32
110023_1	219975.0	2596861.5	219973.50	2596861.51	-1.5	0.01
110023_2	219369.0	2596395.0	219369.74	2596394.80	0.74	-0.2
111354_1	220485.0	2597670.0	220484.74	2597670.51	-0.26	0.51
111354_2	219370.5	2596393.5	219369.78	2596394.85	-0.72	1.35
112619_1	225331.5	2595558.0	225331.30	2595556.50	-0.2	-1.5
112619_2	225165.0	2595435.0	225164.75	2595435.50	-0.25	0.5
115510_1	230425.5	2601480.0	230424.30	2601480.24	-1.2	0.24
115510_2	230635.5	2601672.0	230634.64	2601671.54	-0.86	-0.46
120426_1	229972.5	2600173.5	229971.71	2600171.86	-0.79	-1.64
120426_2	230424.0	2601480.0	230424.22	2601480.23	0.22	0.23
121349_1	229917.0	2600752.5	229917.14	2600754.21	0.14	1.71
121349_2	229954.5	2600796.0	229954.75	2600798.02	0.25	2.02
112815_1	227910.0	2601121.5	227908.58	2601120.74	-1.42	-0.76
111746_1	227898.0	2601114.0	227898.50	2601112.50	0.5	-1.5
111746_2	227884.5	2601064.5	227885.02	2601063.85	0.52	-0.65
114429_1	227173.5	2595019.5	227172.75	2595021.53	-0.76	2.03
113345_1	227002.5	2596821.0	227002.49	2596820.01	-0.01	-0.99
113345_2	227050.5	2596833.0	227050.24	2596833.45	-0.26	0.45
112256_1	226924.5	2596821.0	226925.60	2596821.35	1.1	0.35
112256_2	227050.5	2596833.0	227050.24	2596833.45	-0.26	0.45
111214_1	226795.5	2597203.5	226795.24	2597202.98	-0.26	-0.52
111214_2	226485.0	2596573.5	226486.23	2596573.56	1.23	0.06
121828_1	233407.5	2600314.5	233406.00	2600315.16	-1.5	0.66

121828_2	233227.5	2600335.5	233227.54	2600337.22	0.04	1.72
120009_1	234036.0	2600470.5	234035.08	2600469.90	-0.92	-0.6
120009_2	233824.5	2600449.5	233824.58	2600446.83	0.08	-2.67
123818_1	230781.0	2601187.5	230781.73	2601186.81	0.73	-0.69
123818_2	230907.0	2601214.5	230905.72	2601213.54	-1.28	-0.96
122738_1	222777.26	2596606.229	222777.00	2596605.00	0.26	1.229
122738_2	222874.074	2591510.999	222874.50	2591511.00	-0.426	-0.001
125058_1	224976.241	2598692.779	224976.00	2598693.00	0.241	-0.221
125058_2	225169.256	2595438.992	225168.00	2595438.00	1.256	0.992
132848_1	224585.311	2594979.974	224586.00	2594982.00	-0.689	-2.026
132848_2	224421.244	2594995.916	224421.00	2595000.00	0.244	-4.084
131641_1	224349.99	2594619.286	224349.00	2594620.50	0.99	-1.214
131641_2	224393.03	2580149.528	224394.00	2580150.00	-0.97	-0.472
130231_1	223645.578	2601094.578	223647.00	2601094.50	-1.422	0.078
130231_2	223711.997	2599077.511	223713.00	2599077.00	-1.003	0.511
21527_1	222575.674	2596647.405	222576.00	2596647.00	-0.326	0.405
21527_2	222446.223	2595993.672	222445.50	2595994.50	0.723	-0.828
22805_1	221807.258	2595378.595	221806.50	2595378.00	0.758	0.595
MAE					0.59	0.82
RMSE					0.70	1.10




圖 5-9、阿里山歷史專案(A)(105 年)檢核點分布圖




圖 5-10、阿里山歷史專案(B)、(C)(107 年)檢核點分布圖

5.3、實驗區地真資料蒐集與處理

本計畫中後續實驗選定出雲山苗圃和阿里山森林遊樂區與其周邊區域具有多時期影像之區域做為實驗影像，為了在高光譜影像分類分析有更精確的訓練資料，因此需針對地真資料重新彙整並確認正確性，以下針對個別實驗區的現有地真資料進行說明：

1. 出雲山苗圃：本實驗區由貴所提供了 2 組地真資料，包含 109 年度 4 月現地調查資料，所調查到的主要樹種包含臺灣肖楠、杉木、柳杉、臺灣杉、孟宗竹、臺灣櫟、檜木等，其他則有小區塊的牛樟、烏心石、松、桂竹等，另有許多區塊無法歸納成單一樹種之闊葉樹林型；另一組地真資料則為貴所提供以第四次森林資源調查成果(行政院農業委員會林務局，2015)為基礎，並由貴所同仁於 108 年度時，配合 106 年正射影像編輯修改後，獲得更新的地真資料分布，主要選擇單一林型進行分析，包含針葉樹林型的檜木、臺灣肖楠、杉木、臺灣杉和柳杉，而闊葉樹林型則有小區塊的台灣櫟，其他多為混合的闊葉樹林型，於 109 年研究案已針對地真資料檢查比對，後續更可用於現地資料蒐集之參考，2 組原始地真資料分布如圖 5-11 所示。
2. 阿里山森林遊樂區及鄰近區域：本實驗區同樣以貴所提供第四次森林資源調查之成果為主，如圖 5-12 為阿里山實驗區的純針葉樹林型和純闊葉樹林型之分布圖，實驗區內主要的純林型樹種為針葉樹的檜木、柳杉，其他則有少部分的杉木和臺灣杉分布，以及小區塊的臺灣肖楠、臺灣櫟分布，與出雲山苗圃實驗區所選定的樹種類別相當一致。



(a)109 年度現地調查地真資料

(b)108 年度更新之地真資料

圖 5-11、出雲山苗圃 2 組地真資料分布




圖 5-12、阿里山森林遊樂區地真資料分布

本計畫中地真資料則會進行彙整更新，當有 2 組以上之地真資料，則會將 2 組地真資料比較區塊範圍的變化，以及重疊區域是否有樹種的變化，同時比對航照正射影像與機載高光譜影像，以確認是否有明顯的地物變化，如樹林遭砍除或是森林樹木紋理有明顯差異，如有混淆無法確定之區域，可透過航測立體像對，由貴所的同仁協助重新確認，地真資料透過多種來源與確認方式，可以針對圖資中混淆無法確定的區域進行確認，讓地真資料更加準確與完整，以利於後續高光譜影像於重要樹種調查分析。

出雲山苗圃實驗區的地真資料已於前期計畫完成彙整，最後選定的地真資料類別和分布如圖 5-13 所示，阿里山森林遊樂區實驗區經過航照正射影像與機載高光譜影像確認，並排除部分錯誤資料、範圍過小及樹種混合的區域，最後選定的地真類別和分布如圖 5-14 所示，已選定的各實驗區樹種類別如表 5-9 所示。

表 5-9、本計畫各實驗區選定之樹種

出雲山苗圃			阿里山森林遊樂區		
編號	樹種	林型	編號	樹種	林型
1	檜木	針葉	1	檜木	針葉
2	臺灣肖楠	針葉	2	臺灣肖楠	針葉
3	杉木	針葉	3	杉木	針葉
4	柳杉	針葉	4	柳杉	針葉
5	臺灣杉	針葉	5	臺灣杉	針葉
6	臺灣櫟	闊葉	6	松樹	針葉




圖 5-13、選定之出雲山苗圃實驗區樹種類別和範圍




圖 5-14、選定之阿里山森林遊樂區實驗區樹種類別和範圍

陸、提出多時期影像最適機器學習演算模式

根據 108 年度「應用高光譜航遙測影像於土地覆蓋型調查之研究」案之執行成果，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

本團隊於前兩年度研究案中已完成了上述三類高光譜影像分類演算法之理論彙整及程式軟體之優化，並實際將各種分類演算法應用於出雲山苗圃實驗區高光譜影像分類。此外，根據 109 研究案之實驗成果，機器學習演算法對於本計畫相關實驗區樹種分類具有較佳的分類成果，因此本年度持續針對機器學習演算法中的核方法(kernel method)及深度學習演算法進行改善及優化。此外，本計畫亦針對多時期和區域高光譜影像，評估其適用之演算法，同時針對分類數、類別定義等不同組合及其對分類準確度之影響，找出最適之演算模式。

6.1、機器學習演算法改善及優化

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。本計畫主要著重在核方法(kernel-based method)與深度學習演算法，進行其應用於高光譜影像分類之效能評估。

6.1.1、核方法與改善

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(6-1))，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，再進行內積計算，將其簡化以解決問題，如圖 6-1 為核方法將資料透過轉換使資料分布簡化，以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。




圖 6-1、透過資料空間轉換改變資料分布特性

$$K(\mathbf{x}, \mathbf{x}') = \langle \phi(\mathbf{x}), \phi(\mathbf{x}') \rangle \quad (6-1)$$

核函數(式(6-1))之關鍵在於映射函數 $\phi(\mathbf{x})$ 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($\langle, \rangle$)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)，當 $\mathbf{x}$ 為已知的資料向量，即支持向量， $\mathbf{z}$ 為待求解的資料向量，可表示為：

(一) 線性 (linear kernel)：

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

(二) 多項式 (polynomial kernel)：

$$K(\mathbf{x}, \mathbf{z}) = (\langle \mathbf{x}, \mathbf{z} \rangle + C)^d, d \in \mathbb{Z}^+ \quad (6-3)$$

(三) 輻狀基底函數 (radial basis function)：

$$K(\mathbf{x}, \mathbf{z}) = \exp(-\|\mathbf{x} - \mathbf{z}\|^2 / 2\sigma^2), \sigma \in \mathbb{R}^+ \quad (6-4)$$

其中，線性核函數即是兩個資料向量內積計算，而多項式核函數為資料向量組成多項式，如式(6-3)，其中 C 為截距、 d 為項次，同時 d 為正整數，輻狀基底函數為高斯函數的形式，如式(6-4)， σ 為自由參數，但須為正實數。

支持向量機是以統計學習理論為基礎的監督式分類方法(Cortes and Vapnik, 1995)，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 6-2 所示，透過找出決策超平面 (decision hyperplane) 且使得類別的支持超平面 (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) 為

$$y_i = f(x) = w^T x_i + b = \sum_i \alpha_i y_i x_i^T x_j + b \quad (6-5)$$

其中， x_i 為未知類別資料向量，其類別表示為 y_i ， x_j 為支持向量， w 和 b 為決策函數的斜率與截距， w 和 b 的值是由支持向量來決定的，而 $w = \sum_i \alpha_i y_i x_i$ ，其中 α_i 為每一特徵項對應的係數。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，再進行內積運算，形成核函數的形式 (如式(6-5))，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 6-2、支持向量機分類示意圖

在核方法的改善方面，本年度仍以支持向量機為主，透過多核學習演算法（multiple kernel learning, MKL）將多個核函數組合，同時考量不同核函數的特徵，整合不同核函數的優點，於高光譜影像分類上更有效且獲取更佳的成果(Gönen and Alpaydm, 2011)。多核學習法的基本演算公式可以表示為：

$$k_{\eta}(\mathbf{x}_i, \mathbf{x}_j) = f_{\eta} \left(\{k_m(\mathbf{x}_i^m, \mathbf{x}_j^m)\}_{m=1}^P | \eta \right) \quad (6-6)$$

其中， f_{η} 為核函數整合的函式， k_m 為採用的核函數， η 為整合核函數所加入的參數項， m 為資料的維度， P 為核函數的個數，則多核函數則是將 P 個核函數，以選定的數學關係整合，其中可能包含 η 個參數。而常見的多核學習演算方式是先選定核函數以及其中對應的相關參數，再透過學習訓練的方式找出最佳的參數解與組合方式。若將多個核函數以線性方式組合，用於支持向量機求最佳解，使類別邊界的距離最大，決策函數可以表示為：

$$f(x) = \sum_{m=1}^P \eta_m k_m(\mathbf{x}_i^m, \mathbf{x}_j^m) + b = \sum_i \alpha_i y_i \left(\sum_{m=1}^P \eta_m k_m(\mathbf{x}_i^m, \mathbf{x}_j^m) \right) + b \quad (6-7)$$

與式(6-5)的形式項同， $\mathbf{x}_i$ 為未知類別資料向量，其類別表示為 y_i ， $\mathbf{x}_j$ 為支

持向量， b 為截距由支持向量決定， α_i 為每一特徵項對應的係數， η_m 為不同核函數的係數。

多核學習法中為了在計算效率和分類準確度之間取得平衡，如何選擇具有代表性的核函數即是一個重要的課題。Cristianini et al.(2002)提出利用計算矩陣之間相似性的指標 kernel alignment (KA)，計算核函數矩陣之間的相似性，找出有利於分類的核函數。因此，當有一組訓練資料為 $\{x_i, y_i\}, i = 1, 2, \dots, N$ ，其中， $x_i \in R^d$ ，每一筆訓練資料會有對應的類別 $y_i \in \{1, -1\}$ ，訓練資料的屬性 x_i 可以組成核函數矩陣 K ，其類別標籤 y_i 可以組成 ideal kernel，即 $K_{ideal} = yy^T$ ，則可以利用下列公式計算核函數矩陣 K 與 K_{ideal} 之間的相似性：

$$A(K_{ideal}, K) = \frac{\langle K, yy^T \rangle_F}{\sqrt{\langle K, K \rangle_F \langle yy^T, yy^T \rangle_F}} \quad (6-8)$$

其中， $\langle \cdot, \cdot \rangle_F$ 為矩陣之間的 Frobenius distance，計算方式為 $\langle U, V \rangle_F = \sum_{i,j} u_{ij}v_{ij}$ (Tuia et al., 2010)。KA 值可以做為計算兩個核函數矩陣相關性與相似性的指標，當一個核函數 K 在分類時被視為是具有代表性或含有重要資訊的核函數，該核函數所對應的 KA 值會較高。已有相關研究利用 KA 值建立多核學習法的演算模型，使得多核學習法用於高光譜影像分類時更有效率(Tuia et al., 2010; Gu et al., 2012)，整體多核學習演算法流程如圖 6-3 所示。




圖 6-3、結合小波與多核學習演算法於高光譜影像分類流程

6.1.2、深度學習演算法與改善

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)組合而成，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，並由感知外部資訊的變化而調整網路內部參數，屬於一種自適應的計算模型。深度學習則是傳統神經網路的重要延伸，也被歸類為機器學習的一種方法，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)、影像辨識(recognition)(He et al., 2016)、物體偵測及定位(detection and localization)(Sermanet et al., 2013)、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(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)。卷積神經網路的優點之一是不需要繁複的影像前處理過程，卷積神經網路可以直接輸入原始影像進行一系列的影像處理工作。圖 6-4 所示為卷積神經網路的基本架構圖(Rawat and Wang, 2017)，與大多數前饋式神經網路(feedforward networks)架構類似，卷積神經網路由一個輸入層(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 6-4、卷積神經網路基本架構圖(Rawat and Wang, 2017)

由於卷積神經網路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，卷積神經網路也可以應用到一般航測或衛星影像辨識或分類，圖 6-5 所示即為一個用來處理遙測影像分類的卷積神經網路基本架構(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 6-6 所示。




圖 6-5、以深度學習進行遙測影像分類之基本架構圖(Li et al., 2018)




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

本年度則將 109 年研究案所採用之一維卷積神經網路網路架構(如圖 6-7 所示),延伸到二維及三維卷積神經網路網路架構(如圖 6-8 及圖 6-9 所示),以提升卷積神經網路用於高光譜影像分類之成果。圖 6-7 所示的一維卷積神經網路網路架構直接針對每一像元的光譜向量進行分類(Hu et al., 2015),該網路具有 5 個帶權重的層,分別是輸入層、卷積層、最大池化層、全連結層和輸出層等,圖 6-7 中 n_1 代表輸入一維光譜資料的波段數、 n_2 為對一維光譜資料進行卷積運算後的特徵向量大小、 n_3 為進行最大池化後特徵向量的大小、 n_4 為所有特徵向量扁平化後的長度,也是輸入全連結層的向量大小、最後 n_5 為輸出向量的大小,即本案樹種分類的類別數量。109 年研究案的結果顯示此網路模型具有比支持向量機更佳的分類結果。

相較於一維卷積神經網路模型僅能萃取光譜特徵, Makantasis et al. (2015)所提的二維卷積神經網路能同時萃取光譜及空間特徵,其網路架構如圖 6-8 所示,為了解決高維度資料的問題,該方法先以主成分轉換進行光譜特徵萃取,將波段數為 c 的高光譜影像轉換為特徵數為 c_r 主成分影像,其中 5×5 為二維影像區塊(image patch)的大小,藉以萃取像元周圍之空間特徵,之後即以一般的卷積神經網路模型進行空間特徵的萃取及分類,其實驗成果顯示同時結合光譜及空間資訊的深度學習模型在高光譜

影像分類上的確具有相當大的潛力。雖然二維卷積神經網路已可獲得相當不錯的分類成果，但在光譜特徵的萃取上仍需人為適當地介入，為了真正達到端對端學習(end to end learning)的目標，許多研究引入三維卷積神經網路架構於高光譜影像分類(He et al., 2017; Li et al., 2017)。由於三維卷積神經網路的特徵萃取結果為一三維立方體(3D feature cubes)，因此相當適合應用於高光譜影像的三維立方體資料，如圖 6-9 所示，圖中先從高光譜影像中擷取出大小為 $S \times S \times L$ 的影像區塊，並直接對其進行兩次三維卷積， $K_1^1 \times K_2^1 \times K_3^1$ 與 $K_1^2 \times K_2^2 \times K_3^2$ 分別為兩次三維卷積核的大小。Chen et al. (2016)的實驗成果亦證明三維卷積神經網路具有比二維卷積神經網路更好的分類成果。




圖 6-7、適用於高光譜影像類的一維卷積神經網路架構(Hu et al., 2015)




圖 6-8、適用於高光譜影像類的二維卷積神經網路架構(Makantasis et al., 2015)




圖 6-9、適用於高光譜影像類的三維卷積神經網路網路架構(Li et al., 2017)

6.2、發展多時期影像最適機器學習演算模式

高光譜影像成像時，受光譜取樣角度、地形變化、大氣效應以及樹種成長期變化等因素影響，光譜輻射或反射曲線將會產生不同的變化，當使用多期高光譜影像進行影像分類或影像變遷之應用時，須考量上述這些因素的影響。本計畫以 109 年研究案之機器學習演算法為基礎，應用不同時期影像及光達資料，評估演算法、分類數、類別定義等不同組合及其對分類準確度之影響，找出最適之演算模式。同時評估適合不同時期高光譜影像於臺灣地區重要樹種於高光譜影像自動化偵測之演算法，並建立適合不同時期高光譜影像於臺灣地區重要樹種於高光譜影像自動化偵測之流程。

從蒐集到的多時期高光譜影像分析文獻中，Jiang et al. (2020)採用端元(endmember)分析的方法，該方法首先從不同時期的高光譜影像中萃取出不同物種的端元光譜資料，並取不同時期端元光譜資料的平均值做為影像分類時的參考光譜資料。為了萃取出不同物種的端元光譜資料，輻射光譜必須先經過大氣輻射改正轉換為反射(reflectance)光譜；此外該研究採光譜角映射進行物種分類，光譜角映射需以人工採試誤的方式決定分類門檻值(classification thresholds)，於實際應用時較不方便。因此本計畫主要利用深度學習自動萃取特徵的能力，將同一樹種於不同時期的光譜資料全部串在一起當作是網路模型的輸入，由深度網路架構自行學習對該樹種具分辨性的特徵之後，再據以進行分類。當高光譜影像蒐集的期數或取樣區域越多，且所對應的訓練樣本夠充分且具代表性，可讓所訓練的網路模型具有較佳的泛化能力(generalization ability)。

前述的分析策略主要是針對同一區域多時期影像，且有足夠的訓練資料，若是對於其他區域從未訓練及辨識過的樹種，則本計畫嘗試透過遷移學習(transfer learning)，期待可以利用原先訓練好的模型，在僅需投入少量新樹種的樣本下進行樹種的辨識，或是由原先訓練的模型獲取部分網路層之參數、調整部分網路層之模型，除多時期高光譜影像樹種分析外，也達到多區域高光譜影像樹種分析。遷移學習的基本概念如圖 6-10 所示，

圖中域(domain)定義為一組樣本所形成的樣本空間及其機率分布，而任務(task)指的是在所對應的域中利用已知樣本進行學習並建立一個模型(model)，此模型將可以用在同一個域中的其他資料上進行預測，但當應用到其他域的資料時，由於樣本空間及機率分布的差異，原模型將無法完全適用於新的任務上。傳統機器學習的作法是針對新的任務重新建立新的模型，但往往需要較多的訓練樣本及訓練時間。遷移學習的主要目的是將原域(source domain)已經訓練好的模型遷移到目標域中(target domain)，並利用該域中的樣本進行模型的調整以適用新的任務，此不僅可以縮短訓練時間，也可以降低所需訓練樣本的大小(Yang et al., 2020)。

遷移學習有許多不同的學習方式，對於卷積神經網路模型而言，常用的一種方式是基於特徵的遷移學習(feature-based transfer learning)，其將原訓練模型中特徵萃取層的參數遷移到新的學習模型中，再利用新的樣本資料進行特徵的微調以適應新的任務，如圖 6-11 所示。




圖 6-10、遷移學習的基本概念(Yang et al., 2020)




圖 6-11、針對卷積神經網路模型的遷移學習過程(Lemley et al., 2017)

承續前述之遷移學習演算理論，本計畫採用圖 6-12 之分析流程，將所有已觀測的多時期高光谱影像串接在一起，由深度網路架構自行學習對該樹種具分辨性的特徵，再據以進行分類，如圖 6-12 上半部所示，並針對影像輸入後所需進行的預處理或多時期資料串接的方法進行測試及評估。因深度學習特徵係由多時期的影像學習而來，較不受時間的影響，因此可視為具有時間不變性的特徵。對於其他不同時期或不同區域的高光谱影像分類任務，本計畫將嘗試以遷移學習的方式，期待可以利用原先訓練好的模型(pre-trained model)，在僅需投入少量新樹種的樣本下進行樹種的辨識，如圖 6-12 下半部，最後則針對多時期高光谱影像網路學習及分類策略進行測試及成果評估，第 7 章實驗即測試所提方法確實可行，並根據實驗成果建立適合不同時期高光谱影像於臺灣地區重要樹種於高光谱影像自動化偵測流程。





圖 6-12、多時期、不同區域高光譜影像之網路學習及分類策略

柒、實驗區高光譜影像多時期分類及優化成果分析

本章說明目前利用出雲山苗圃實驗區以及阿里山森林遊樂區實驗區兩時期之機載高光譜影像於核方法與卷積神經網路之樹種分類分析，並測試同時分析多時期影像和遷移學習的成效。

7.1、出雲山苗圃實驗區兩時期影像與統計分析

延續前期計畫之選定的出雲山苗圃實驗區類別與分布區域，如圖 5-13 與表 5-9，則根據選定的類別以及排除原始影像的遮蔽區，選定出雲山苗圃實驗區影像分析範圍，影像大小為寬 4200 個像元、長 6500 個像元，波段數為 96 個，圖 7-1 為實驗區 2 個時期實驗用影像。決定實驗區域影像大小及類別後，則利用遙測影像處理軟體 ENVI 選取目標區域(region of interest, ROI)，做為後續分析中訓練資料和檢核資料，如圖 7-2 所示，目標區域避免選取鄰近類別邊界之區域，同時也避免選取影像中有較稀疏或是樹種混合的區域，所圈選的目標區域以像元為單位用於分類分析，各類別圈選的總像元數如表 7-1 所示，於分類分析時，會排除空像元及陰影像元，並以隨機選擇的方式選取訓練資料和檢核資料。



(a)108 年 6 月

(b)109 年 10 月

圖 7-1、出雲山苗圃實驗區兩時期實驗用影像




圖 7-2、出雲山苗圃實驗區目標區域

表 7-1、出雲山苗圃實驗區各類別之像元數

編號	樹種	總像元數
1	檜木(紅檜、扁柏)	25,650
2	臺灣肖楠	128,919
3	杉木(巒大杉、杉木)	243,764
4	柳杉	118,940
5	臺灣杉	25,812
6	臺灣檫	13,468

根據選定的類別與實驗區影像，分別計算 2 個時期影像之檜木、臺灣肖楠、杉木、柳杉、臺灣杉和臺灣檫等 6 種類別的平均光譜曲線如圖 7-3 所示，從單一時期的平均光譜曲線可以發現不同樹種之間皆具有一定的差異性，這將有助於單一時期的影像分類，此已於前兩年度研究案中獲得驗證；同時由整體平均光譜輻射值變化大致可分為幾個族群，屬於闊葉樹種的臺灣檫較其他針葉樹種的平均光譜輻射值高，吸收帶變化比其他樹種明顯，其次平均光譜輻射值較高且變化明顯為針葉樹種的臺灣肖楠，杉木和臺灣杉的平均光譜輻射值之變化為一個族群，最後則是檜木和柳杉，這 2 個樹種的平均光譜輻射值較其他樹種低，在可見光範圍中，不同樹種的光譜輻射值差異較小，而在 700nm 之後的紅外光波段，不同樹種的差異則較明顯，可以看出不同樹種的吸收帶變化，但其中杉木與臺灣杉之間的差異較其他樹種類別小。

再根據 ROI 資料，分別計算 2 個時期出雲山苗圃實驗區高光譜影像各類別兩兩之間的類別分離度，採用的指標為巴氏距離(Bhattacharyya distance)，計算公式為：

$$D = \frac{1}{8} \left[(\mu_a - \mu_b)^T \left(\frac{C_a + C_b}{2} \right)^{-1} (\mu_a - \mu_b) \right] + \frac{1}{2} \ln \left[\frac{|(C_a + C_b)/2|}{(|C_a||C_b|)^{1/2}} \right] \quad (7-1)$$


其中 μ 為各類別光譜曲線的平均值、 C 為協變方矩陣，計算所得巴氏距離為單純數量級，無對應單位。108年出雲山苗圃實驗區各類別分離度如表 7-2 所示，其中分離度最小的類別為杉木—臺灣杉，分離度為 0.9163，其次為臺灣肖楠—杉木和杉木—柳杉的組合，其分離度值不超過 1.5，而類別分類離度較大的類別組合分別為檜木—台灣檫、柳杉—臺灣檫和檜木—臺灣肖楠，類別分離度值均大於 3，以單一樹種與其他樹種的平均類別分離度，臺灣檫的平均類別分離度最大，為 2.6130，其次為檜木的 2.4502，最小的平均類別分離度為杉木的 1.4974。不同時期拍攝的高光譜影像所記錄到的輻射值會因為拍攝當下的環境有所不同，因此 109 年實驗區影像用於計算各類別分離度也與 108 年有些微差異，如表 7-3，類別分離度最小的組合同樣為杉木—臺灣杉，類別分離度值為 0.7268，其次為檜木—柳杉、杉木—臺灣肖楠和杉木—柳杉等，這三種組合的類別分離度值均小於 1.4，而類別分離度值較大的類別組合為檜木—臺灣肖楠與檜木—臺灣檫；單一樹種平均類別分離度中，同樣臺灣檫的平均類別分離度最大，為 2.4393，其次為檜木的 2.2563，最小的平均類別分離度為杉木的 1.4794。而分別繪製單一樹種不同時期平均光譜輻射值變化，從圖 7-4 可以發現，相同樹種在不同時期的光譜輻射曲線大致呈現相同的形狀變化，僅在部分光譜波長範圍內呈現出些許的差異，輻射差異主要出現在近紅外線及藍光之波譜範圍，其中以檜木的差異最大，臺灣肖楠的差異最小。因為相同樹種在不同時期的光譜曲線仍大致維持同樣的形狀變化，這表示有機會可以找到不受時間影響的光譜特徵。

表 7-2、108 年度出雲山苗圃各類別間之類別分離度


類別	檜木	臺灣肖楠	杉木	柳杉	臺灣杉	臺灣櫟
檜木	--	3.0251	2.1112	1.3946	2.4026	3.3173
臺灣肖楠	3.0251	--	1.1616	2.6684	1.8607	2.2517
杉木	2.1112	1.1616	--	1.3523	0.9163	1.9457
柳杉	1.3946	2.6684	1.3523	--	1.6631	3.2220
臺灣杉	2.4026	1.8607	0.9163	1.6631	--	2.3283
臺灣櫟	3.3173	2.2517	1.9457	3.2220	2.3283	--
平均	2.4502	2.1935	1.4974	2.0601	1.8342	2.6130

表 7-3、109 年度出雲山苗圃各類別間之類別分離度

類別	檜木	臺灣肖楠	杉木	柳杉	臺灣杉	臺灣櫟
檜木	--	3.1966	1.9333	1.0693	2.1417	2.9404
臺灣肖楠	3.1966	--	1.3573	2.5949	1.7207	2.2839
杉木	1.9333	1.3573	--	1.3945	0.7268	1.9853
柳杉	1.0693	2.5949	1.3945	--	1.8158	2.5151
臺灣杉	2.1417	1.7207	0.7268	1.8158	--	2.4716
臺灣櫟	2.9404	2.2839	1.9853	2.5151	2.4716	--
平均	2.2563	2.2307	1.4794	1.8779	1.7753	2.4393



(a) 108 年 6 月



(b) 109 年 10 月

圖 7-3、出雲山苗圃實驗區影像不同樹種平均光譜曲線




圖 7-4、出雲山苗圃不同時期各樹種高光譜影像平均光譜曲線

7.2、支持向量機於出雲山苗圃實驗區兩時期影像分析

7.2.1、支持向量機分類之實驗方法說明

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、多核學習法 MKLpy 模組，搭配高光譜影像分析 spectral 模組，以自行撰寫程式的方式操作實驗，而支持向量機於計算過程中，須利用訓練資料同時建構核函數，必須使用大量的電腦計算資源，為了使程式可以正常且有效率的運作，選定 2,000 個像元，以 7:3 的數量分配，其中 1,400 個像元為訓練資料、600 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；
2. 輻狀基底函數 (RBF)：採用的 γ 為預設值(1/波段數)；
3. 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 Daubechies 3；
4. 小波多核函數：利用 2 次離散小波轉換，共有 1 組近似係數及 2 組細節係數的核函數，將 3 個核函數取平均建立多核函數，採用的小波基底函數為 Daubechies 3；
5. RBF 多核函數：採用 3 個 γ 值，分別為 0.001、0.01、0.1 組成 3 個核函數取平均建立多核函數；
6. 自選離散小波多核函數：採用 4 次離散小波轉換，取得 1 組近似係數及 4 組細節係數核函數，利用 KA 值計算找出 3 個較大值的核函數，核函數相加建立多核函數，採用的小波基底函數為 Daubechies 3；
7. 自選連續小波多核函數：採用連續小波轉換，基底函數選擇 Morlet，尺度(scale)為 32，利用 KA 值計算找出 16 個較大值的核函數，核函數相加建立多核函數。

將原始高光譜影像波段利用支持向量機選擇不同核函數，其餘參數設定均相同，多類別分類則採用一對多的方式，計算不同支持向量機分類成果。

7.2.2、兩時期影像個別分析之支持向量機分類成果

分別將出雲山苗圃實驗區的 108 年、109 年兩時期影像以不同支持向量機和多核學習法進行分類分析。其中 108 年出雲山苗圃高光譜影像的不同支持向量機分類成果評估如表 7-4 所示，其中分類成果均是採用檢核資料集進行評估。在採用單一核函數的支持向量機時，輻狀基底核函數 (RBF) 的分類成果最佳，整體分類準確度為 82.86%，Kappa 指標為 0.7943、F1-score 為 0.8282；優於線性核函數的整體分類準確度 79.25%，以及單一小波核函數的分類準確度 78.11%。

由單一核函數延伸至多核學習法時，由手動試誤選擇輻狀基底多核函數整體分類準確度為 82.67%，接近採用單一輻狀基底核函數的分類成果；而小波多核函數的整體分類準確度為 79.25%，其成果與採用線性核函數相當。為了在多核學習法實作時，在核函數選擇上減少手動試誤，本計畫嘗試利用 KA 值找出較具有代表性的核函數；其中在離散小波多核函數中，選擇 3 個對應較大 KA 值的小波核函數組成多核支持向量機，而整體的分類準確度為 78.00%，而連續小波多核函數則是選擇 KA 值較大的 16 個小波核函數，組成多核支持向量機，其整體分類準確度為 78.83%。綜合不同支持向量機之分類成果，利用輻狀基底函數的支持向量機可以達到比其他核函數較好的分類成果，而利用 KA 值組成多核學習的支持向量機成果與採用單一小波核函數的成果相差不多。

表 7-4、108 年度出雲山苗圃影像不同支持向量機之分類成果

SVM 核函數(參數)	OA(%)	Kappa 指標	F1-score
線性核函數	79.25	0.7510	0.7921
輻狀基底函數核函數 ($r=\text{default}=1/96$)	82.86	0.7943	0.8282
小波核函數 (採用近似係數，db3)	78.11	0.7373	0.7811
多核函數(小波核函數，cA2、 cD2、cD1)	79.25	0.7510	0.7921
多核函數 (RBF，0.001、0.01、0.1)	82.67	0.7920	0.8268
自選離散多核函數 (小波核函數，分解 4 次以 KA 值取 3)	78.00	0.7363	0.7803
自選連續多核函數 (連續小波核函數，scale=32 以 KA 值取 16)	78.83	0.746	0.7881

根據前述的 108 年度出雲山苗圃影像不同支持向量機分類成果，利用單一輻狀基底函數的支持向量機即可以達到良好的分類成果，且計算效率較多核學習法佳。則表 7-5 即為支持向量機採用單一輻狀基底核函數的類別分類成果，訓練資料集的評估成果為整體分類準確度 86.63%、Kappa 指標 0.8396 及 F1-score 為 0.8659，而檢核資料集的評估成果為整體分類準確度 82.86%、Kappa 指標為 0.7943，和 F1-score 為 0.8282。進一步分析比較不同樹種的分類成果，臺灣檫的分類成果最佳，生產者與使用者準確度分別為 0.9483、0.9177，F1-score 為 0.9328；其次檜木的生產者準確度為 0.9200、使用者準確度為 0.8585、F1-score 為 0.8882，其他樹種的分類成果依序為臺灣肖楠、柳杉、臺灣杉，最低為杉木，其 F1-score 小於 0.7，圖 7-5 為支持向量機使用輻狀基底核函數的分類成果圖，其成果分布與地真資料相近，除了有椒鹽效應外，在圖 7-5 中黑框區域的臺灣杉、柳杉、杉木區塊被錯誤分類的情況較明顯，而錯誤分類區域主要分布於影像中陰影區域，在光譜曲線輻射值普遍較低的情形下，使分類成果較差。

表 7-5、108 年度出雲山苗圃支持向量機(RBF 核函數)分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	86.63	0.8396	0.8659	82.86	0.7943	0.8282
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.9457	0.8827	0.9131	0.9200	0.8585	0.8882
2 臺灣肖楠	0.8857	0.8979	0.8918	0.8450	0.8652	0.8550
3 杉木	0.7607	0.7729	0.7667	0.7017	0.6982	0.6999
4 柳杉	0.8500	0.8667	0.8583	0.8117	0.8470	0.8289
5 臺灣杉	0.7986	0.8400	0.8187	0.7450	0.7801	0.7621
6 臺灣檫	0.9571	0.9325	0.9447	0.9483	0.9177	0.9328




圖 7-5、108 年度出雲山苗圃支持向量機(RBF 核函數)分類成果圖

109 年度出雲山苗圃實驗區高光譜影像利用不同的支持向量機與多核學習法，以檢核資料集評估分類成果如表 7-6 所示。同樣的採用單一核函數時，以輻狀基底函數的支持向量機分類成果最佳，整體分類準確度為 80.39%，Kappa 指標為 0.7647、F1-score 為 0.8061，其次採用線性核函數的整體分類準確度為 76.06%，而採用單一小波核函數的支持向量機分類成果則略差於前述兩者，分類準確度則為 73.80%。

採用多核學習的支持向量機時，採用多核輻狀基底函數的支持向量機分類成果比採用單一的輻狀基底函數支持向量機分類成果來得差，分類準確度僅有 78.81%；再比較小波多核函數的支持向量機，發現其成果比採用單一核函數或是輻狀基底多核函數來的差，不論是利用離散的小波多核函數或是連續的小波多核函數其分類準確度介於 73%至 76%之間，顯示仍需透過其他的方式改善小波核函數的選擇，找出適用於高光譜影像資料的核函數。由於 109 年度與 108 年度出雲山苗圃實驗區高光譜影像的拍攝條件不相同，透過統計分析也可看出有所差異，而從分類結果來看，109 年度的分類結果較差。

此外計畫中嘗試將 108 年度影像訓練的支持向量機用於 109 年度影像分類，並測試檢核資料的分類準確度。以前期(108 年)影像資料訓練模型再用後期(109 年)影像分類之整體分類準確度介於 15%到 23%間，顯示兩期高光譜影像的輻射值之間仍有一定的差距，無法直接利用現有訓練好的模型進行多時期影像樹種分析。計畫中亦嘗試將兩期出雲山苗圃高光譜影像視為一個資料集，合併資料進行支持向量機模型訓練，並以兩期資料分別評估分類成果，則發現不同核函數的支持向量機模型分類結果都變差，合併訓練的不同支持向量機整體分類準確度皆比分開訓練的不同支持向量機模型分類準確度降低了 2%到 7%，顯示當資料分布有所差異會使得支持向量機本身的模型訓練受到明顯的影響；因此本計畫中兩時期高光譜影像拍攝的條件不完全相同，在採用光譜輻射值進行分析時，資料的分布也有所差異，較不適合直接將兩時期高光譜影像資料利用支持向量機進行合併分析。

表 7-6、109 年度出雲山苗圃影像不同支持向量機之分類成果

SVM 核函數(參數)	OA(%)	Kappa 指標	F1-score
線性核函數	76.06	0.7127	0.7624
輻狀基底函數核函數 (r=default=1/96)	80.39	0.7647	0.8061
小波核函數 (採用近似係數，db3)	73.80	0.6857	0.7410
多核函數(小波核函數，cA2、 cD2、cD1)	76.00	0.7120	0.7619
多核函數 (RBF，0.001、0.01、0.1)	78.81	0.7457	0.7876
自選離散多核函數 (小波核函數，分解 4 次以 KA 值 取 3)	73.89	0.6867	0.7417
自選連續多核函數 (連續小波核函數，scale=32 以 KA 值取 16)	76.22	0.7147	0.7637

表 7-7 為 109 年度高光譜影像採用單一輻狀基底核函數的支持向量機分類成果，利用訓練資料集與檢核資料集的整體分類準確度分別為 83.38%、80.39%。不同樹種的分類成果評估，以臺灣櫟的分類成果最佳，生產者、使用者準確度、F1-score 分別為 0.8933、0.9322、0.9123，其次為檜木，檜木的生產者準確度為 0.8967，而使用者準確度明顯較低，為 0.7970，其他樹種的分類成果依序為臺灣肖楠、柳杉、臺灣杉，最低為杉木，全部樹種的 F1-score 皆大於 0.72，圖 7-6 為 109 年度影像用支持向量機(RBF 核函數)的分類成果圖，其成果分布與地真資料相近，但同樣在圖 7-6 影像右側黑框區域的臺灣杉、柳杉、杉木區塊被錯誤分類的情況比前期影像資料來的顯著。

表 7-7、109 年度出雲山苗圃支持向量機(RBF 核函數)分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	83.38	0.8006	0.8363	80.39	0.7647	0.8061
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.9243	0.8027	0.8592	0.8967	0.7970	0.8439
2 臺灣肖楠	0.8421	0.8720	0.8568	0.8000	0.8013	0.8007
3 杉木	0.8029	0.7105	0.7539	0.7700	0.6774	0.7207
4 柳杉	0.7229	0.8440	0.7788	0.7083	0.8065	0.7542
5 臺灣杉	0.8064	0.8527	0.8289	0.7550	0.8358	0.7933
6 臺灣櫟	0.9043	0.9512	0.9271	0.8933	0.9322	0.9123




圖 7-6、109 年度出雲山苗圃支持向量機(RBF 核函數)分類成果圖

7.3、一維卷積神經網路於出雲山苗圃實驗區兩時期影像分析

7.3.1、一維卷積神經網路分類之實驗方法說明

本次實驗以一維卷積神經網路(1D CNN)進行高光譜影像分類之分析，分析的工具是透過 Python 程式中的深度學習 Tensorflow 和 Keras 模組，根據 Hu et al.(2015)建立一個 5 層的神經網路架構於高光譜影像分類，已可獲得良好的成果，故建立一維卷積神經網路如圖 7-7 所示，各網路層說明如下：

1. 輸入層：單一像元即為一個輸入資料，大小為 96×1 (1 維向量)；
2. 卷積層：建立 20 個濾波器，濾波器大小為 10，產生 20 個 96×1 的節點；
3. 池化層：利用 max pooling 將網路縮小為 20 個 32×1 的節點；
4. 全連結層：建立 100 個節點的全連結層；
5. 輸出層：根據目標類別數(6 個)，建立輸出層，亦為全連結層。

實驗區影像將目標區域的所有像元資料用於分類分析，並以 3:7 的數量分配，其中 166,965 的像元為訓練資料，並取出 1/3 做為驗證資料，389,588 個像元為檢核資料；實際操作透過卷積神經網路學習以逐像元方式進行光譜特徵自動萃取及學習，並進行影像分類，因卷積神經網路為批次學習的模式，因此每此放入 256 個訓練資料(即批次大小為 256)，進行 100 次的運算學習(100 epoch)，學習速率為 0.001，而學習速率是指神經網路訓練時，權重參數更新的速率，過小時會使得訓練速度太慢，過大時則可能會造成模型無法收斂。




圖 7-7、一維卷積神經網路示意圖(修改自 Hu et al.,2015)

7.3.2、兩時期影像個別分析之一維卷積神經網路分類成果

利用一維卷積神經網路於 108 年度出雲山苗圃高光譜影像訓練和檢核資料集的分類成果如表 7-8，所示，首先訓練資料集的分類成果評估為分類準確度 92.78%、Kappa 指標為 0.8968、F1-score 為 0.9045；而檢核資料集的分類成果為整體分類準確度為 91.14%、Kappa 指標為 0.8732、F1-score 為 0.8803。

檢視檢核資料集的單一類別分類成果，大部分的類別都有良好的分類準確度，檜木、臺灣肖楠、杉木、柳杉的 F1-score 皆大於 0.90，其中臺灣肖楠的分類成果最佳，生產者準確度為 0.9338、使用者準確度為 0.9415、F1-score 為 0.9377，其次為杉木與柳杉的分類成果次佳，F1-score 為 0.9160，且生產者準確度和使用者準確度均大於 0.9，接著檜木的 F1-score 為 0.9034，臺灣櫟的 F1-score 為 0.8727，與前述的類別接近，而分類成果最差的是臺灣杉，F1-score 為 0.7170，其中生產者準確度為 0.6170，比其他類別來得低，漏判的情形明顯。圖 7-8 為 108 年度影像採用一維卷積神經網路的分類成果圖，與地真資料的分布比對，各類別的分類成果大致吻合，成果圖中椒鹽現象也比支持向量機分類成果來得少，主要明顯可以看出原本臺灣

杉分布的區塊被錯誤分類為其他類別。

表 7-8、108 年度出雲山苗圃一維卷積神經網路分類成果

	訓練資料集			檢核資料集		
	OA(%)	Kappa 指標	F1-score	OA(%)	Kappa 指標	F1-score
	92.78	0.8968	0.9045	91.14	0.8732	0.8803
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.9357	0.9134	0.9244	0.9093	0.8975	0.9034
2 臺灣肖楠	0.9471	0.9531	0.9501	0.9338	0.9415	0.9377
3 杉木	0.9449	0.9176	0.9311	0.9320	0.9005	0.9160
4 柳杉	0.9275	0.9347	0.9311	0.9109	0.9212	0.9160
5 臺灣杉	0.6602	0.8978	0.7609	0.6170	0.8555	0.7170
6 臺灣檫	0.9347	0.8901	0.9118	0.8953	0.8511	0.8727




圖 7-8、108 年度出雲山苗圃一維卷積神經網路分類成果圖

109 年度影像利用一維卷積神經網路訓練與檢核資料集的分類成果如表 7-9 所示，109 年度的整體分類成果與支持向量機相同，也略差於 108 年度之資料，首先訓練資料集的分類成果評估為分類準確度 91.48%、Kappa 指標為 0.8778、F1-score 為 0.8848；而檢核資料集的分類成果為整體分類準確度為 98.63%、Kappa 指標為 0.8515、F1-score 為 0.8602。

檢視檢核資料集的單一類別分類成果，其中以臺灣肖楠、杉木、柳杉的分類成果較佳，F1-score 大約在 0.90，臺灣肖楠的分類成果最佳，F1-score 為 0.9158，其次依序為杉木、柳杉和臺灣檫，其 F1-score 分別為 0.9158、0.8920 和 0.8606，分類成果較差的同樣是檜木與臺灣杉，其中檜木的 F1-score 為 0.8148，而生產者準確度明顯較差，只有 0.7607，臺灣杉的 F1-score 只有 0.7493，同樣為生產者準確度較差，僅有 0.6746。圖 7-9 為 109 年度影像採用一維卷積神經網路的分類成果圖，與地真資料的分布比對，各類別的分類成果大致吻合，同樣在臺灣杉的部分有較明顯的錯誤分類。

表 7-9、109 年度出雲山苗圃一維卷積神經網路分類成果

	訓練資料集			檢核資料集		
	OA(%)	Kappa 指標	F1-score	OA(%)	Kappa 指標	F1-score
	91.48	0.8778	0.8848	89.63	0.8515	0.8602
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.7897	0.9132	0.8470	0.7607	0.8773	0.8148
2 臺灣肖楠	0.9219	0.9402	0.9310	0.9086	0.9231	0.9158
3 杉木	0.9421	0.9142	0.9279	0.9238	0.9004	0.9119
4 柳杉	0.9356	0.8877	0.9110	0.9182	0.8672	0.8920
5 臺灣杉	0.7102	0.8937	0.7915	0.6746	0.8424	0.7493
6 臺灣檫	0.7996	0.9872	0.8835	0.7727	0.9711	0.8606




圖 7-9、109 年度出雲山苗圃一維卷積神經網路分類成果圖

7.4、混合三維及二維卷積神經網路於出雲山苗圃實驗區兩時期影像分析

7.4.1、混合三維及二維卷積神經網路分類之實驗方法說明

本次實驗以混合三維及二維卷積神經網路(HybridSN)進行高光譜影像分類之分析，HybridSN 為 Roy 等人於 2020 年所提出一個混合三維及二維卷積神經網路架構，其在許多高光譜測試影像中已獲得良好的成果，因此本研究透過 Python 語言中的深度學習 Tensorflow 和 Keras 模組對其進行改寫，使其可以運作於本案之大型實驗資料。HybridSN 的網路架構如圖 7-10 所示，各網路層說明如下：

1. 輸入層：原始影像經 PCA 轉換後，以單一像元及其鄰近像元所組成的影像區塊及所對應之 PCA 特徵形成一影像立方體 (image cube)，並以此為單筆輸入資料，大小為 $S \times S \times B$ (三維張量)，其中 S 為影像區塊大小， B 為 PCA 特徵數，本實驗資料 S 為 21、 B 為 96；
2. 三維卷積層：分別以 8、16、及 32 個濾波器建立三個三維卷積層，濾波器大小分別為 $3 \times 3 \times 7$ 、 $3 \times 3 \times 5$ 、及 $3 \times 3 \times 7$ ，最後產生 32 個大小為 $15 \times 15 \times 3$ 的三維特徵圖。
3. 二維卷積層：將 32 個 $15 \times 15 \times 3$ 的三維特徵圖轉換成 96 個 15×15 的二維特徵圖，再利用 64 個大小為 3×3 的濾波器進行二維卷積，產出 64 個 13×13 的二維特徵圖。
4. 扁平層：將 64 個 13×13 的二維特徵圖展平為 10816 個節點；
5. 全連結層：建立 10816 個節點的全連結層，其中包含兩個 dropout 層，以避免過度擬合的狀況；
6. 輸出層：根據目標類別數(6 個)，建立輸出層，亦為全連結層。

實驗區影像選定所有的像元資料進行分析，並以 3:7 的數量分配，其中 166,965 個像元為訓練資料、389,588 個像元為檢核資料，訓練資料中又取出 1/3 做為驗證資料；實際操作透過三維及二維卷積對各影像立方體進行光譜及空間特徵自動萃取及學習，並進行影像分類。訓練卷積神經網路時採批次學習的模式，每此放入 512 個訓練資料(即批次大小為 512)，進行

50 次的運算學習(50 epoch)，學習速率為 0.001。




圖 7-10、HybridSN 網路架構示意圖(Roy et al., 2020)

7.4.2、兩時期影像個別分析之 HybridSN 神經網路分類成果

利用 HybridSN 神經網路於 108 年度出雲山苗圃高光譜影像分類的成果如表 7-10，所示，在檢核資料集的分類成果為：整體分類準確度為 99.98%、Kappa 指標為 0.9998、F1-score 為 0.9998，成果非常良好。若檢視檢核資料集的單一類別分類成果，可以發現所有類別無論是在生產者準確度、使用者準確度、及 F1-score 皆趨近於 1，顯示此模型的分類成果極佳。圖 7-11 為 108 年度影像採用 HybridSN 神經網路的分類成果圖，與地真資料的分布比對，各類別的分類成果幾乎完全吻合，成果圖中也無椒鹽現象，顯示三維及二維卷積網路確實可以萃取並學習對分類有用的空間特徵。

109 年度影像利用 HybridSN 神經網路的分類成果如表 7-11 所示，可以觀察到整體分類成果與 108 年度之分類成果相類似，檢核資料集的整體分類準確度為 99.99%、Kappa 指標為 0.9999、F1-score 為 0.9999，成果非常良好。若檢視檢核資料集的單一類別分類成果，可以發現所有類別無論是在生產者準確度、使用者準確度、及 F1-score 皆趨近於 1，顯示此模型的分類成果極佳。圖 7-12 為 109 年度影像採用 HybridSN 神經網路的分類成果圖，若與地真資料的分布比對，各類別的分類成果幾乎完全吻合，分類錯誤的情況相當稀少。

表 7-10、108 年度出雲山苗圃 HybridSN 神經網路分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	100.00%	1.0000	1.0000	99.98%	0.9998	0.9998
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	1.0000	1.0000	1.0000	0.9997	1.0000	0.9997
2 臺灣肖楠	1.0000	1.0000	1.0000	1.0000	0.9999	1.0000
3 杉木	1.0000	1.0000	1.0000	1.0000	0.9999	1.0000
4 柳杉	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
5 臺灣杉	1.0000	1.0000	1.0000	0.9993	1.0000	0.9994
6 臺灣櫟	1.0000	1.0000	1.0000	1.0000	0.9988	0.9994

表 7-11、109 年度出雲山苗圃 HybridSN 神經網路分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	100.00%	1.0000	1.0000	99.99%	0.9999	0.9999
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999
2 臺灣肖楠	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
3 杉木	1.0000	1.0000	1.0000	1.0000	0.9999	0.9999
4 柳杉	1.0000	1.0000	1.0000	0.9999	1.0000	0.9999
5 臺灣杉	1.0000	1.0000	1.0000	0.9998	1.0000	0.9998
6 臺灣櫟	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000




圖 7-11、108 年度出雲山苗圃 HybridSN 神經網路分類成果圖






圖 7-12、109 年度出雲山苗圃 HybridSN 神經網路分類成果圖

7.5、阿里山森林遊樂區實驗區兩時期影像與統計分析

本計畫中阿里山森林遊樂區實驗區根據地真資料分布，以森林遊樂區之範圍及部分台 18 線沿線選定影像分析範圍，並選擇阿里山歷史專案 (A)(105 年)、(B)(107 年)兩時期影像進行，用於實驗之兩期影像如圖 7-13 所示，由於 105 年影像地元尺寸為 1 公尺，實驗用影像大小為寬 7500 個像元、高 4000 個像元，而 107 年影像地元尺寸為 1.5 公尺實驗用影像大小為寬 5001 個像元、高 2668 個像元，影像的波段數皆為 72 個波段，而 107 年度的阿里山影像相較於 105 年度影像有未涵蓋到的區域，同時雲遮蔽區也較多。決定實驗區後同樣利用 ENVI 選取目標區域，選取時避免稀疏或樹種混合的區域，所選取的目標區域以像元為單位用於分類分析，如圖 7-14，同時會排除空像元和陰影區像元。各類別選取的總像元數如表 7-12 所示，分類分析時同樣以隨機選擇方式。



(a)105 年



(b)107 年

圖 7-13、阿里山實驗區兩時期實驗用影像





圖 7-14、阿里山實驗區圈選之目標區域分布


表 7-12、阿里山實驗區各類別之像元數

編號	樹種	總像元數	總像元數
		(105 年)	(107 年)
1	檜木(紅檜、扁柏)	1,570,154	432,574
2	臺灣肖楠	21,755	8,490
3	杉木(巒大杉、杉木)	147,560	53,534
4	柳杉	3,167,561	1,155,589
5	臺灣杉	56,001	24,881
6	松樹(二葉松、五葉松)	63,293	12,961

將阿里山森林遊樂區 2 時期實驗影像根據選定的類別與目標區域，分別繪製檜木、臺灣肖楠、杉木、柳杉、臺灣杉和松樹的平均光譜曲線圖，如圖 7-15 所示，同樣單一時期的平均光譜曲線可以發現不同樹種之間有一定的差異性，整體而言 105 年度資料的平均光譜輻射值較 107 年度高，而 105 年度的平均光譜輻射值在可見光範圍不同類別的差異比較小，在 700nm 之後的紅外光波段，檜木與柳杉的平均光譜輻射值明顯低於其他樹種。在 107 年的平均光譜輻射值曲線，則是在可見光範圍中，檜木與松樹與其他樹種有明顯的差異，數值較高，在 700nm 之後的紅外光波段不同樹種的差異較明顯由高到低依序為松樹、檜木、臺灣杉、柳杉，而臺灣肖楠與杉木的數值較近。圖 7-16 為相同樹種在不同時期的平均光譜輻射曲線，同一樹種的吸收帶特徵變化大致相近，而輻射值上的差異以柳杉和松樹兩個時期的差異較小，另外則是檜木於 107 年度的平均輻射值曲線高於 105 年度的數值，而臺灣肖楠、杉木與臺灣杉則是 105 年度的輻射值曲線高於 107 年度的值。



(a) 105 年



(b) 107 年

圖 7-15、阿里山森林遊樂區實驗區影像不同樹種平均光譜曲線




圖 7-16、阿里山森林遊樂區不同時期各樹種高光譜影像平均光譜曲線

再根據 ROI 資料分別計算兩個時期阿里山實驗區高光譜影像各類別兩兩之間的巴氏距離，以了解不同類別的類別分離度。兩個時期影像所計算出來的類別分離度不完全相同，但趨勢相近；105 年度阿里山影像的類別間分離度如表 7-13 所示，105 年度的影像中臺灣肖楠與其他類別的分離度最佳，平均的分離度為 3.1118，其中類別分離度最大的為臺灣肖楠—臺灣杉的 3.8616，其次為檜木—杉木、檜木—臺灣肖楠、檜木—臺灣杉。而單一樹種的平均值大約都落在 2 到 3 之間，其中柳杉的平均類別分離度最低，值為 2.2274，而兩兩之間類別分離度較小的則是檜木—松樹的 1.6152 和檜木—柳杉的 1.6331，其他類別組合的類別分離度均接近或大於 2。

107 年度的各類別間類別分離度值如表 7-14 所示；其中臺灣肖楠的平均類別分離度最大，其值為 4.7560，同樣為臺灣肖楠—臺灣杉的 6.3427 最大，其次為臺灣肖楠—檜木、臺灣肖楠—柳杉、臺灣肖楠—松樹。其他樹種的平均類別分離度差異不大，大致落在 2.6 到 3.4 之間，而兩兩之間類別分離度最小的同樣是檜木—松樹，其類別分離度值為 1.2779，再來是檜木—柳杉的 1.4300。可以看出 107 年度阿里山影像的整體類別分離度與 105 年度影像的趨勢相似，但 107 年的整體類別分離度數值略高於 105 年度。

表 7-13、105 年度阿里山實驗區各類別間之類別分離度

類別	檜木	臺灣肖楠	杉木	柳杉	臺灣杉	松樹
檜木	--	3.5617	3.6616	1.6331	3.3396	1.6152
臺灣肖楠	3.5617	--	2.2810	2.9951	3.8616	2.8597
杉木	3.6616	2.2810	--	2.2593	2.3470	3.0338
柳杉	1.6331	2.9951	2.2593	--	2.3132	1.9365
臺灣杉	3.3396	3.8616	2.3470	2.3132	--	2.8476
松樹	1.6152	2.8597	3.0338	1.9365	2.8476	--
平均	2.7622	3.1118	2.7165	2.2274	2.9418	2.4586

表 7-14、107 年度阿里山實驗區各類別間之類別分離度

類別	檜木	臺灣肖楠	杉木	柳杉	臺灣杉	松樹
檜木	--	5.3761	3.9855	1.4300	2.5328	1.2779
臺灣肖楠	5.3761	--	2.1413	4.9298	6.3427	4.9899
杉木	3.9855	2.1413	--	2.9530	3.7006	3.9127
柳杉	1.4300	4.9298	2.9530	--	1.9898	1.9820
臺灣杉	2.5328	6.3427	3.7006	1.9898	--	2.2341
松樹	1.2779	4.9899	3.9127	1.9820	2.2341	--
平均	2.9205	4.7560	3.3386	2.6569	3.3600	2.8793

7.6、支持向量機於阿里山森林遊樂區實驗區兩時期影像分析

7.6.1、支持向量機分類之實驗方法說明

與 7.2.1、採用的支持向量機分析方法相同，同樣採用 Python 自行撰寫程式，為了可以提升分類成果，而程式亦可以有效率的運作，同樣選定 2,000 個像元以 7:3 的數量分配，其中 1,400 個像元為訓練資料、600 個像元為檢核資料，程式實際執行方式是利用支持向量機搭配不同核函數和參數設定，以逐像元的方式進行影像分類，採用的核函數與參數設定與 7.2.1、相同，包含：

1. 線性核函數；
2. 輻狀基底函數 (RBF)；
3. 採用近似係數的小波核函數 (wavelet kernel)；
4. 小波多核函數；
5. RBF 多核函數；
6. 自選離散小波多核函數；
7. 自選連續小波多核函數。

同樣將原始高光譜影像波段利用支持向量機選擇不同核函數，其餘參數設定均相同，多類別分類則採用一對多的方式，計算不同支持向量機的分類成果。

7.6.2、兩個時期影像個別分析之支持向量機分類成果

同樣分別將阿里山實驗區 105 年、107 年兩時期高光譜影像以不同支持向量機與多核學習法進行分類分析。105 年阿里山高光譜影像的不同支持向量機分類成果評估如表 7-15 所示，表中分類成果評估均是採用檢核資料集進行驗證。在採用單一核函數的支持向量機時，輻狀基底核函數 (RBF) 的分類成果最佳，整體分類準確度為 89.74%、Kappa 指標為 0.8769 和 F1-score 為 0.8978；明顯比線性核函數的 84.70% 分類準確度，以及單一小波核函數的分類準確度 82.69% 來得佳。當採用多核函數時，輻狀基

底多核函數的整體分類準確度為 84.36%，與小波多核函數的 84.70% 分類準確度相近，也與線性核函數的支持向量機分類成果相近。利用 KA 值選取核函數的離散多核函數以及連續多核函數的分類準確度分別為 80.03%、82.75%。

表 7-15、105 年度阿里山影像不同支持向量機之分類成果

SVM 核函數(參數)	OA(%)	Kappa 指標	F1-score
線性核函數	84.70	0.8164	0.8471
輻狀基底函數核函數 (r=default=1/96)	89.74	0.8769	0.8978
小波核函數 (採用近似係數，db3)	82.69	0.7923	0.8270
多核函數(小波核函數，cA2、 cD2、cD1)	84.70	0.8164	0.8471
多核函數 (RBF，0.001、0.01、0.1)	84.39	0.8127	0.8431
自選離散多核函數 (小波核函數，分解 3 次以 KA 值取 3)	80.03	0.7603	0.8002
自選連續多核函數 (連續小波核函數，scale=32 以 KA 值取 16)	82.75	0.7930	0.8282

根據前述的 105 年度阿里山實驗區影像不同支持向量機分類成果，同樣利用單一輻狀基底函數的支持向量機可以達到較其他支持向量機更好的分類成果，且計算效率比多核學習法來得佳。表 7-16 即為單一輻狀核函數的支持向量機樹種類別分類成果，訓練資料集的分類準確度為 91.46%、Kappa 指標為 0.8975，和 F1-score 為 0.9149，而檢核資料集的評估成果為整體分類準確度 89.74%、Kappa 指標為 0.8769，和 F1-score 為 0.8978。進一步根據檢核資料集比較不同樹種的分類成果，臺灣杉的分類成果最佳，生產者準確度與使用者準確度分別為 0.9780、0.9551，均大於 0.95，F1-score 為 0.9664，臺灣肖楠的分類成果次佳，F1-score 為 0.9318，再來是松樹和杉木，其 F1-score 分別為 0.9225、0.9060，最後則是檜木與柳杉的分類成果較差，其 F1-score 介於 0.81 至 0.84 之間。圖 7-17 為 105 年阿里山影像利用支持向量機(RBF 核函數)的分類成果圖，因為屬於逐像元分類，有椒鹽現象產生，各類別的分類結果大致與圖 7-14 的地真資料分布吻合，而類別分布以檜木和柳杉佔大部分，其中部分柳杉的區塊有較明顯被錯誤分類為檜木、杉木等類別。

表 7-16、105 年度阿里山影像支持向量機(RBF 核函數)分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	91.46	0.8975	0.9149	89.74	0.8769	0.8978
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.8703	0.8311	0.8502	0.8527	0.8162	0.8340
2 臺灣肖楠	0.9237	0.9571	0.9401	0.9160	0.9482	0.9318
3 杉木	0.9411	0.9150	0.9279	0.9280	0.8849	0.9060
4 柳杉	0.8000	0.9126	0.8526	0.7540	0.8934	0.8178
5 臺灣杉	0.9880	0.9681	0.9779	0.9780	0.9551	0.9664
6 松樹	0.9643	0.9080	0.9353	0.9560	0.8912	0.9225




圖 7-17、105 年度阿里山影像支持向量機(RBF 核函數)分類成果

107 年度阿里山高光譜影像利用不同支持向量機與多核學習法的檢核資料集評估分類成果如表 7-17 所示。在採用單一核函數時，以輻狀基底函數的支持向量機分類成果最佳，整體分類準確度為 86.76%，Kappa 指標為 0.8411、F1-score 為 0.8670，其次採用線性核函數的整體分類準確度為 84.27%，而採用單一小波核函數的支持向量機分類成果則略差於前述兩者，分類準確度則為 83.09%。

採用多核學習的支持向量機時，採用輻狀基底多核函數的支持向量機分類成果與採用單一的輻狀基底函數支持向量機分類成果相當接近，分類準確度為 86.84%；再比較小波多核函數的支持向量機，其中採用離散的小波多核函數分類成果最差，整體分類準確度不到 80%，而另外兩種小波多核函數則比採用輻狀基底函數差，與其他的分類成果相近。

表 7-18 為 107 年阿里山高光譜影像採用單一輻狀基底核函數的支持向量機分類成果，利用訓練資料集與檢核資料集的整體分類準確度分別為 87.81%、86.76%。不同樹種的分類成果評估，以松樹的分類成果最佳，生產者、使用者準確度、F1-score 分別為 0.9887、0.9494 和 0.9686，其次為臺灣肖楠，臺灣肖楠的 F1-score 為 0.9258，其他樹種的分類成果依序為臺灣杉、檜木，以兩樹種的 F1-score 均接近 0.9，而杉木與柳杉的分類

成果較差 F1-score 均低於 0.8，其中柳杉的生產者準確度較差，僅有 0.6807。圖 7-18 為 107 年阿里山影像的支持向量機(RBF 核函數)分類成果圖，可看出影像中也有椒鹽現象，而在影像左側海拔較低的區域柳杉的區塊有明顯被誤判之情形。

表 7-17、107 年度阿里山影像不同支持向量機之分類成果

SVM 核函數(參數)	OA(%)	Kappa 指標	F1-score
線性核函數	84.27	0.8113	0.8421
輻狀基底函數核函數 (r=default=1/96)	86.76	0.8411	0.8670
小波核函數 (採用近似係數，db3)	83.09	0.7971	0.8303
多核函數(小波核函數，cA2、 cD2、cD1)	84.28	0.8113	0.8421
多核函數 (RBF，0.001、0.01、0.1)	86.64	0.9397	0.8652
自選離散多核函數 (小波核函數，分解 3 次以 KA 值 取 3)	79.58	0.7550	0.7945
自選連續多核函數 (連續小波核函數，scale=32 以 KA 值取 16)	84.69	0.8163	0.8468

表 7-18、107 年度阿里山影像支持向量機(RBF 核函數)分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	87.81	0.8537	0.8779	86.76	0.8411	0.8670
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.9049	0.8805	0.8925	0.8713	0.8696	0.8705
2 臺灣肖楠	0.9391	0.9143	0.9266	0.9320	0.9197	0.9258
3 杉木	0.8137	0.7769	0.7949	0.7980	0.7728	0.7852
4 柳杉	0.6840	0.8608	0.7623	0.6807	0.8274	0.7469
5 臺灣杉	0.9329	0.8732	0.9021	0.9347	0.8591	0.8953
6 松樹	0.9940	0.9605	0.9770	0.9887	0.9494	0.9686




圖 7-18、107 年度阿里山影像支持向量機(RBF 核函數)分類成果

7.7、一維卷積神經網路於阿里山森林遊樂區兩時期影像分析

7.7.1、一維卷積神經網路之實驗方法說明

阿里山森林遊樂區的兩時期高光譜影像以一維卷積神經網路(1D CNN)進行高光譜影像分類之分析，同樣透過 Python 程式進行實作，該神經網路同樣為一個 5 層的神經網路架構於高光譜影像分類，卷積神經網路如圖 7-19 所示，各網路層說明如下：

1. 輸入層：單一像元即為一個輸入資料，大小為 72×1 (1 維向量)；
2. 卷積層：建立 20 個濾波器，濾波器大小為 8，產生 20 個 72×1 的節點；
3. 池化層：利用 max pooling 將網路縮小為 20 個 24×1 的節點；
4. 全連結層：建立 100 個節點的全連結層；
5. 輸出層：根據目標類別數(6 個)，建立輸出層，亦為全連結層。

其中，因為影像波段數為 72，因此輸入層的向量為 72×1 ，卷積層的濾波器大小也設定較小的 8，經過池化層後，每一個節點為 24×1 的向量。實驗區圈選的目標區域涵蓋的像元數超過百萬個像元，因此選定像元資料的 1/10，並以 3:7 的數量分配訓練資料與檢核資料，而訓練資料中又取出 1/3 做為驗證資料；實際操作透過卷積神經網路學習以逐像元方式進行分類，因卷積神經網路為批次學習的模式，因此每此放入 256 個訓練資料(256 patch)，進行 100 次的運算學習(100 epoch)，學習速率為 0.001。




圖 7-19、一維卷積神經網路示意圖(修改自 Hu et al.,2015)

7.7.2、兩時期影像個別分析之一維卷積神經網路分類成果

利用一維卷積神經網路於 105 年度阿里山高光譜影像分類的成果如表 7-19 所示，阿里山影像用一維卷積神經網路的分類成果與出雲山實驗區的成果相近，整體分類準確度大約再 90%左右。首先訓練資料集的分類成果評估為分類準確度 92.03%、Kappa 指標為 0.8414、F1-score 為 0.8758；而檢核資料集的分類成果為整體分類準確度為 90.88%、Kappa 指標為 0.8184、F1-score 為 0.8379。

檢視檢核資料集的單一類別分類成果，大部分的類別都有良好的分類準確度，6種樹種的分類成果有明顯的差異，其中柳杉的分類成果最佳，F1-score 為 0.9343，其次依序為檜木、台灣杉、杉木、臺灣肖楠，F1-score 介於 0.83 到 0.88 之間，最後則是松樹的分類成果明顯比其他類別差，生產者準確度、使用者準確度與 F1-score 分別為 0.6849、0.6643、0.6744。圖 7-20 為 105 年度阿里山影像採用一維卷積神經網路的分類成果圖，與地真資料的分布比對，各類別的分類成果大致吻合，成果圖中椒鹽現象也比較少，可以明顯看出柳杉與檜木被錯誤分類的情形，其他樹種的分類結果則相對良好。

表 7-19、105 年度阿里山影像一維卷積神經網路分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	92.03	0.8414	0.8758	90.88	0.8184	0.8379
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.8886	0.8887	0.8887	0.8764	0.8748	0.8756
2 臺灣肖楠	0.8069	0.9410	0.8688	0.7808	0.9070	0.8392
3 杉木	0.8434	0.9144	0.8775	0.8039	0.8846	0.8423
4 柳杉	0.9439	0.9393	0.9416	0.9365	0.9321	0.9343
5 臺灣杉	0.8884	0.9325	0.9099	0.8321	0.8828	0.8567
6 松樹	0.7765	0.7510	0.7635	0.6849	0.6643	0.6744




圖 7-20、105 年度阿里山影像一維卷積神經網路分類成果圖

107 年度阿里山高光譜影像利用一維卷積神經網路的分類成果如表 7-20 所示，107 年度的阿里山高光譜影像與 105 年阿里山影像相比整體的分類成果略差，但幅度較小；首先訓練資料集的分類成果評估為分類準確度 89.87%、Kappa 指標為 0.7769、F1-score 為 0.7908；而檢核資料集的分類成果為整體分類準確度為 89.58%、Kappa 指標為 0.7710、F1-score 為 0.7803。檢視檢核資料集的單一類別分類成果，僅有柳杉的分類成果較佳，生產者準確度、使用者準確度和 F1-score 分別為 0.9422、0.9164、0.9291，均大於 0.9；其次為檜木的 F1-score 為 0.8534，而其他類別的 F1-score 都小於 0.8，分別為松樹、臺灣肖楠和臺灣杉，對應的 F1-score 為 0.7716、0.7607 和 0.7395，最後則是杉木的分類成果最差，F1-score 只有 0.5986。圖 7-21 為 107 年阿里山影像採用一維卷積神經網路的分類成果圖，與地真資料的分布比對，各類別的分類成果大致吻合，其中可以明顯看出部分柳杉區塊被錯誤分類之情形。

表 7-20、107 年度阿里山影像一維卷積神經網路分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	89.87	0.7769	0.7908	89.58	0.7710	0.7803
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.8340	0.8814	0.8571	0.8308	0.8773	0.8534
2 臺灣肖楠	0.8740	0.6883	0.7701	0.8738	0.6735	0.7607
3 杉木	0.5420	0.6735	0.6006	0.5451	0.6637	0.5986
4 柳杉	0.9446	0.9175	0.9309	0.9422	0.9164	0.9291
5 臺灣杉	0.7540	0.7604	0.7572	0.7414	0.7375	0.7395
6 松樹	0.7222	0.9000	0.8014	0.6925	0.8713	0.7716




圖 7-21、107 年度阿里山影像一維卷積神經網路分類成果圖

7.8、混合三維及二維卷積神經網路於阿里山森林遊樂區影像分析

7.8.1、混合三維及二維卷積神經網路之實驗方法說明

與出雲山實驗影像類似，阿里山森林遊樂區高光譜影像以混合三維及二維卷積神經網路(HybridSN)進行影像分類之分析時，同樣透過 Python 程式進行實作，以三個三維卷積層及一個二維卷積層萃取特徵之後，再利用一全連結層進行分類，HybridSN 神經網路如圖 7-10 所示，各網路層之說明請參考 7.4.1 節。

7.8.2、阿里山森林遊樂區 HybridSN 卷積神經網路之影像分類成果

利用 HybridSN 神經網路於 105 年度阿里山高光譜影像分類的成果如表 7-21 所示，相較於出雲山苗圃之影像分類成果略差，但在檢核資料集的分類成果為整體分類準確度為 98.52%、Kappa 指標為 0.9708、F1-score 為 0.9852，仍為十分良好的分類成果。若檢視檢核資料集中單一類別分類成果，大部分的類別都具有良好的分類準確度，6 種樹種的 F1-score 均接近或大於 0.95，其中柳杉的分類成果最佳，F1-score 為 0.99，其次依序為檜木、杉木、台灣杉、松樹及台灣肖楠，F1-score 都接近或大於 0.95。圖 7-22 為 105 年度阿里山影像採用一維卷積神經網路的分類成果圖，與地真資料的分布比對，各類別的分類成果幾乎吻合，成果圖中椒鹽現象也比較少，顯示三維及二維卷積網路確實可以萃取並學習對分類有用的空間特徵。

表 7-21、105 年度阿里山影像 HybridSN 神經網路分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	100.00	1.0000	1.0000	98.84%	0.9770	0.9884
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	1.0000	1.0000	1.0000	0.9842	0.9838	0.9840
2 臺灣肖楠	1.0000	1.0000	1.0000	0.9389	0.9972	0.9672
3 杉木	1.0000	1.0000	1.0000	0.9789	0.9840	0.9815
4 柳杉	1.0000	1.0000	1.0000	0.9918	0.9915	0.9917
5 臺灣杉	1.0000	1.0000	1.0000	0.9944	0.9908	0.9926
6 松樹	1.0000	1.0000	1.0000	0.9569	0.9534	0.9552




圖 7-22、105 年度阿里山影像 HybridSN 神經網路分類成果圖

7.9、遷移學習法於出雲山苗圃實驗區及阿里山森林遊樂區實驗區影像分析

本計畫中遷移學習法主要利用卷積神經網路，將訓練好的模型，利用其他時期或其他區域的影像資料，以較少量的訓練資料調整模型的參數，進行影像分析，實驗主要針對兩時期出雲山苗圃影像和兩時期阿里山森林遊樂區影像，進行多時期影像的遷移學習分析；而利用 108 年出雲山苗圃影像與 105 年阿里山影像進行多區域的遷移學習分析。

7.9.1、一維卷積神經網路遷移學習法於出雲山苗圃實驗區影像多時期影像分析

一維卷積神經網路遷移學習法於出雲山苗圃多時期影像分類，一樣透過 Python 程式的相關深度學習模組，建立一個 5 層的神經網路架構於高光譜影像分類。在建構一維卷積神經網路前，需要先將 108 年、109 年出雲山苗圃的高光譜影像進行前處理，雖然兩時期的出雲山苗圃高光譜影像均為 96 波段，但兩者的波長涵蓋範圍不完全相同，108 年度影像為 364.5nm-1042.6nm、109 年度影像為 376.0nm-1054.8nm，每一波段對應的波長也不相同，因此須將後期 109 年度每一波段影像內插至與 108 年度影像相同，因此最後會獲得兩時期影像為 94 波段，波長涵蓋範圍為 378.8nm-1042.6nm。同樣建立 5 層的一維卷積神經網路，各層說明如下：

1. 輸入層：單一像元即為一個輸入資料，大小為 94×1 (1 維向量)；
2. 卷積層：建立 20 個濾波器，濾波器大小為 10，產生 20 個 94×1 的節點；
3. 池化層：利用 max pooling 將網路縮小為 20 個 32×1 的節點；
4. 全連結層：建立 100 個節點的全連結層；
5. 輸出層：根據目標類別數(6 個)，建立輸出層，亦為全連結層。

利用 108 年出雲山苗圃影像訓練後保留模型與參數，進一步利用 109 年度出雲山苗圃影像，透過少量的訓練樣本，約為原始訓練樣本的 30%，進一步更新整體模型的參數，以利於後期影像分類。

將兩時期出雲山苗圃高光譜影像以一維卷積神經網路遷移學習的方式進行影像分類之分析，可以採用較少的訓練樣本，約為原始訓練樣本的30%，同時模型訓練的時間也縮短約 1/3。分類成果評估如表 7-22 所示，首先訓練資料集的分類成果評估為分類準確度 88.94%、Kappa 指標為 0.8422、F1-score 為 0.8562；而檢核資料集的分類成果為整體分類準確度為 86.75%、Kappa 指標為 0.8108、F1-score 為 0.8236。檢視檢核資料集的單一類別分類成果，其中以杉木的分類成果最佳，F1-score 為 0.8883，其次為臺灣肖楠、柳杉和臺灣櫟，其 F1-score 均大於 0.83，檜木和臺灣杉的分類成果較差，其中檜木的 F1-score 為 0.7933，與前述的類別差異不大，而臺灣杉的 F1-score 為 0.6672，其中可以看到杉木的生產者準確度較低，為 0.6346，圖 7-23 為 109 年度出雲山苗圃影像一維卷積神經網路多時期遷移學習的分類成果圖，主要可以看出臺灣杉的區塊有被錯誤分類為杉木的情形，其他類別的分類成果大致與圈選的目標區域相似，雖然兩時期拍攝的條件不完全相同，獲得的光譜曲線輻射值有資料分布上的差異，透過遷移學習，以少量的訓練資料將原有模型的參數重新訓練，即可對後期影像有良好的分析成果。

表 7-22、109 年度出雲山苗圃一維卷積神經網路遷移學習分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	88.94	0.8422	0.8562	86.75	0.8108	0.8236
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.8189	0.8739	0.8455	0.7727	0.8150	0.7933
2 臺灣肖楠	0.8768	0.9232	0.8994	0.8655	0.9079	0.8862
3 杉木	0.9178	0.8920	0.9047	0.8984	0.8784	0.8883
4 柳杉	0.9174	0.8731	0.8947	0.8879	0.8434	0.8651
5 臺灣杉	0.6745	0.7615	0.7153	0.6346	0.7034	0.6672
6 臺灣櫟	0.8106	0.9413	0.8711	0.7752	0.9052	0.8352




圖 7-23、109 年度出雲山苗圃一維卷積神經網路遷移學習分類成果

7.9.2、一維卷積神經網路遷移學習法於阿里山森林遊樂區實驗區影像多時期影像分析

與 7.9.1 節分析出雲山苗圃影像類似，同樣利用兩時期阿里山森林遊樂區影像進行一維卷積神經網路遷移學習，透過 Python 程式進行實作，建立一個 5 層的一維卷積神經網路，利用 105 年阿里山影像訓練後保留模型與參數，進一步利用 107 年度阿里山影像，透過少量的訓練樣本，約為原始訓練樣本的 30%，進一步更新整體模型的參數，以利於後期影像分類。

將 105 年阿里山實驗區影像建立一維卷積神經網路後，透過遷移學習的方式分析 107 年阿里山實驗區之影像，不僅減少了所需的訓練樣本，模型訓練的時間也縮短約 1/3。表 7-23 為遷移學習後 107 年阿里山影像分類成果評估，首先訓練資料集的分類準確度為 90.63%、Kappa 指標為 0.7998、F1-score 為 0.8146，而檢核資料集的整體分類準確度約減少 1%，為 89.76%，Kappa 指標為 0.7804、F1-score 為 0.7797。檢視檢核資料集的單一類別分類成果，其中以柳杉的分類成果最佳，生產者準確度、使用者準確度與 F1-score 皆大於 0.92，其次檜木的 F1-score 為 0.8676，而檜木的使用者準確度明顯低於生產者準確度，其次為松樹、臺灣肖楠和臺灣杉的分類成果較差，F1-score 介於 0.74 到 0.79 之間，最後則是杉木的分類成果最差，F1-score 只有 0.5405，並可以發現杉木的生產者準確度較低，僅有 0.4336，漏判的情形明顯。圖 7-24 為 107 年度阿里山森林遊樂區影像，以一維卷積神經網路遷移學習的分類成果圖，各類別的分類成果大致與圈選的目標區域相符，僅有在影像左側的杉木區塊被錯誤分類為柳杉或是臺灣杉，以及影像右側的柳杉區域被錯誤為檜木，透過阿里山多時期影像遷移學習分析，同樣可看出以少量的訓練資料將原有模型的參數重新訓練，可獲得後期影像有良好的分析成果。

表 7-23、107 年度阿里山一維卷積神經網路遷移學習分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	90.63	0.7998	0.8146	89.76	0.7804	0.7797
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.9150	0.8433	0.8777	0.9030	0.8348	0.8676
2 臺灣肖楠	0.7662	0.8419	0.8023	0.7241	0.8142	0.7665
3 杉木	0.4480	0.7967	0.5736	0.4336	0.7173	0.5405
4 柳杉	0.9275	0.9407	0.9341	0.9216	0.9354	0.9285
5 臺灣杉	0.8217	0.7615	0.7905	0.7694	0.7202	0.7440
6 松樹	0.9198	0.7961	0.8535	0.8527	0.7327	0.7882




圖 7-24、107 年度阿里山森林遊樂區一維卷積神經網路遷移學習分類成果

7.9.3、一維卷積神經網路遷移學習法於出雲山苗圃、阿里山森林遊樂區實驗區影像多區域影像分析

多區域的遷移學習法於高光譜影像分類之分析，將會以 108 年度的出雲山苗圃影像為基準訓練出模型後，用於 107 年度阿里山影像的遷移學習法分。首先仍需要將兩組資料進行前處理，108 年度的出雲山苗圃影像為 96 波段，而 107 年度阿里山影像為 72 波段，因此需將 108 年度出雲山影像內插為 72 波段，波長涵蓋範圍在 365.7nm-1041.4nm 之間。建立 5 層的一維卷積神經網路，各層說明如下：

1. 輸入層：單一像元即為一個輸入資料，大小為 72×1 (1 維向量)；
2. 卷積層：建立 20 個濾波器，濾波器大小為 8，產生 20 個 72×1 的節點；
3. 池化層：利用 max pooling 將網路縮小為 20 個 24×1 的節點；
4. 全連結層：建立 100 個節點的全連結層；
5. 輸出層：根據目標類別數(6 個)，建立輸出層，亦為全連結層。

利用 108 年出雲山苗圃影像訓練後，保留模型至遷移學習，將舊有的輸出層刪除加入新的輸出層(目標類別數會有改別之情形)，第 1 層輸入層至第 4 層全連結層的模型參數不會重新訓練，進一步利用 107 年度阿里山影像訓練輸出層，一維卷積神經網路遷移學習的模型如圖 7-25 所示。




圖 7-25、多區域一維卷積神經網路遷移學習示意圖

將多區域的遷移學習進行高光譜影像分類之分析，成果如表 7-24 所示，首先訓練資料集的分類成果評估為分類準確度 84.69%、Kappa 指標為 0.6625、F1-score 為 0.6251；而檢核資料集的分類成果為整體分類準確度為 84.94%、Kappa 指標為 0.6658、F1-score 為 0.6175。檢視檢核資料集的單一類別分類成果，可以看出柳杉和檜木的分類成果明顯比其他類別來得佳，F1-score 分別為 0.8955 和 0.8064，其次依序為松樹、臺灣肖楠，這兩類別的 F1-score 皆大於 0.6，而杉木與臺灣杉的分類成果最差，F1-score 僅有 0.3348 和 0.2450，從各類別的分類結果可以看出影像中柳杉與檜木所佔的範圍最廣，因此訓練資料的像元個數也比其他類別多出許多；其次是松樹的訓練資料像元數也比其他類別多，因此在遷移學習中有較多的訓練資料的類別可以訓練出更好的模型參數，對應的分類成果也較佳，此外，由於柳杉與檜木的像元數佔訓練和檢核資料的大部分，因此雖然有部分類別的分類成果較差，整體的分類準確度仍然有 84% 以上。圖 7-26 為 107 年度阿里山影像一維卷積神經網路多區域遷移學習的分類成果，其中影像左側的杉木與臺灣杉分類錯誤情形較明顯，影像右側則是柳杉的錯誤分類情形較明顯。由於兩組影像資料的拍攝條件不完全相同，獲

得的光譜曲線輻射值有資料分布上的差異，再加上遷移學習中，舊有模型的參數是不可以被重新訓練，因此會使得模型參數是以前期影像訓練而成，較不利於後期影像的分類分析，但其中可注意阿里山影像的類別中，松樹原本不存在於出雲山苗圃影像中，在足夠的訓練資料下仍可進行分類，顯示多區域的遷移學習對於不同的類別組成，仍有一定的分析能力。

表 7-24、107 年度阿里山影像一維卷積神經網路遷移學習分類成果

	訓練資料集			檢核資料集		
	OA(%) Kappa 指標 F1-score			OA(%) Kappa 指標 F1-score		
	84.69	0.6625	0.6251	84.94	0.6658	0.6175
類別	PA (recall)	UA (precision)	F1-score	PA (recall)	UA (precision)	F1-score
1 檜木	0.8199	0.7900	0.8047	0.8180	0.7951	0.8064
2 臺灣肖楠	0.5485	0.7171	0.6216	0.5454	0.6883	0.6086
3 杉木	0.2542	0.4913	0.3350	0.2599	0.4704	0.3348
4 柳杉	0.9048	0.8813	0.8929	0.9074	0.8839	0.8955
5 臺灣杉	0.1529	0.5680	0.2410	0.1534	0.6075	0.2450
6 松樹	0.7372	0.7079	0.7223	0.7019	0.6453	0.6724




圖 7-26、107 年度阿里山影像一維卷積神經網路遷移學習分類成果

7.10、應用機器學習演算法於多時期高光譜影像分析之討論

本年度計畫中分別建立了支持向量機和卷積神經網路進行多時期、多區域的高光譜影像重要樹種分析，並採用了 108 年、109 年出雲山苗圃實驗區和 105 年、107 年阿里山森林遊樂區實驗區等兩個區域各兩個時期的影像進行實驗分析，並且選定檜木、臺灣肖楠、杉木、柳杉、臺灣杉、臺灣檫及松樹等樹種做為重要樹種進行分類，其中臺灣檫在出雲山苗圃實驗區影像資料中才有，松樹則在阿里山森林遊樂區實驗區才有；在進行實際高光譜影像利用本計畫的機器學習演算法分析前，先透過巴氏距離的計算進行樹種類別的統計分析，其中在出雲山苗圃影像中以杉木、臺灣杉的平均類別分離度較低，在阿里山影像中則是柳杉的平均類別分離度較低，在後續的分類分析中，也可發現這幾個類別的分類準確度較低。

根據本章的不同機器學習演算法分別用於出雲山苗圃、阿里山高光譜影像分析結果，根據本年度計畫實驗資料之檢核資料集的分類成果而言：

- (1) 採用支持向量機進行高光譜影像樹種分類分析實驗中，在核函數的選擇上採用單一輻狀基底(RBF)核函數，比線性或小波核函數的支持向量機分類成果佳，在實驗資料中可以超過 80%或是 90%以上的分類準確度；在採用多核演算法時，採用輻狀基底多核函數可以達到與單一 RBF 核函數相當的分類成果，小波多核函數則可以和線性核函數相似的分類成果，但由於多核函數所需的計算資源比單一核函數來得多，以整體運算效率而言，以採用單一輻狀基底(RBF)核函數為較合適的支持向量機分析方法。當支持向量機用於多時期高光譜影像分類分析時，實際高光譜影像可能會因為拍攝條件的不同，不同時期影像的光譜輻射值資料分布有所差異，若同時用於支持向量機模型訓練，無法達到個別分析的分類效果，而新的影像資料也不適宜直接利用舊有支持向量機模型分析，因此，若是採用光譜輻射值時，較不適宜利用支持向量機於多時期高光譜影像樹種分析。
- (2) 採用卷積神經網路進行高光譜影像樹種分類分析的實驗中，以較簡單

的一維卷積神經網路(1D CNN)即可以達到良好的分類成果，不論是出雲山苗圃高光譜影像或是阿里山高光譜影像均可以達到接近甚至是超過 90%的分類準確度，而利用二維或三維的卷積神經網路進行分析，雖然需要耗費較多的計算資源與時間，但卻可以達到接近 100%的分類準確度。而在建構卷積神經網路模型時，則須注意要針對資料來源，如高光譜影像的大小、波段數、分類數等，對於網路結構中的參數進行調整，如濾波器的大小、輸入輸出層的個數。

- (3) 在本計畫中主要利用遷移學習進行多時期、多區域的高光譜影像分析，實驗中利用訓練好的模型用於多時期、多區域的高光譜影像分析，在以訓練好的模型，針對新增之高光譜影像，以較少量的訓練樣本數，調整模型之參數，同一區域多時期遷移學習，可透過模型參數調整達到良好的分類成果，且運算時間較少；而多區域的遷移學習則容易受到訓練樣本數的影響，當某一類別的訓練樣本較多時，分類成果較佳。

根據本年度計畫中所採用的不同時期高光譜影像資料、類別選定、採用之機器學習演算法，對於森林樹種的分析可以討論的因素包含：

- (1) 高光譜影像的波段數、波長涵蓋範圍：在單一影像分析時，波段數和波長涵蓋範圍不會影響分析的流程，而須注意可能會有部分波段資料為雜訊需進行資料清理。若需要多時期資料進行遷移學習的分析，則需要統一輸入資料的波段數、波長涵蓋範圍，才能運用訓練好的模型進行分析。
- (2) 高光譜影像的資料型態：在單一影像分析時，採用光譜輻射值或是反射值都可以進行樹種類別的分類分析，然而不同物種類別的光譜反射值皆不相同且具有單一性，不因拍攝條件的變化而改變，因此若採用光譜反射值較有利於多時期的高光譜影像分類分析。
- (3) 物種類別數與類別定義：物種類別的選定和類別數是以研究目標去決定的，機器學習的模型會根據分類目標完成訓練。
- (4) 機器學習演算法：由本計畫的實驗中，採用混合三維、二維卷積神經網路成果最佳，可達到接近 100%的分類準確度，而一維卷積神經網

路的分類成果比支持向量機來的佳，但不同方法所需要的訓練資料、電腦效能、時間皆不同，仍需要更具當下的環境設備選擇合適的分析方法。

捌、建立多期高光譜影像應用於重要樹種偵測自動流程

本計畫延續前期之研究，蒐集出雲山苗圃、大雪山森林遊樂區和阿里山森林遊樂區之多時期高光譜影像，並且選定了中低海拔常見 7 種類之針葉、闊葉樹種，以不同方法進行高光譜影像的樹種分類分析，本年度主要集中於採用機器學習的相關演算法進行分析，並根據計畫的實驗成果探討利用自動化演算法於不同時期高光譜影像於臺灣地區重要樹種偵測之適用性。

根據本計畫的實驗流程與結果，若要建立不同時期高光譜影像於重要樹種自動化偵測的演算法，需考量幾個因素：

- (1) 高光譜影像光譜資料類型：雖然光譜值為輻射值或反射值均可以進行樹種分類分析，而不同物種有其對應的光譜反射曲線，若要進行多時期或多區域的高光譜影像重要樹種偵測，採用光譜反射值將是較適宜的研究資料。
- (2) 高光譜影像資料之前處理：不同高光譜影像中可能會有不同的影像波段數、波長涵蓋範圍，部分的波段值也有可能屬於雜訊，則需要透過人工的介入進行資料前處理，包含雜訊清理，以其多時期資料分析時，需要將高光譜資料的波段數及對應的波長統一，因此可能需要加入資料內插的步驟。
- (3) 類別選定與訓練資料：類別的選定對於高光譜影像樹種的分析並沒有影響，但選定類別之後，則須建立對應的訓練資料，如有對應的光譜資料庫則可以做為訓練資料，或於影像中圈選 ROI，ROI 以選擇純像元為目標，並且排除空像元、雲遮蔽像元或是陰影區。
- (4) 機器學習演算法：若要建立多時期高光譜影像於重要樹種偵測之自動演算法，深度學習方法中卷積神經網路是較適宜的演算方法，在確定資料輸入型態、類別後，即可決定對應之參數，並建立自動化的流

程。

因此根據本計畫的實驗經驗與前述的考量因素，不同時期高光譜影像於臺灣地區重要樹種於高光譜影像自動化偵測之流程，如圖 8-1 所示，若已蒐集的多時期高光譜影像，並組成影像資料庫，而高光譜影像要用於樹種類別分析前，需進行資料前處理和訓練資料的建立，而此步驟可能需要人工介入，包含在光譜資料中可能會有雜訊，可透過統計分析的方式排除雜訊。在確定影像分析的範圍後則需要獲取合適的訓練資料，可透過光譜資料庫或是由影像中圈選目標區域(ROI)，而用於訓練模型的影像資料，則須排除空像元、陰影像元或雲遮蔽區域，除了透過人工圈選外，也可以利用植生指標等指標輔助判斷。獲取影像資料與對應的訓練資料後，則可將影像資料進行深度學習分析，建立合適的神經網路模型並進行訓練，完成模型評估後，即擁有一組以完成訓練的深度學習模型；當有新增的高光譜影像時，即可直接透過現有模型完成分類分析，後續再進行成果評估與應用，隨著多時期高光譜影像資料的增加，原有的深度學習模型可能不敷使用，則新增的高光譜影像和對應的訓練資料，亦可加入模型調整並更新，讓高光譜影像分析的演算模型更加穩定，即完成自動化分析流程。




圖 8-1、多時期高光譜影像自動化分類分析流程圖

玖、結論與建議

本計畫「應用高光譜航遙測影像於重要樹種調查之研究」為 2 年期計畫，主要蒐集實驗區機載高光譜影像，包含了出雲山苗圃、大雪山森林遊樂區和阿里山森林遊樂區等 3 個區域多時期、多區域影像，其中出雲山苗圃影像為 108 年度「應用高光譜航遙測影像於土地覆蓋型調查之研究」計畫及 109 年度本計畫所拍攝，大雪山森林遊樂區影像為 109 年度本計畫航拍之影像，阿里山森林遊樂區影像則蒐集歷史高光譜影像。本計畫另一重要工作項目則是建立高光譜影像自動化演算法於重要樹種調查之分析，計畫中將高光譜影像分類法概分為三類，包含：(1)特徵分類法、(2)結合空間資訊的特徵分類法、(3)以機器學習為基礎的分類法。團隊於先前研究案已完成三類分類演算法的理論彙整及分析流程建立與優化，並實際將不同演算法用於出雲山苗圃實驗區高光譜影像分類，本年度計畫則進一步針對機器學習演算法的核方法與深度學習演算法進行優化，並且延伸至多時期、多區域的高光譜影像分析，本年度同樣利用出雲山苗圃和阿里山森林遊樂區高光譜影像來實際進行樹種類別分析，最後則根據研究成果建立一個多時期高光譜影像應用於重要樹種偵測自動流程。

歸納整理本計畫所使用的三類分類演算法之實驗方法、效率與成果如下：

(一) 特徵分類法

特徵分類法主要是整合不同特徵萃取方法與最大似然法進行影像分類，計畫中嘗試 PCT、DAFE、DBFE 和小波特徵萃取法，不同方法需要利用不同軟體或是程式依序處理，雖然特徵萃取方法是既有且成熟的演算法，參數設定較簡單，主要需選定用於分類的特徵數目，以及在特徵影像與分類程式之間有資料格式轉換之問題，此方法將高光譜分析分為 2 個步驟，所需要的操作與程式運算時間較多。在分類成果採用 DBFE、DAFE 的特徵萃取可獲取較穩定的分類成果，但比其他分類方法的分類準確度差，出雲山苗圃影

像整體分類準確度接近或低於 80%。

(二) 結合空間資訊的特徵分類法

結合空間資訊的特徵分類法是以物件分類法進行操作，雖然透過既有商業軟體 eCognition 分析，分類的流程依序為影像分割、建立特徵以及影像分類，首先，影像分割會根據影像本身場景有所變化，需透過操作者主觀決定並花費時間進行試誤；建立特徵影像則需要逐一處理各項特徵，且參數設定複雜，還需要另外的分析工具判斷特徵影像的合適性，最後則是影像分類包含常見的決策樹、最鄰近法與支持向量機，其中決策樹方法雖然最常使用，但也需要大量操作者主觀試誤，因此整體而言以物件為基礎的分類方法，需要大量的主觀操作，需花費最多的時間操作執行。其分類成果則略優於特徵分類法，出雲山苗圃影像整體分類準確度接近 85%。

(三) 以機器學習為基礎之分類法

計畫中採用了兩種機器學習演算法，包含支持向量機與卷積神經網路；在機器學習的演算法中，是針對影像的原始光譜資訊進行操作分析，只要完備了實驗影像與訓練資料，不需經過前處理程序即透過單一程式進行影像分類分析。支持向量機方法需要選定核函數及對應的參數，在實驗中嘗試了多個單核函數及多核函數，透過輻狀基底核函數即可以獲得良好的分類成果，同時計算效率比多核函數佳。卷積神經網路的方法則是根據影像資料的波段數、類別數，對於網路結構的參數進行調整，包含卷積層、池化層、連結層的層數和參數，濾波器大小、輸入輸出層個數等。在實驗中利用一維卷積神經網路(1D CNN)在單一高光譜影像資料分類分析即可以達到良好的分類成果，出雲山苗圃影像可達到 90%左右的分類準確度，混合三維與二維的卷積神經網路(HybridSN)更可以達到接近 100%的分類準確度。

除了上述三類高光譜影像自動演算法之測試及分析之外，本研究也加入遷移學習的概念，將卷積神經網路的模型用於多時期、多區域高光譜影像分析。因本案所使用的深度學習屬監督式訓練，訓練成果與原訓練區資料關係密切，若其他區域資料特性與原訓練區資料類似，則理論上可獲得類似的

分類準確度，但實際上受環境及拍攝時間影響，造成其他區域與原訓練區域資料特性差異太大，則將獲得較差的分類成果，但透過本案所提遷移學習將可解決此問題。

本計畫機器學習方法透過自行撰寫的 Python 程式，整體操作較簡單，而計算時間主要受到分析的影像資料量影響，資料量越大計算時間較長，並且須注意記憶體不足的問題。

本計畫根據上述之研究成果，提出未來建議如下：

- (一) 本研究目前已針對中低海拔常見 7 種類之針葉、闊葉樹種進行高光譜影像分類效能之分析與評估，未來可再針對更多樹種進行分類效能之評估及分析。
- (二) 進行深度學習時，必須先蒐集足夠的地真資料，並與影像進行幾何位置上的對應及標示 (labeling)，此工作通常需要較多的人工介入，且需耗費較多時間。建議可預先蒐集並彙整各種不同來源的森林調查圖資，並針對已知樹種的幾何分布範圍進行確認後做成 GIS 圖層，以供後續影像分類參考使用；此外，針對地真資料與高光譜影像之對應及標示作業，可再結合光譜類別自動統計分析以協助人工進行訓練資料之標示作業。
- (三) 除了本研究所使用之一維卷積神經網路及混合三維及二維卷積神經網路之外，目前尚有許多不同的深度網路架構可用來進行高光譜影像分類，未來可再針對新的網路架構進行測試及分析，以提升高光譜影像應用於樹種分類之效能。
- (四) 本研究已提出遷移學習方式，透過預先訓練的模型及較少的樣本可對不同時期、不同區域之高光譜影像進行分析及分類，未來可再針對遷移學習方式進行精進，以進一步降低地真資料調查之需求。
- (五) 進行多時期高光譜影像分析時，可能會面臨不同時期影像空間解析度不一致、光譜波段數不同、以及影像是否進行大氣校正等問題，未來可針對不同分類演算法提出相對應的解決對策。
- (六) 除了樹種分類之應用外，未來可針對其他應用，如外來樹種偵測、植

被健康度評估、森林生態指標反衍等應用進行可行性測試及評估。

- (七) 理論上，分類任務可於影像空間藉由光譜資訊進行。然而，由於品質驗證所需，地真資料與影像資料必須有明確位置對應。本研究利用經由結合光達數值地表模型及高光譜影像產製正射影像並進行樹種分類，衍生兩議題: (1)數值地表模型品質如何影響正射影像品質，進而影響分類成果? (2)經由良好正射處理之影像相較於原始影像，其對樹種分類品質之增益效果如何? 此兩議題值得作為後續工作評估對象。

參考文獻

1. AVIRIS NEXT GENERATION, 2021. <https://avirisng.jpl.nasa.gov/aviris-ng.html>.
2. 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.
3. Ballanti, L., L. Blesius, E. Hines and B. Kruse, 2016. Tree Species Classification Using Hyperspectral Imagery: A Comparison of Two Classifiers, Remote Sensing, 8(6): 445.
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. Chen, Y., H. Jiang, C. Li, X. Jia and P. Ghamisi, 2016. Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks. IEEE Transactions on Geoscience and Remote Sensing 54, 6232-6251.
9. Chen, Y., N. M. Nasrabadi and T. D. Tran, 2011. Hyperspectral Image Classification Using Dictionary-Based Sparse Representation, IEEE Transactions on Geoscience and Remote Sensing, 49(10): 3973-3985.
10. 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.

11. Cortes, C. and V. Vapnik, 1995. Support-vector Networks, Machine-Learning, 20:273-297.
12. Cristianini, N, J. Shawe-Taylor, A. Elisseeff and J. Kandola, 2002. On Kernel Target alignment, Advances in Neural Informtion Processing Systems, 14: 367-373.
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. Farabet, C., C. Couprie, L. Najman and Y. LeCun, 2013. Learning Hierarchical Features for Scene Labeling, IEEE Transactions on Pattern Analysis and Machine Intelligence, 35: 1915-1929.
15. Forest Service, U.S. DEPARTMENT of AGRICULTURE, 2021. Forest Health Protection Aviation Safety and Aerial Survey. <https://www.fs.fed.us/foresthealth/applied-sciences/aviation/>.
16. Fricker, G. A., J. D. Ventura, J. A. Wolf, M. P. North, F. W. Davis and J. Franklin, 2019. A Convolution Neural Network Classifier Identifies Tree Species in Mixed-Conifer Forest from Hyperspectral Imagery, Remote Sensing, 11: 2326.
17. 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.
18. 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.
19. Goetz, A. F. H., G. Vane, J. E. Solomon and B. N. Rock, 1985. Imaging Spectrometry for Earth Remote Sensing, Science, 228:1147-1153.
20. 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, Berling Heidelberg, Germany, pp. 171-206.
21. Gönen, M. and E. Alpaydın, 2011. Multiple Kernel Learning Algorithms, Journal of Machine Learning Research, 12: 2211-2268.

22. Gonzalez, R. C. and R. E. Woods, 2002. Digital Image Processing, Upper Saddle River, N.J.: Prentice Hall.
23. Gu, Y., C. Wang, D. You, Y. Zhang, S. Wang, and Y. Zhang, 2012. Representative Multiple Kernel Learning for Classification in Hyperspectral Imagery, IEEE Trans. on Geoscience and Remote Sensing, 50(7): 2852-2865.
24. Haralick, R. M., K. Shanmugam and I. H. Dinstein, 1973. Textural Features for Image Classification, IEEE Transactions on Systems, Man and Cybernetics, 3(6), 610-621.
25. Hati, J. P., S. Samanta, N. R. Chaube, A. Misra, S. Giri, N. Pramanick, K. Gupta, S. D. Majumdar, A. Chanda, A. Mukhop and S. Hazra, 2021. Mangrove Classification Using Airborne Hyperspectral AVIRIS-NG and Comparing with Other Spaceborne Hyperspectral and Multispectral data, The Egyptian Journal of Remote Sensing and Space Sciences, 24(2021):273-281.
26. He, K., X. Zhang, S. Ren and J. Sun, 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.
27. He, M., B. Li and H. Chen, 2017. Multi-scale 3D Deep Convolutional Neural Network for Hyperspectral Image Classification, 2017 IEEE International Conference on Image Processing (ICIP 2017), IEEE, Beijing, China.
28. 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.
29. 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.
30. Hu, W., Y. Huang, L. Wei, F. Zhang and H. Li, 2015. Deep Convolutional Neural Networks for Hyperspectral Image Classification, Journal of Sensors, 2015(256619): 12pages.
31. Hycza, T., K. Sterenczak and R. Balazy, 2018. Potential Use of Hyperspectral Data to Classify Forest Tree Species, New Zealand Journal of Forestry Science, 48: 18.
32. Indian Space Research Organization(ISRO), 2017. Science Results from Phase-1 Airborne Hyperspectral Campaign with AVIRIS-NG over India, https://vedas.sac.gov.in/aviris_web/.
33. 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.
34. Jiang, T., H. van der Werff and F. van der Meer, 2020. Classification Endmember Selection with Multi-Temporal Hyperspectral Data, Remote Sensing, 12(10), 1575.
 35. Krizhevsky, A., I. Sutskever and G. E. Hinton, 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.
 36. Kubat, M., 2015. An Introduction to Machine Learning. Springer, Cham.
 37. Kumar, T., P. Kaur, K Chandrasekar and S Bandyopadhyay, 2020. AVIRIS-NG Hyperspectral Data for Mapping Mangrove Forests and Their Health Spatially, Journal of Tropical Forest Science, 32(3), 317-331.
 38. Landgrebe, D. A., 2003. Signal Theory Methods in Multi-Spectral Remote Sensing. New Jersey: John Wiley & Sons.
 39. LeCun, Y., B. E. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. E. Hubbard and L.a.D. Jackel, 1990. Handwritten Digit Recognition with a Back-Propagation Network, in: Touretzky, D.S. (Ed.), Neural Information Processing Systems 1998, Denver, CO, pp. 396-404.
 40. LeCun, Y., Y. Bengio and G. Hinton, 2015. Deep Learning, Nature 521, 436-444.
 41. Lee, C. and D. A. Landgrebe, 1993. Analyzing High-Dimensional Multispectral Data, IEEE Transactions on Geoscience and Remote Sensing, 31: 792-800.
 42. Lemley, J., S. Bazrafkan and P. Corcoran, 2017. Transfer Learning of Temporal Information for Driver Action Classification, Proceedings of the 28th Modern Artificial Intelligence and Cognitive Science Conference, Fort Wayne Indiana, pp.123-128.
 43. Li, Y., H. Zhang and Q. Shen, 2017. Spectral–Spatial Classification of Hyperspectral Imagery with 3D Convolutional Neural Network. Remote Sensing, 9: 67.
 44. Li, Y., H. Zhang, Z. Xue, Y. Jiang and Q. Shen, 2018. Deep Learning for Remote Sensing Image Classification: A Survey, Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 8(6): e1264.

45. 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.
46. Long, J., E. Shelhamer and T. Darrell, 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.
47. Makantasis, K., K. Karantza, A. Doulos and N. Doulos, 2015. Deep supervised learning for hyperspectral data classification through convolutional neural networks, 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS 2015). IEEE, Milan, Italy.
48. Mäyrä J., S. Keski-Saari, S. Kivinen, T. Tanhuanpää, P. Hurskainen, P. Kullberg, L. Poikolainen, A. Viinikka, S. Tuominen, T. Kumpula and P. Vihervaara, 2021. Tree Species Classification from Airborne Hyperspectral and LiDAR Data Using 3D Convolution Neural Networks, *Remote Sensing of Environment*, 256(2021):112322.
49. Mitchell, Tom M., 1997. *Machine Learning*. Mc Graw Hill, 414 pages.
50. Natural Resources Canada, 2019. <https://www.nrcan.gc.ca/forests/measuring-reporting/remote-sensing/13437>.
51. Noh, H., S. Hong and B. Han, 2015. Learning Deconvolution Network for Semantic Segmentation, 2015 IEEE International Conference on Computer Vision (ICCV 2015). IEEE, Santiago, Chile, pp. 1520-1528.
52. Rawat, W. and Z. Wang, 2017. Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review, *Neural Computation* 29, 2352-2449.
53. Roy, S. K., G. Krishna, S. R. Dubey, and B. B. Chaudhuri, 2020. HybridSN: Exploring 3-D-2-D CNN Feature Hierarchy for Hyperspectral Image Classification, *IEEE Geoscience and Remote Sensing Letters*, 17(2), pp. 277-281.
54. Saito, S., T. Li and H. Li, 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.
55. Sarkar, D., R. Bali and T. Sharma, 2018. *Practical Machine Learning with Python: A Problem-Solver's Guide to Building Real-World Intelligent Systems*, Apress, Berkeley, CA.
56. Sermanet, P., K. Kavukcuoglu, S. Chintala and Y. LeCun, 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.
57. Tuia, D, G. Camps-Valls , G. Matasci and M. Kanevski, 2010. Learning Relevant Image Features with Multiple-Kernel Classification, IEEE Trans. on Geoscience and Remote Sensing, 48(10): 3780-3791.
58. Waske, B., J. A. Benediktsson, K. Árnason and J. 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.
59. Yang, Q., Y. Zhang, W. Dai and S.J. Pan, 2020, Transfer Learning, Cambridge University Press.
60. Zhang, Bin, L. Zhao and X. Zhang, 2020. Three-Dimensional Convolution Neural Network Model for Tree Species Classification Using Airborne Hyperspectral Images, Remote Sensing of Environment, 247(2020):111938.
61. Zhang, L. and X. Huang, 2010. Object-Oriented Subspace Analysis for Airborne Hyperspectral Remote Sensing Imagery, Neurocomputing, 73(4-6):927-936。
62. 王驥魁，朱宏杰、林志交、曾義星，2012。全波形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。
63. 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>。
64. 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。
65. 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。
66. 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。
67. 浦瑞良和宮鵬，2002。高光譜遙測及其應用，五南出版社。
68. 陳正杰，2018。應用CASI高光譜影像於辨識森林樹種之研究，國立嘉義大學森林暨自然資源學系研究所碩士論文。

69. 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。

附件 A-1、期初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重要樹種調查之研究(2/2) 期初審查會議紀錄			
壹、時間：		中華民國 110 年 4 月 8 日（星期四）下午 2 時	
貳、地點：		農航所和平辦公大樓 201 會議室	
參、主席：		吳委員淑華	記錄：蔡仲涵
肆、出席人員：		詳如簽到表	
伍、會議結論		(一) 本案因目前國內唯一一架通過 CASI 1500h 高光譜儀適航認證之飛機，確定無法於 110 年 2 月~4 月飛行並取得試驗區所需影像，請研究團隊、中興測量公司及本所空間測量課儘速就國內既存多期高光譜影像、地真資料涵蓋等情形，於評估對研究進行具有助益之原則下提出影像替代方案，如能以阿里山森林遊樂區範圍或其他外來種入侵區域之多期高光譜影像尤佳，並請對應修訂工作計畫書相關內容。 (二) 請研究團隊於 4 月 30 日前將修正後工作計畫書電子檔 1 份，並同契約變更相關文件函送本所，俾便辦理再審查及契約變更等後續事宜。請各位委員協助本案修正後工作計畫書之書面再審事宜。	
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	
邱委員式鴻	1. 計畫書請增列地真資料蒐集之章節，以利讀者瞭解地真資料來源及後續檢核資料之準確度。 2. 目前地真資料區分為訓練及檢核資料，若未來導入無地真資料之新樹種分析，或遷移學習之分析成果，請說明應如何進行驗證及檢核。 3. P26 請敘明此處率定係為系統間軸角或相機參數之率定。 4. P33 請說明幾何糾正章節，因有使	1. 感謝委員建議，已於報告書 4.5 節補充地真資料蒐集彙整之說明。 2. 若加入新樹種分析或遷移學習，仍需要對應的地真資料加入訓練和驗證，對於新增的資料數量則需少量資料即可進行學習分析。 3. 已於報告書 4.4.4 節第(4)點說明 6 個參數與系統軸角和相機之間的關係。 4. 此部份使用 1 米 DTM 網格資料進行，搭配影像外方位進行正射糾正，已新	

	用 1 米的 DTM，所指是否為正射糾正。 5. P34 圖 4-18 為幾何前後對照圖，圖上又標註輻射及幾何字樣，請敘明該圖表達之意義。 6. P32 請說明幾何偏移參數為何，另請修正幾”何”之錯字。 7. P45 請就簡報之策略 3 補充說明。 8. P48 請說明不同時期影像資料融合如何處理。 9. P51 有關幾何校正精度分析小節，為分類結果相對應幾何位置套疊之分析，是否修正標題使讀者更容易瞭解。	增說明於 4.4.5 節中。 5. 幾何前後對照圖更新為圖 4-22，因幾何改正前的影像沒有實際坐標，即為輻射校正後的影像，為避免混淆，更新影像註解為幾何前與幾何後。 6. 報告書 4.4.4 節已修正幾何偏移參數為六個外方位參數的改正量，並加強說明與系統軸角、相機間的關係。 7. 策略 3 主要是由多時期影像分析延伸至多區域高光譜影像樹種分析之策略，已補充說明於報告書中。 8. 已更新報告書圖 6-1，應將此處的資料融合修正為多時期資料預處理和資料串接的步驟。 9. 已更新該小節為高光譜影像產製幾何校正精度分析，此處所指的是高光譜影像產製過程的精度分析，若精度分析符合標準，影像分類成果即可直接套疊。
鍾委員智昕	1. 請說明森林區域之高光譜影像如何進行輻射校正。 2. 請統一多核學習演算法結合小波函數敘述方式如 P37、P38 圖 5-3。 3. P44 圖 5-11 為出雲山苗圃實驗區影像不同樹種平均光譜曲線圖，是否探討各樹種間 2 季光譜曲線差異之原因，尤以柳杉及檜木等常綠樹樹種於光譜曲線次序有相反的情形。 4. P44 圖 5-12 圖中，於植物光譜曲線之低點為樹種判釋的重要特徵之一，通常於 970nm 及 800nm 處會各有 1 個水份的吸收點，請說明 750nm	1. 森林區域高光譜影像輻射校正與一般機載高光譜影像輻射校正並無異，主要根據原廠輻射轉換軟體與參數設定，配合飛行資料即可完成輻射校正，如 4.4.3 節之說明。 2. 感謝委員建議，已修正為多核學習法結合小波核函數，而分類機制則是採用支持向量機。 3. 圖 5-11 僅先列出兩個時期光譜曲線的差異，且拍攝條件也會對於光譜曲線有顯著的影像，其造成之原因仍須要進一步探討。 4. 植物光譜曲線 750nm 處的低點為氧

	處之低點的原因為何。 5. 請問本研究地真驗證資料為 pixel base 或 polygon base，如何進行分析成果準確度評估？ 6. 本研究參考 Jiang 等人 (2020)文獻，請敘明研究 6 種目標樹種如何萃取其端元。 7. 簡報 P12 參考文獻其溫帶區域植物於中長紅外光波段有明顯之起伏及區別，而本研究為亞熱帶區域亦無該波段資料；於本研究中，是否能藉由分析多期高光譜影像，探討臺灣森林分類研究之關鍵波段。 8. 多期影像分析時，為全部同時匯入分析，產出單一分類圖層，是否能探討需要至少幾期或特定月份拍攝之高光譜影像，對樹種分類研究將有重大影響。 9. 請修正 P30 圖 4-14 圖錯置及 P44 圖 5-11(b)漏字。 10.P34 請敘明團隊實際使用之影像鑲嵌軟體，供未來使用參考。	氣(O₂)的吸收帶。 5. 研究中獲得的地真資料為多邊形向量資料，於影像分析時會轉換為 pixel based 分析，對於分類準確度也是利用像元檢核資料以誤差矩陣進行分析。 6. 萃取端元的方式需要將高光譜影像進行大氣改正，再以統計分析的方式萃取端元，研究中會以軟體操作萃取端元。 7. 感謝委員建議，後續會考量機載高光譜儀所涵蓋的波段資料，探討對森林樹種分類有影響之波段。 8. 感謝委員建議，後續也會根據單期、多期影像，以及拍攝時間對高光譜影像樹種分析之影響，而目前僅有 2 期影像，若要分析更多期資料的影響則會受限。 9. 已修正於報告書中。 10.影像鑲嵌軟體是使用 ENVI，已增加說明於報告書中。
陳委員連晃	1. 本研究高光譜資料解算使用衛星一等控制點，是否有至現場接收資料？若本案使用既有影像，是否有控制點的問題？ 2. 請敘明本案掃描儀是否有率定程序，其率定時間為何。 3. 請說明 P29 圖 4-13 圖中 3 條黑線是否無原始資料及後續如何處理。	1. 本案使用衛星一等控制點做為解算飛航資料之基礎，並未至現場收集相關控制點與檢核點。若使用既有影像，則視當時飛航資料獲取時採用何種方式做為解算飛航資料之基礎，才能決定後續是否需要控制點。 2. 109 年度拍攝時之飛航率定為 109 年 10 月 28 日，並更新於報告書 4.4.4 節中。 3. 圖 4-15 中此 3 條黑線為原廠 CCD 結構的一部分，原始影像中會存在，透過原廠幅射轉換後之資料，將消除這

		3 條線，並更新報告書 4.4.3 節說明。
蔡 委 員 展 榮 (書 面 意 見)	1. 如何確認地真資料的正確性及代表性？ 2. P15 建議未來持續蒐集之文獻及案例，挑選與臺灣林相及氣候、地理環境相似的國外實際案例或公部門政策規劃。 3. 請於計畫書中敘明試驗區之地表高程、影像比例尺、地元尺寸、林相組成等資訊。 4. P19、P67 請確認儀器其航高為 32,500m 之正確性。 5. P23 圖 4-6 衛星控制點請以對比鮮明之顏色表示。 6. P26 圖 4-10「像主點（光束法平差產生）」項目，請說明如何檢查(x0, y0)，及 f 三個公稱內方位數據正確性。 7. 請說明本研究是使用「GNSS」或「GPS」，並請統一 P24 之「GNSS」、P31 及 P32 之「GPS」用字。 8. P35 請補充說明本案採用核方法及深度學習之原因。 9. P55 建議宜補充說明本計畫主持人異動之原因。 10. 部分謬誤疏漏、中英文對應及用法統一部分，請團隊參照書面意見修訂。	1. 部分地真資料已經過現地調查，具有一定的正確性，後續則會加強地真資料與影像資料之間的比對彙整，並且本年度規畫至實驗區現地調查，確保地真資料的正確性與代表性。 2. 感謝委員建議，與台灣相似的林相、氣候、地理環境範例較少，會盡力蒐集相關文獻及案例。 3. 已將實驗區的相關資訊更新於 4.1 和 4.5 節中。 4. 已將圖 4-4 及附錄 B-2 內容修正。 5. 已將圖 4-8 更新於報告書中。 6. 焦距和像主點依據原廠建議 CASI-1500h 之焦距率定後數值需落在 2100+/-50 像元內，像主點則需落在 750+/-40 像元內，並更新於 4.4.4 節中。 7. 本研究是採用 GNSS 資料，已將圖 4-9 修正，並統一用字。 8. 團隊對於核方法與深度學習已有較深入的研究，對於模型與參數調整能有較好掌握，且 108 年與 109 年研究案已實際用於高光譜影像分析，有較佳的分類成果，因此本案選用上述之方法並精進。 9. 因原計畫主持人個人生涯變動，由趙鍵哲副教授擔任主持人，徐百輝兼任助理教授擔任計畫共同主持人。 10. 已將相關內容修正於報告書中。
李 委 員 淑 蓉	1. 請將研究文獻蒐集比照 109 年成果報告書格式彙整成表，以利讀者閱讀。 2. 今年是否規劃至大雪山森林遊樂區進行地真資料蒐集？ 3. 建議教育訓練可讓本所同仁上機操作，以加深印象。 4. 請修正 P53「109 年度」誤植問題。	1. 感謝委員建議，已新增於表 3-1 中。 2. 今年度規劃至大雪山森林遊樂區，及新增之阿里山森林遊樂區鄰近區域等區域進行地真資料蒐集。 3. 感謝委員建議，會朝此方向辦理上機操作。 4. 已修正計畫書內容。
李	1. 請統一「本計畫」、「本案」等敘述方	1. 已統一並修正計畫書內敘述方式。

委員茂園	式。 2. 請補齊 P57 協力廠商執行相關計畫之段落敘述。	2. 已更新協力廠商相關計畫之敘述。
林副所長科言	1. 請修正封面漏字。	1. 已修正工作計畫書封面。
葉課長堃生	1. 若需以他期影像替代，請注意其品質、規格及影像拍攝時間是否符合本研究需求。	1. 感謝課長建議，目前選定阿里山森林遊樂區鄰近區域，其歷史影像有春、秋兩季，地面解析度至少 2 公尺，相關影像品質可符合本研究需求。
吳委員淑華	1. 請研究團隊確保試驗區之地真資料準確性。 2. 請敘明遷移學習的方法，利用遷移學習分類外來入侵種，可能會對林務局較有實務性的幫助。 3. 目前研究中是以 pixel base 分類，其樹種偵測之最小單元為何？混合林是否有機會辨識？ 4. 請研究團隊及主辦單位注意謬誤疏漏部分，讓審查委員可針對研究內容及方向給與建議，減省挑錯字及確認疏漏之時間。	1. 感謝委員建議，今年度規劃至選定的實驗區進行現地地真資料蒐集，以確保地真資料的正確性。 2. 已將遷移學習之細節更新於報告書第 5 節中。 3. 目前研究是以 pixel based 進行分類，單一樹木可能會由多個像元組成，因此分析的單元比樹種分布來得小，即在影像資料未受陰影或雜訊影響之下，是有機會找出混合林內的目標樹種，但仍須有對應的地真資料以檢核分類的正確性。 4. 感謝委員建議，會加強計畫書內文字之正確性。

附件 A-2、期中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重要樹種調查之研究(2/2) 期中審查會議紀錄			
壹、時間：	中華民國 110 年 7 月 23 日（星期五）上午 9 時 30 分		
貳、地點：	線上視訊會議		
參、主席：	吳委員淑華	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，請研究團隊於契約範圍內參酌委員建議修正，並於 8 月 6 日前將修正後期中報告書電子檔函送本所，據以辦理第二請款事宜。		
陸、散會：	上午 11 時 54 分		
柒、委員意見：			
審查意見		研究團隊處理情形回覆	
蔡 委 員 展 榮	1. 目前團隊分析是利用已鑲嵌調色影像進行分析，建議未來評估原始、傾斜相機及正射鑲嵌等不同種類之高光譜影像在研究上之優缺點，及哪種影像在計算效能、成果品質較穩定，可供需求單位做選擇。 2. P49 有關契約變更取得之歷史高光譜影像資料，請確認其資料所有權再行使用，以免觸法。 3. P66~69 請敘明報告書中核方法之數學符號意義及相關公式之邏輯，以利讀者閱讀，並請再確認 P68 6-8 公式上方敘述。 4. 建議納入歐洲相關參考研究，如德國、法國及荷蘭等文獻，以期對本研究有所突破。 5. P40~45 之 CASI-1500(h)之名稱是否正確，或請說明清楚與 CASI-1500	1. 為了避免重複內插計算光譜值影響分類分析，目前計畫中的鑲嵌影像並未進行調色處理；而計畫之高光譜儀為推帚式，原始影像未經過幾何校正呈現扭曲不易於分析，因此仍是以正射鑲嵌影像為主要分析目標。 2. 目前使用之歷史高光譜影像為伴隨著光達任務蒐集之歷史高光譜影像，也就是蒐集光達資料時一併獲取高光譜影像，因此高光譜影像並無版權問題。 3. 已將相關數學符號與內容進行調整。 4. 團隊內尚無多國語言之能力，若有歐洲區域的相關研究文獻，會補充於期末報告中。 5. 因計畫所使用之影像包含了 CASI-1500 和 CASI-1500h 所拍攝之影像，因此以 CASI-1500(h)統一代稱，CASI-1500h 為 CASI-1500 升級後新一代的	

之差異。 6. P40 有關原廠建議 CASI-1500(h)解算後數值需落在 2100$\pm$50 像元內，是否為中誤差？又 P42 表 4-5 內方位和外方位為-2092.860 像元，其負數代表之義意為何？並請說明像主點 751.140 為像主點之 X0 或 Y0。 7. 請說明 P42 表 4-5 外方位參數平均改正量之意思。 8. P40 請確認「6 個參數 RMS 落在 0.8 ~1 公尺之間則為合理範圍」與對應圖表的相聯性；若為 6 個外方位參數，則請再確認單位正確與否。 9. 請補充說明正射影像如何做光譜內插，及如何使相鄰二張高光譜影像像元值連接良好。 10.P40 請說明物空間之特徵點於本計畫之關聯？ 11.P13 請標明圖 3-2 的水平軸及垂直軸意義，並將灰階之 scale bar 也表示出來。 12.P79 請標明 7:3 比例代表多少像元，以利讀者了解影像大小，以及訓練、檢核像元佔全部影像像元之佔比。 13.請擬定本計畫於森林資源調查分類準確度之目標。 14.P37 表 4-4 中台大農航所相關內容可能會令讀者誤解，請酌修。 15.請補充說明並確認輻射校正前後於 950nm 以上之 DN 值差異大之原因。 16.P76 請說明多時期影像如何串接。 17.請敘明高光譜影像及地真資料之取	產品，基本元件並無太大差異，主要是新增了內建的光譜集成燈，能在每次飛航任務掃描前，自動的在儀器內部進行光譜校準作業。 6. 解算後的焦距與像主點數值，並非為中誤差，$\pm$數值為可容許誤差像元，正負數代表為儀器的方向性，像主點 751.140 為 X₀。 7. 外方位參數平均改正量修正為軸角軸臂參數，包含 CASI 到 IMU 的 Lever arm 改正量及 Boresight angles。 8. 6 個參數的 RMS 以原廠建議的 0.8-1 公尺以內為合適範圍，6 個參數 X、Y、Z 為公尺單位，ω、ϕ、κ 為度單位，焦距與像主點使用像元為單位。 9. 高光譜正射糾正是透過原廠軟體執行，詳細內插方式仍需再與原廠確認，後續補充於期末成果中。而影像鑲嵌時，目前計畫並未做連接計算，以避免重複內插計算光譜值影響分類分析。 10.主要是透過率定場的控制點與特徵點進行高光譜儀與定位系統間軸角軸臂參數率定。 11.已更新於報告書中。 12.不同的分類方法受到電腦效能限制，因此採用的像元數會有所不同，支持向量機採用的訓練和檢核像元數為 1400、600 像元；一維卷積神經網路則為 7000、3000 像元，採用的像元數分別於 7.2.1、7.3.1 節說明，同時表 7-1 亦列出各類別圈選的像元數。
--	---

得時間，並確認影像與地真資料無變化才能進行比較。 18.請說明不同時期高光譜影像 end member 平均值之 variation 是否為對本研究有影響。 19.P40 請敘明原廠建議 CASI-1500(h) 解算後之數值。 20.P29 圖 4-3 光達高程與平面精度，每一個地面像元對應地面點之準確度可達多少？如何評估？ 21.高光譜鄰近像元光譜值之訊雜比為何？在自動化分類變異的誤差量連續性為何？	13.感謝委員建議，會根據研究成果，探討並評估分類之目標。 14.已修正表格內容。 15.初步檢查 DN 值的變化應無錯誤，正在向原廠詢問可能因素，並補充於期末成果中。 16.目前是將多時期影像同時加入模型之中，平行進行前處理及模型計算，後續於實際高光譜影像操作，補充於期末成果中。 17.感謝委員建議，地真資料會先透過航照影像或現地資料檢查是否有變化，實際進行影像分類前，也會檢查高光譜影像內容是否有差異。 18.若要進行高光譜 endmember 分析，則需要將影像進行大氣改正並取得光譜反射值，不同時期的光譜反射值應相同；而目前取得高光譜影像之限制，未進行大氣改正，目前未規劃進行端元分析。 19.原廠建議內方位參數精度需落在焦距 2050-2150 像元及像主點 710-790 像元內，8.6 個參數的 RMS 以原廠建議的 0.8-1 公尺以內為合適範圍。 20.圖 4-3 為光達儀器原廠建議之優規，以實務經驗高程精度約落在 15-20 公分，平面精度約為 $1/7500 \times \text{航高}$。評估方式一般採用「LiDAR 測製數值高程模型及數值地表模型標準作業程序(草案)」之建議方式。 21.感謝委員提問，後續會將訊雜比、分類變異的誤差等列入討論。
--	---

蘇委員木春	1. P86 建議補充說明支持向量機的輸入特徵是哪些參數。又是依何種方法選取的。 2. 建議表 7-5~7-10 應比照表 7-11，同時列出訓練資料集和檢核資料集的實驗數據。 3. 將二期資料合併訓練的結果比個別訓練的結果差，如何克服解決多時期的問題？ 4. 如果只用 1 年的訓練再用另 1 年的影像來測試，不知效果如何，又是否可從特徵方面著手。	1. 支持向量機輸入的特徵皆為原始像元光譜值，並未進行前處理取特徵值，主要是在核函數進行參數調變。 2. 感謝委員建議，已更新表格內容。 3. 兩時期資料的差異會互相影響，如何克服多時期資料差異造成的問題，仍需後續探討。 4. 只用 1 年訓練的模型用於另 1 年測試，其分類成果相當差，因此需加入部分新的資料調整模型。
邱委員式鴻	1. P5 建議甘特圖加上目前工作進度俾清楚顯示與預定時程的差距。 2. P42~43 表 4-5 及圖 4-19~20 之外方位參數，建議修正為常用之軸角與軸臂率定的撰寫方式。 3. P50~P52 表 5-2~5-4 因已計算出空間解析度，建議刪除”預計”二字。 4. P56 應敘明清楚正射糾正之地面解析度。 5. P70 6.1.2 請說明清楚深度學習演算法與改善，改善方式為何？其敘述會讓人誤解直接使用 2D 及 3D 演算，而 P112 提及 2D 及 3D 已完成程式撰寫，亦請說明清楚有改善的內容。 6. 類別分離度之分析是否於後續分析中適度加以引用？而 7.2~7.3 節建議用圖示的方式比較好理解。 7. 7.4 小結請修正為”捌、期中結語與未來工作”。	1. 感謝委員建議，已調整甘特圖內容。 2. 感謝委員建議，軸角軸臂及內外方位參數之解算程序及解讀，待與原廠充分討論後，會在期末報告補充。 3. 感謝委員建議，已調整報告書內容。 4. 已修正報告書內容，正射糾正之地面解析度為 1 公尺。 5. 原採用的深度學習演算法是 1D CNN，只考量了光譜軸的資料變化，因此希望利用 2D 和 3D CNN 將空間軸的資料特性也納入考量，提升高光譜影像分類的成果，詳細提升成果仍待後續實際高光譜影像實驗成果分析。 6. 感謝委員建議，類別分離度目前只用於樹種類別間的統計分析，後續會適度加以引用。同時成果比較也會於期末成果利用圖示方式比較。 7. 感謝委員建議，已調整報告書內容。 8. 多時期的分析三種策略，因端元分析需要將影像經過大氣改正取得反射值，於本計畫中執行較不易。後續則會將多時期影像串接利用深度學習方法分析，而遷移學習法則會加入多區

	8. 請將分類的三種策略再說明更清楚。 9. 光達資料應用為何？會納入本計畫做相關輔助高光譜影像分類嗎？	域的資料分析。 9. 光達資料目前是用於高光譜影像正射糾正，而於前期有嘗試加入分析，但對於成果的提升不顯著，因此未納入本計畫的機器學習方法中。
陳委員連晃	1. P43 圖 4-19 及 4-20 請確認相機率定的外方位參數及率定精度成果，前後數字為相同，另角度 3 個數值皆為 0 是否可再增列 2 位。 2. 請說明不同期影像在地面解析度差距，是否會影響分析結果。 3. 期初審查會議有提及飛機可能於七月取像，請問目前飛機狀態為何？ 4. 阿里山試驗區地真資料蒐集執行上，若有困難亦請提出說明。	1. 已確認相關參數數值，角度 3 個數值皆為 0 可否再增列 2 位，根據原廠表示，目前高光譜影像的空間解析度皆為公尺等級，因此求解至小數點第三位已足夠。有關軸角軸臂及內外方位參數之解算程序及解讀相關資料，待與原廠充分討論後，會在期末報告補充。 2. 目前 108 年與 109 年影像均為 1 公尺解析度，而阿里山歷史影像則在 1.5-2 公尺間，而這樣的解析度大致比單棵樹木細，對於分析成果影響不大。 3. 目前前進航空已倒閉，德安航空使用之直升機機型尚無法將光達與高光譜系統以及相關設備全數上機，因此還再尋找合適機型做後續高光譜儀器搭載考量。 4. 感謝委員建議，會嘗試以現有影像進行確認，若有需現地調查也會前往，有需要時會請貴所協助。
鍾委員智昕	1. 因契約變更，今年度採用歷史影像，建議 4.2 節機載高光譜影像獲取流程應降低報告篇幅。 2. 請統一「輻射轉換」及「輻射輸出」敘述方式。 3. 歷史影像及阿里山部分請統一列表會較容易理解。 4. 請評估不同高光譜影像解析度在模型或準確度產生的影響。 5. 評估各種影響因子之權重為何？ 6. 陰影處影像是否分類成果較差？ 7. 請說明 P76 深度網路架構如何自行學習樹種具分辨性及時間不變性的特徵？	1. 感謝委員建議，已調整報告書內容。 2. 感謝委員建議，已修正報告書內容。 3. 感謝委員建議，目前阿里山區域的影像仍在微調中，完成後會於期末報告以列表彙整。 4. 感謝委員建議，目前高光譜影像解析度雖有不同，但皆比單棵樹木細，理論上對於成果影像不大，而後續會於期末成果中探討分析。 5. 感謝委員建議，目前實驗仍在進行參數調變，後續會評估各項影響因子，並於期末成果探討分析。 6. 由目前的分類成果，陰影處有受到小部分影響，可能是像元的光譜值太

	8. 請統一精度評估於文字及表中之位數。 9. 柳杉及杉木等樹種可能位於陰影面，應如何克服或呈現，亦建議特別探討分類成果較差區域之原因。 10. 本案依據不同影像訓練模型，最後如何使用 1 個模型預測新的資料？ 11. 遷移學習可加少量樣本即可套用新影像分類，是否可能提供一個最低樣本數之指引，供大家應用參考？	低，已失去原有的光譜特徵，後續會再針對陰影處資料進行確認。 7. 呈上題，若樹種的光譜曲線因拍攝環境有所變化，但該樹種的光譜吸收特徵仍在，仍然可以用於深度網路架構分析。 8. 感謝委員建議，報告書中成果均以小數點 4 位呈現，而分類準確度通常是以百分比顯示。 9. 感謝委員建議，會再針對陰影面的資料進行確認與分析探討。 10. 本計畫中會嘗試利用不同模型，並進行參數調變，最後會比較不同模型預測新資料的成果，並比較其特性與優劣，並提供貴所參考。 11. 感謝委員建議，後續會於實際高光譜實驗時加入考量，並提供參考資訊。
李委員淑蓉	1. 報告書中 P52 阿里山歷史專案(C)提及有部分影像毀損，提醒團隊注意契約變更後高光譜影像需達面積 100 平方公里。 2. 請於教育訓練將參數及變數詳細編列於操作手冊，以利同仁後續參考使用。	1. 感謝委員建議，會注意高光譜影像的需求與面積。 2. 感謝委員建議，會於教育訓練時加入相關內容。
李委員茂園	1. 各國的參考文獻請納入其高光譜影像之解析度與波段，以利本所未來拍攝參考。 2. 請再補充 P40 光束法平差相關內容。 3. 建議增加利用高光譜影像搭配其他高解析度影像進行分析之相關參考案例。	1. 感謝委員建議，已調整報告書內容。 2. 感謝委員建議，軸角軸臂及內外方位參數之解算程序及解讀，待與原廠充分討論後，會在期末報告補充。 3. 感謝委員建議，後續會嘗試蒐集相關資訊並加入期末成果。
林副所長科言	1. 建議成果報告附件納入本研究重要樹種之樹形、枝條、葉面照片、學名等基礎資訊，以利報告書之完整性。	1. 感謝委員建議，後續會嘗試蒐集相關資訊並加入期末成果。
葉	1. P94 未來若加入更多期影像，是否	1. 目前仍在調變實驗參數，多時期影像

課 長 堃 生	有預期合併訓練收斂的可行性。 2. P103 杉木區域誤判為臺灣櫟等地真資料疑異，請提供相關點位或資料，本所可再利用航照再次確認。 3. P103 建議於圖面上標示相對應報告書文字敘述之錯誤分類區域，以利讀者閱讀。 4. 請說明 P103 圖 7-9 杉木分類明顯直線的原因。 5. 請說明遷移學習是針對空間或時間？	分析應可以達到穩定分類成果。 2. 會再針對該區域的資料點進行確認，初步判斷可能為該區域的不同樹種之間距離較接近，可能有光譜混合之情形。 3. 感謝委員建議，已調整報告書內容。 4. 該杉木區域中間有道路，於訓練資料圈選時已避開道路，因此看起來有直線。 5. 遷移學習是針對不同組資料可以將模型進行在訓練，因此可以針對不同空間資料也可以針對不同時間資料分析。
蔡 技 士 仲 涵	1. 請研究團隊將目前參考文獻及研究情形，就有關高光譜分類限制或影響因子等一併整理於報告書中，供本所未來取像及應用參考。	1. 感謝委員建議，後續會將相關資料彙整，加入期末成果中。

附件 A-3、期末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重要樹種調查之研究(2/2) 期末審查會議紀錄			
壹、時間：	中華民國 110 年 12 月 1 日(三)下午 2 時 00 分		
貳、地點：	農林航空測量所 201 會議室		
參、主席：	吳委員淑華	記錄：	謝幸宜
肆、出席人員：	詳如簽到表		
伍、會議結論	今日期末審查於報告書修正後通過；請研究團隊參酌委員建議修正，並於 12 月 10 日前將修正後期末報告書電子檔送交本所，俾轉請各委員檢視確認。		
陸、散會：	下午 4 時 46 分		
柒、委員意見：			
審查意見		研究團隊處理情形回覆	
蔡 委 員 展 榮	1. 團隊執行兩年的經驗、實務工作狀況及目前成果收穫實屬寶貴，建議貴團隊將這兩年內的重要心得、結論與建議事項等，整理為「結論與建議」之獨立章節，使農航所未來實際運用於業務時更有助益。 2. 有關 P4「(7)成果交付」說明，似未包括本案開發的多時期影像最適機器學習演算程式以及多期高光譜影像自動偵測重要樹種之程式？ 3. P145 教育訓練部分，是否讓農航所同仁練習使用貴團隊開發的程式來實際操作本案的多時期影像最適機器學習演算，以及多期高光譜影像自動偵測重要樹種的練習？農航所同仁若能實際操作，貴團隊的經驗能有較好的傳承。 4. 本案研究文獻蒐集部分，較欠缺英	1. 感謝委員建議，已將相關內容更新於第 9 章結論與建議。 2. 期末成果交付時，除了報告書、影像等內容，亦會交付相關程式。 3. 教育訓練中已說明程式環境建置方式，以及程式介面操作，程式介面是以單期高光譜影像樹種分析進行建置，讓貴所同仁了解模型參數的調變，多時期影像分析也會於期末成果中交付。 4. 感謝委員建議，團隊內較無第二外語的能力，研究文獻蒐集雖以中英文文獻為主，而蒐集的文獻中實驗區範圍已盡量涵蓋歐洲、美洲、亞洲等全球各地的區域，以增加文獻的多樣性。 5. 感謝委員建議，已更新圖 3-1 和圖 3-2 之內容。 6. 感謝委員建議，已更新並統一文字內	

文文獻以外的其他語系之文獻，有點可惜。 5. P13 圖 3-1 的標註文字太小、不清晰，水平軸建議標註波長的單位。另 P13 圖 3-2(b)中 scale bar 標示的相關係數值介於 0~1，試驗過程中是否有負相關之情形（數值介於-1~1）？ 6. 報告書中的前後用詞建議統一，如：最大概似法及最大似然法、以物件為基礎的影像分析（分類）及物件導向分類、正確度及準確度、稀疏表示及稀疏模式……等，對讀者而言較不易產生困擾。 7. 本案使用的分類技術，其分類成果準確度是否具備可重複性？亦即，相同的分類方法如果應用到其他地區，是否能維持相當的分類準確度？如果可能的話，也建議將常出現分類錯誤的位置（如陰影區、易誤判之樹種）及其錯誤發生的原因補充說明，俾供農航所同仁後續應用作業之參考。 8. 部分敘述未具體寫出其內容，如：P3「二、4.光達資料取樣規格需符合試驗所需」之「試驗所需」內容、P7「部分樹種的分類準確度更可接近 100%」之「部分樹種」名稱、P8「蒐集本計畫研究所需之其他測試資料及地真資料等」之「其他測試資料及地真資料」內容、P18「……採用支持向量機的分類準確度為	容。 7. 本案所使用的深度學習屬監督式訓練，訓練成果與原訓練區資料關係密切，若其他區域資料特性與原訓練區資料類似，則理論上可獲得類似的分類準確度，但實際上受環境及拍攝時間影響，造成其他區域與原訓練區域資料特性差異太大，則將獲得較差的分類成果，但透過本案所提遷移學習將可解決此問題。另造成分類錯誤的可能原因將在於期末成果報告中補充說明。 8. 感謝委員建議，已補充文字內容，P7、P8 為招標文件之項目。 9. 感謝委員建議，已修改報告書內對應的內容。 10.感謝委員建議，部分英文用詞主要採用至蒐集的原文資料種，且無對應合適的中文翻譯，故以英文原有用詞書寫。表 3-2 之樹種採用英文列舉，亦直接採用文獻內樹種名詞，避免翻譯錯誤或不完善。 11.感謝委員建議，已修改並補充英文縮寫之內容。 12.感謝委員建議，已修正報告書內容。 13.原廠軟體並未計算此數值，已將此建議回饋給原廠。 14.感謝委員建議，已修改報告書內容，主要是描述航帶重疊區域的高光譜影像光譜值，不會進行航帶間的光譜值內插，而是選擇主要航帶的光譜值填入鑲嵌影像，以減少對於分類之影響。
--	--

82.27%，優於採用光譜角映射的分類準確度，另……」之「光譜角映射的分類準確度」數值、P19「……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……」之「資訊」包含哪些種類與項目。 9. 期末報告書中部分使用未來式的敘述，建議應改為完成式，如 P8「……將提供 2 場次各 4 小時之教育訓練」等。 10. 建議報告書中的敘述方式不宜中英文混雜，例如：P16「針對森林環境健康監測與保護建立的 The Forest Health Protection(FHP)任務」、P21～P25 表 3-1 中部分文獻「樹種對象」欄內的敘述。 11. 報告中使用的字首語(縮寫字)，如：P17 的 OLI、P18 的 FLAASH、P21 的 REP 及 PLS……等，宜於第一次出現處載明其全名，或整理至附件 B 中。 12. 另中文譯名建議與英文內容對應，如 P16「Forest Service, U.S. DEPARTMENT of AGRICULTURE」建議譯為「美國國家農業部森林局」。 13. P47 表 4-4，建議加註對應數據的後驗標準偏差。 14. P50 第 4 行「……高光譜影像鑲嵌沒有進行光譜值內插，減少光譜值內插計算，以減少……」語意不清，請酌修。	15. 感謝委員建議，以修正報告書內容與圖 5-2 之標號。 16. 含雲量並非以逐像元方式計算，在影像中數化含雲位置，最後統一以 shp 格式於 GIS 軟體中進行面積計算，含雲量百分比已修正於內文，並新增含雲量分布位置圖供參考。 17. 兩期精度檢核成果差距，主要是每次歷史專案的拍攝目的不同，而且也會根據不同航拍的專案有所變化。 18. 感謝委員建議，以修正報告書內容，σ 應屬於正實數。 19. 感謝委員建議，已修正報告書內容。 20. 感謝委員建議，已修正報告書內容。 21. 圖 7-3 主要是展示和比較兩個時期不同樹種類別的光譜曲線差異，而平均值與標準差是透過實際影像計算，實際所計算出的標準差值變異大，若將相關資訊加入圖中，會造成圖表的可讀性降低。 22. 過去研究中曾經透過連續小波轉換分析光譜曲線，可以量化光譜曲線尺度—頻率變化，因此把此概念加入多核函數中。 23. 感謝委員建議，已修正報告書內容。 24. 感謝委員建議，已修正報告書內容，並新增第 9 章結論與建議。 25. 實驗中，支持向量機需要一次將所有資料放入模型訓練，因此每一類別採用 2000 個像元以 7:3 的比例訓練和檢核；卷積神經網路則將程式更新，統一為目標區域所有的像元資料，以 3:7
--	---

15.P52 表 5-1 之「光譜涵蓋範圍」建議統一為簡報內容中使用的「波長涵蓋範圍」，另「地面解析度」建議改為「地元尺寸」較易理解。P53 第 2 行「.....並正在進行解算.....」，請調整為完成式之敘述。另 P53 第 2 段格式及圖片編號等(圖 5-25 應為圖 5-2) 請再檢視。 16.P54 含雲量是否採逐像元計算？P54「...含雲量約為 0.01%(如圖 5-4)...」圖片編號似應修正為圖 5-5。 17.表 5-6、表 5-7 中兩期影像的精度檢核成果差距較大，建議補充其原因。 18.P72 第 1 段「.....σ 為自由參數，但須為正整數。」與(6-4)式之「$\sigma \in R^+$」(R^+為正實數)，請酌修。 19.圖 6-7~圖 6-9，建議將圖中的符號及其意義加以說明。 20.P82「時間不變性的特徵」、P88「不受時間影響的光譜特徵」，建議更具體說明，以提高未來參考價值。 21.P91 圖 7-3 若能加註平均光譜曲線之 RMSD 或 Variation 的大小，較易看出不同樹種間的可分性如何。 22.P92「7.自選連續小波多核函數：採用連續小波轉換，基底函數選擇 Morlet.....」，光譜值為離散值，採用連續小波轉換時係如何進行計算？建議補充說明。 23.P93 第 1 段「F1-score 為 0.7921.....」與表 7-4 內容不一致，請修正。 24.P93 最後 1 行「.....如何透過 KA	的比例進行訓練和檢核，同時成果亦更新於報告書中第 7 章。 26.感謝委員建議，已補充報告書內容。
---	---

	值選擇合適的核函數仍需進一步分析探討」,請檢視報告書中此類需進一步分析探討的部分,納入「結論與建議」章節中。 25.P110 最後一段「.....並以 3:7 的數量分配.....」對照 P115 最後「以 7:3 之比例設定訓練資料與檢核資料的數目。」請檢視該等敘述是否須修正。 26.P112 表 7-11、表 7-12 中未列訓練資料集之相關數據,建議補上較完整。	
鍾 委 員 智 昕	1. P29 圖 4-2 的「鄰近道路 all other values」圖例未見於圖中,建議可刪除。 2. P42 倒數 3 行之「RMSE 小於 1 公尺」與圖 4-17、圖 4-18 的 RMS 表示單位(pixel)、表示方式不一致,建議連同後續精度檢核表所提之 MAE 等,於報告中補充說明其定義及計算公式。 3. P46 圖 4-20 內標示有 15 控制點、32 特徵點,與 P44 所述數量不符,請確認。 4. P52 波段數不同時,所需前處理的過程建議加以描述。 5. P61 像元誤差量有時以「公尺」表示,有時以「像元」表示,建議酌修敘述方式。 6. P65 建議將「西元年(2017 年)」統一為以「民國年」表示。 7. P68 圖 5-11、圖 5-12 圖說之「地真	1. 感謝委員建議,報告書中已更新圖 4-2。 2. 圖 4-17 與圖 4-18 原廠使用表述方式為 pixel,主要原因在於使用高光譜儀器 CCD 大小轉換單位的原因,因此在圖 4-17 和圖 4-18 則使用 pixel 的概念進行資料率定過程的描述。MAE 公式已加入報告書中。 3. 感謝委員建議,此為誤植,已修正於內文中。 4. 不同時期、區域的高光譜影像有可能會波段數不同,而在單一資料分析實不需要進行前處理;在遷移學習法中,則需要將多期影像調整為相同波段數,並內插到同樣的波長。 5. 已修正於內文統一使用公尺表示誤差量 6. 感謝委員建議,已修正報告書內容。 7. 感謝委員建議,已調整報告書圖 5-11、5-12 圖標題。

	樹種」，建議調整為「地真樹種的資料」，語意較清晰。 8. P87 有關光譜訊號特徵高、低之描述方式較模糊，建議可加入統計特徵值進行描述，或分光譜區段（可見光、近紅外光等）進行論述。 9. P88 建議補充「松樹」光譜曲線的相關敘述及圖表，亦可作為後續參考。 10. 影像訓練前已剔除的含雲區、陰影區、資料空缺處，於 P124 圖 7-16、圖 7-19 預測結果似可涵蓋，請檢視該測試成果圖是否正確。 11. 本報告中使用的方法較多，不易比較、理解，建議將各種方法綜整、以列表方式比較不同方法之精度、效率，使未來選擇分類方法時較快速簡便。 12. P143 部分敘述之「數種」應修正為「樹種」，請檢視。 13. P143 第(1)點之敘述較模糊，不確定本報告是建議未來採用 reflectance 或 radiance，希望更明確建議，供農航所未來選擇保存何種產品有更明確的參考。 14. 附件 A-2 期中回應項次的題號、回應有跳號情形，請修整。	8. 由於本計畫實驗資料是採用高光譜像的輻射值，容易受到拍攝現況影響，圖 7-3 主要想比較不同樹種的趨勢變化，若加入光譜曲線的標準差，會使得圖的可讀性下降，而主要可以看出不同樹種的差異仍以紅邊、近紅外光波段的吸收帶大小變化。 9. 感謝委員建議，已將阿里山森林遊樂區的實驗影像光譜曲線資訊更新於 7.5 節。 10. 經過資料確認，計畫中的實驗主要是剔除目標區域的空像元和陰影像元，並且已更新報告書中的圖。 11. 感謝委員建議，將各種方法比較條列於第 9 章的結論與建議。 12. 感謝委員建議，已修正報告書內容。 13. 在單一影像資料分析時，採用輻射值或是反射值都可以有良好的分析結果；若要進行多時期影像，採用反射值資料較不易受到拍攝環境之影響，但反射值資料還需要進行地面光譜調查和大氣校正，建議貴所仍以實際可採行方式選擇合適的影像資料。 14. 感謝委員建議，已修正報告書內容。
蘇委員木春	1. 簡報第 30 頁（對應報告書 P81~P83）有關遷移學習部分，貴團隊將新的資料加入已完成訓練的原始模型後再細調參數，此種方式會影響既有模型中對原訓練樹	1. 透過遷移學習會改變既有的模型參數，以符合新的資料分析，確實會影響對原有樹種的分類準確度，但會如何影響，以及影響的程度，將會是未來研究的範疇。若是在遷移學習之

種的分類準確率(可能降低原訓練樹種的分類準確率),請問貴團隊是否有拿資料來驗證此遷移學習方式的效果? 2. 簡報第 36 頁(對應報告書 P102) 一維 CNN 中只使用一層卷積層,後面即加全連接層,但通常 CNN 會使用較多個卷積層去找出不同層級的特徵,只用一層卷積層找出的特徵可能不夠好,建議可增加卷積層數量。 3. 簡報第 39 頁(對應報告書 P111 圖 7-10),原始影像經過 PCA 轉換成另一影像,但透過 PCA 降為多少維度的影像、使用 PCA 降低維度的理由並未敘明。且一般常見方法係將原始影像直接匯入三維 CNN 中計算,本案中先做 PCA 轉換的成效是否有提升?建議補充說明。 4. 簡報第 40 頁(對應報告書圖 7-5~圖 7-10),建議將訓練資料集的各项數據與訓練資料集之數據分為 2 個表列可能更具參考價值。另「檢核資料」與「測試資料」是否相同?檢核資料指的是 Validation 資料或 Test 資料?建議統一用語,避免混淆。 5. 多時期資料的處理部分,貴團隊似乎是將多時期的資料混在一起訓練成一個模型,但樹種在不同時期(季節)可能有不同的特徵,且可能有更多不同季節的其他特徵未加入訓	後,有對於舊有類別分析的需求,可使用儲存的舊有模型進行分析。 2. 計畫中的 1D CNN 實驗設計主要是參考 Hu et al.(2015)文獻的神經網路建構方式,調整神經網路增加卷積層,將是未來研究的課題。 3. 感謝委員建議,高光譜影像輸入到三維 CNN 時,可輸入原始影像或是先對其進行 PCA 之後再輸入到三維 CNN 中(原始文獻之建議),根據本研究先前的測試,兩者分類成果的差異並不大,但輸入原始影像時將佔用較多的記憶體及計算時間。本案因實驗影像範圍較大,且波段數較多,因此採後者之方法以減少其資料量,同時降低其計算時間。 4. 感謝委員建議,報告書成果已將訓練資料集與檢核資料集的個別分析成果更新於報告書第 7 章。同時已經統一測試模型成果的為檢核資料(test data),在卷積神經網路中,驗證資料(validation data)則是由訓練資料中取 1/3 進行模型驗證。 5. 本研究成果顯示,對不同時期進行單獨訓練確實可以獲得較佳的分類成果,但必須所有不同時間或不同區域皆具有足夠多的訓練樣本;另若將多時期影像混在一起訓練,成果將比單獨訓練時為差。因此本研究採遷移學習方式,希望藉由預先訓練好的模型進行其他時間或其他區域的分類而不需要太多的訓練樣本,甚至針對從
--	--

	練，混合多時期訓練一個模型的目的為何？為何不將各時期的特徵單獨訓練？未來能使用混合訓練的模型推估其他季節的影像嗎？期待補充說明。	未訓練過的樹種亦可以進行分類，實驗成果顯示遷移學習確實可以達到此目的。
陳委員連晃	1. 建議在「結論與建議」章節中，可增加對高光譜影像取像的建議天候、大氣條件、季節、取像時間、太陽角度等條件，以提高取得高光譜影像後能提高後續應用價值。 2. P131 之「7.8 混和三維及二維……」、「7.8.1 混合三維及二維……」，建議將報告書內之用詞統一。 3. P91 圖 7-3 中，不同時期的臺灣肖楠光譜曲線幾乎重疊，其他樹種的光譜曲線則有較明顯差異，建議補充說明不同樹種於兩期資料中有所差異的原因。 4. P29 底圖範圍建議加大，使阿里山森林遊樂區所在位置更明確。	1. 感謝委員建議，已於報告書中新增第 9 章結論與建議。 2. 感謝委員建議，已修正報告書內容，更正為混合三維及二維卷積神經網路。 3. 因為是採用機載高光譜影像的光譜輻射曲線進行比較分析，容易受到拍攝當下的條件影響，圖 7-3 即是展示既有資料。 4. 感謝委員建議，已更新報告書圖 4-2。
李委員淑蓉	1. 報告書中的用詞「GPS」請統一為「GNSS」。 2. P67 第 1 段提及「若有需要後續則安排現地的地真資料調查」等部分，因已是期末報告，建議此類未來式的敘述予以刪除。 3. 「結論與建議」章節，可將中興測量對高光譜取像之經驗與建議納入，作為農航所未來規劃取像之參考。	1. 感謝委員建議，已修正報告書內容。 2. 感謝委員建議，已修正報告書內容。 3. 感謝委員建議，已於報告書中新增第 9 章結論與建議。
李委員	1. 報告中所提 6500×4200 像元之案例，會使電腦之解算負荷過重，是否能就團隊經驗，建議農航所未來	1. 因計畫中的實驗是採用個人電腦運算，所以會受限於現有電腦設備，電腦負荷過重可以透過電腦規格增強

茂園	高光譜影像取像的解析度範圍？ 2. 目前分類成效不錯，是否和光達資料的使用有關？若高光譜影像未搭配光達資料使用或輔助，是否會影響分類成果？ 3. 報告中建議之以 reflectance 進行分類效果較佳，希望能納入「結論與建議」中，作為農航所未來高光譜影像取像、資料保存等相關規劃之參考。 4. 測試影像中的含雲量數值看起來較影像中實際比率低，該含雲量是透過人工計算或特殊演算法計算而得？ 5. P64 圖 5-7、圖 5-8 使用的檢核點數量與位置均不相同，該等檢核點可否共用？	或是程式撰寫的方式改善。而高光譜影像取像解析度仍建議以後續要應用的面向進行規劃。 2. 本計畫的光達資料主要是用於高光譜影像建置時正涉糾正，在分類分析中是採用光譜資訊，並未納入光達資料；在前一年度中的物件分類法有加入光達資料，但輔助效果有限。 3. 感謝委員建議，已於報告書中新增第 9 章結論與建議。 4. 報告書內已重新確認並修正含雲量數值，含雲量的計算方式是在影像中數化雲的位置，利用向量檔在 GIS 中計算面積。 5. 因為每一幅影像的檢核點是利用該趟飛行計畫中獲取的航拍影像進行檢核，所以檢核點數量和位置會有所不同。
林務局賴技正靖融	1. 表 5-7 的正射坐標中有千分位符號，建議可刪除，與表 5-6 表達方式一致。	1. 感謝委員建議，已修正報告書內容。
林副所長科言	1. P143 第一段「……參考參考森林法第五十二條第四項之貴重木樹種，選定了共 7 種針葉、闊葉樹種……」之敘述，建議可改為「……選定了中低海拔常見 7 種類之針葉、闊葉樹種……」，一則因為研究中使用的「松樹」實際上包含了二葉松、五葉松等（生物分類學中）不同「種」的樹種，「檜木」也包含了紅檜、扁柏等樹種，一則法規所訂之	1. 感謝委員建議，已修正報告書內容。 2. 感謝委員建議，已調整報告書內容，將教育訓練及成果交付等內容調整於附件中，並增加第 9 章結論與建議。

	貴重木樹種與研究案中使用的樹種不盡相同，不同領域的人閱讀此報告可能會產生誤解。 2. 報告書中「玖、教育訓練」及「拾、成果交付」等章節內容，係屬契約文件要求的行政事項，建議從報告書中抽出來（以供驗收之用），使報告書整體架構更完整、專注。	
吳委員淑華	1. 若未來農航所的飛機同時搭載高光譜儀及 DMC III，相較於本案使用高光譜儀及光達搭配，是否能達到相當的成效？ 2. 遷移學習部分應是未來最有潛力減省人工訓練成本的方法，未來可如何應用到實務上、相關操作流程(如簡報第 58 頁)，建議加強包含影像前處理、光譜資料轉換等……之細節說明且綜整。 3. 簡報內容之綜整程度、色彩、編排均比報告書內容吸引人，希望將簡報綜整於報告書。	1. 目前高光譜儀搭載光達，主要可以利用光達資料進行高光譜影像的正射糾正，搭配 DMC III 雖然可以獲進行密點雲匹配，但其效果可能會光達資料差，以及有高差位移的問題，則需要考量的造成的影響是否可以符合目標，或以其他方式解決問題。 2. 感謝委員建議，已修正報告書內容於第 8、9 章中。 3. 感謝委員建議，已修正報告書內容。
葉課長堃生	1. 報告書中所提學習速率(如 P110 最後一行)之定義為何？學習速率之優劣應如何評估？ 2. P85 所提「排除空像元及陰影像元」，請問空像元成因為何？而空像元及陰影像元之排除方法為何？例如是否採用光譜或地形等資訊加以排除。 3. 農航所對於台大團隊所使用的各項程式（不僅限於教育訓練時所使用的簡易介面）很有興趣，希望有機會能取得試用。	1. 學習速率即是深度學習模型在每一回和更新權重參數的大小，學習速率過小時會造成訓練速度太慢，過大時可能會造成模型無法收斂。 2. 計畫中，實驗影像的空像元即所有波段值皆為零，可以直接計算排除；陰影像元則是平均光譜取線值會比正常像元低，實驗中是以計算統計值的方式進行排除。 3. 後續可以將程式環境的建置和程式提供給貴所測試。

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重要樹種調查之研究(2/2) 期末報告修正版審查委員意見回覆		
審查意見		研究團隊處理情形回覆
蔡 委 員 展 榮	1. “期末成果交付時，除了報告書、影像等內容，亦會交付相關程式。” ≤ 建議也包括”程式使用說明” 2. 建議宜將吳所長於 12/1(三)期末審查會議所做的結論、尤其是農航所的工作任務以及未來的科技計畫主題，再補充具體說明，俾利農航所同仁未來作業準備之用。 3. 建議貴團隊能將 12/1(三)期末審查會議的口頭回答(尤其是農航所需要的、有助於農航所業務推動的實務操作和經驗)、以及簡報的補充新內容(原報告文稿沒有的內容)整理於報告中，重要結語寫於結論一章中。例如:” 本案所使用的深度學習屬監督式訓練，訓練成果與原訓練區資料關係密切，若其他區域資料特性與原訓練區資料類似，則理論上可獲得類似的分類準確度，但實際上受環境及拍攝時間影響，造成其他區域與原訓練區域資料特性差異太大，則將獲得較差的分類成果，但透過本案所提遷移學習將可解決此問題。” 4. 建議宜再仔細檢查報告書內容的錯字、漏字、語焉不詳等謬誤疏漏並予以訂正補充。例如: 甲、p.147:“本年度同樣利用實際	1. 感謝委員建議，因本案相關程式碼的內容及數量繁多，部分尚須搭配其他商業軟體使用，現階段要補充「程式使用說明」有其難度，目前本案程式碼內皆有註解，後續所內有需要時，本團隊可協助程式環境的安裝並說明使用方式。 2. 感謝委員建議，已於成果報告書中第八章及第九章中進行補充。 3. 感謝委員建議，已於成果報告書的結論與建議中補充相關內容。 4. 已於成果報告書中進行補充。 5. 感謝委員建議，所提各點已於成果報告書中進行訂正及補充。

	出雲山苗圃和阿里山森林遊樂區高光譜影像之樹種類別分析”=> “本年度同樣利用出雲山苗圃和阿里山森林遊樂區高光譜影像來實際進行樹種類別分析” 乙、p. 147：“將本計畫中用的三類分類演算法的實驗方法、效率與成果歸納整理”=> “將本計畫使用的三種分類演算法的實驗方法、效率與成果歸納整理如下” 丙、p. 148：“建立特徵影像實需要逐一處理各項特徵”=> ”建立特徵影像則需要逐一處理各項特徵” 丁、p. 148：“其分類成果則略優於特徵分類法，用出雲山苗圃影像整體分類準確度接近 85%”=> “其分類成果則略優於特徵分類法，出雲山苗圃影像整體分類準確度接近 85%” 戊、p. 148：“不須經過前處理程序即透過單一程式進行影像分類分析”=> “不需經過前處理程序即透過單一程式進行影像分類分析” 己、p. 149：“提出未來建議”的各點宜給予編號，俾利農航所和林務局未來引用的標示使用。 庚、p. 149：“作成 GIS 圖層”=> ”做成 GIS 圖層”	
--	--	--

	辛、期末審查會議紀錄及處理情形回覆：“含雲量並非以逐項元方式計算” => “含雲量並非以逐像元方式計算”	
鍾委員智昕	1. 第 29 頁，圖 4-2 中的請刪除圖例中的「鄰近道路」與「all other values」 2. 第 43 與 44 頁，建議請於途 4-17 與 4-18 圖說增加括弧本案的 pixel 像素大小為 1 公尺，如此才可以對應第 42 頁所說 RMSE 小於 1 公尺。 3. 第 67 頁，圖 5-12 中的請刪除圖例中的「all other values」，建議指北針請跟圖例放在一起 4. 第 79 頁，第一段第九行，請修正「數種」->「樹種」 5. 第 133 頁，表 7-12 缺訓練集分類精度資訊 6. 第 173 頁，回應第 21 點，請修正「數種」->「樹種」 7. 第 179 頁，林副所長提問回應第 1 點，請修正「數種」->「樹種」	1. 感謝委員建議，報告書中已更新圖 4-2。 2. 感謝委員建議，已於報告書中加入像元大小之說明。 3. 感謝委員建議，已修正報告書內容。 4. 感謝委員建議，已修正報告書內容。 5. 感謝委員建議，已修正報告書內容。 6. 感謝委員建議，已修正報告書內容。 7. 感謝委員建議，已修正報告書內容。

附件 B、英文名詞縮寫對照表

英文縮寫	英文名詞	中文名詞
AVIRIS	Airborne Visible/Infrared Imaging Spectrometer	
AVIRIS-NG	AVIRIS-Next Generation	
ConvNet/CNNs	convolutional neural networks	卷積神經網路
DAFE	discriminant analysis feature extraction	判別分析特徵萃取法
DBFE	decision boundary feature extraction	決策邊界特徵萃取法
DL	deep learning	深度學習
FC	fully connected layer	全連結層
FLAASH	Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes	
GLCM	gray-level co-occurrence matrix	灰階共生矩陣
GNSS	global navigation satellite system	衛星導航系統
GPS	global positioning system	全球定位系統
HHT	Hilbert-Huang transform	希爾伯特-黃轉換
ICA	independent component analysis	獨立成分分析
IMU	inertial movement unit	慣性感測器
ISRO	Indian Space Research Organization	印度太空研究組織
JSM	joint sparse model	聯合稀疏模式
KA	kernel alignment	
KNN	k-nearest neighbor	k-鄰近法
LDA	linear discriminant analysis	線性判別分析
MKL	multiple kernel learning	多核學習法
MLC	maximum likelihood classifier	最大似然法

MNF	minimum noise fraction	最小噪聲分離轉換
OA	overall accuracy	整體準確度
OBIA	object-based image analysis	以物件為基礎的影像分析
PA	producer's accuracy	生產者準確度
PCT	principal component transform	主成分轉換法
PLS	partial least squares regression	偏最小平方迴歸
PLS-DA	discriminant analysis based on partial least squares	判別分析基於偏最小平方迴歸
RBF	radial basis function	輻狀基底函數
REP	red-edge position	紅邊
RF	random forests	隨機森林
ROI	region of interest	感興趣區域/目標區域
SAM	spectral angle mapping	光譜角映射
SID	spectral information divergence	光譜資訊散度
SVM	support vector machines	支持向量機
UA	user's accuracy	使用者準確度
WFE	wavelet-based feature extraction	小波特徵萃取法

附件 C-1、CASI-1500h 規格表及光學率定證明文件

CASI1500h

Same CASI-1500 High Performance, But 50% Smaller¹ & Eliminates Separate Instrument Controller

Vegetation Classifications / Invasive Species / Optical Water Quality / Coral Reefs / Wetlands / Forestry / Agriculture / Change Detection / Environmental Impact Assessments / Utility Corridors

SENSOR TYPE		DIMENSIONS, WEIGHTS, AND POWER		GEORECTIFICATION SYSTEM	
VNIR Pushbroom Sensor (Compact Airborne Spectrographic Imager)		ITEM	W / H / D (cm) / WT (kg)	- GPS/IMU integration to POS AV (other systems available) - Data synchronization (GPS, attitude, and image streams) - Precision positional accuracy - After bundle adjustment no need for GCPs - Stabilized mount option	
PERFORMANCE		ENVIRONMENTAL CONSTRAINTS		GEORECTIFICATION/ORTHO CORRECTION SOFTWARE	
Spectral Range (Continuous Coverage)	380-1050nm	Operating Temperature	Ambient 0 to +35°C (+32 to +104°F) RH 20-80% non-condensing	- Best nadir pixel selection function during mosaicking - Accepts Lidar, Ifsar, and USGS DEM inputs - Nearest neighbor algorithm used – maintains radiometric fidelity - Separately stores ancillary data (e.g. pointing vector, DBM)	
# Spectral Channels	Up to 288	Maximum Altitude	3,048m (10,000 ft) ASL (unpressurized, non-condensing environment)	MOSAIC HOURLY COVERAGE Real-world operational assumptions: 35% sidelap, 3.5 minute turns, zig-zag flight direction, integration time flexibility used to optimize for faster aircraft ground speed within typical fixed-wing survey speed range. Note that as the CASI is both spectrally and spatially programmable, many other band number/airspeed/pixel resolution combinations are possible. Four simple examples (smaller pixel resolutions possible): - Up to 212 km² at 1.25 m spatial resolution and 144 bands (110 knots) - Up to 230 km² at 1.0 m spatial resolution and 72 bands (150 knots) - Up to 248 km² at 1.0 m spatial resolution and 36 bands (162 knots) - Up to 93 km² at 0.5 m spatial resolution and 48 bands (121 knots)	
# Across-Track Pixels	1500	Storage Temperature	Optimum -20 to +60°C (-4 to +120°F) RH 10-90% non-condensing		
Total Field of View	40 degrees	OPERATION		SPATIAL RESOLUTION & FLIGHT ALTITUDE - Resolutions between 20 cm to 1.5 m possible with typical unpressurized aircraft at 110 knots 1m Pixel Example (96 bands): Flight altitude = 6760 ft AGL, air speed = 110 knots	
IFOV	0.49 milliradians	Display	15" sunlight readable, 1024x768 resolution. High altitude display available.		
f/#	f/3.5	Operator	Control Via Keyboard, Windows™ OS		
Spectral Width Sampling/Row	2.4nm	Real-Time Display	Scene Image, automated sensor health diagnostics, signal level display		
Spectral Resolution (FWHM)	<3.5nm	Remote Diagnostics	Ethernet-ready remote diagnostic capability	¹ by volume	
Pixel Size	20x20 microns	Data Storage	Swappable mass storage		
Dynamic Range	14-bits (16384:1)	Multiple Sensor Operation	Up to 5 ITRES imagers may be simultaneously operated via MUSIC™ System		
Frame Rate	Up to 333 frames per second	DATA PROCESSING SYSTEM			
Data Rate	19.2 Mb/sec	- Processing software Linux or Windows-based - Playback software (Quicklook) - Generates 16-bit 32 bit BIP format data compatible with ENVI (BIL, BSQ formats possible) - ASCII format ancillary QC data output – clocking, attitude, logging, GPS, and sensor health monitoring information - Outputs diagnostic information - Selectable band output			
Spectral Smile/Keystone Distortion	±0.35 pixels				
Peak Signal to Noise Ratio	SNR models for various radiance conditions are available				

CASI-1500 Imagery:



CASI-1500 imagery, Antarctica, 2011. Courtesy collaboration between British Antarctic Survey, DRDC Suffield, & ITRES

ITRES Research Limited

Calgary, Alberta, Canada

T: +1.403.250.9944

F: +1.403.250.9916

USA Contact Information

T: +1.228.467.2345

TF: +1.877.250.9944

info@itres.com

www.itres.com

Document ID: U10082-00

© 2012 ITRES Research Limited

All ITRES sensors are calibrated to traceable standards. Specifications subject to change without notice.



CASI-1500 Instrument Certification #0760

Date: September 14, 2020
Serial Number: 2608
Customer: Chung Hsing Surveying Co. Ltd.
 159 Chung-jen Street, West District
 Taichung 403
 Taiwan R.O.C.

1. Spectral Range: 372.5- 1058.4nm
 2. g-coefficients: $g_0 = 1057.2208$
 $g_1 = -2.3860183$
 $g_2 = 4.7602393e-005$
 $g_3 = -1.1422683e-007$
 3. Gain: 77.28 e-/DN Left
 72.32 e-/DN Right
 4. Noise Floor: 189.31 e- Left
 144.77 e- Right
 5. Peak Sensitivity: 1598 DN/SRU-s-pixel @ 850 nm
 2992 DN/SRU-s-pixel @ 650 nm
 2257 DN/SRU-s-pixel @ 450 nm

6. CCD Temperature: 298 °K

7. Dark Current Generation Rate:

Region	Left Side	Right Side
IR	0.64	0.65
Red	1.03	1.04
Blue	0.98	0.99

(DN/ms/pixel)

8. Spectrograph Alignment: axis: alignment:
 Spatial 0.27 spectral pixels across
 1500 spatial pixels
 Spectral 0.36 spatial pixels across
 288 spectral pixels

9. Image Pixels: 1500

10. Data Offset: 23

11. Scattered Light Column 13 (Left Side); 1536 (Right side)

12. Traceable Light Standard: Labsphere IS 97612B – Lamp 2 (Rectangular Aperture)

Calibrated By: Alejandro Umaña Diaz

Date: Sep 14, 2020

Verified By: Gabe De Guzman

Date: Sept. 14 / 2020

ITRES Research Limited
 Unit 8, 2121 – 29 Street NE
 Calgary, Alberta, Canada T1Y 7H8
 Tel: (403) 250-9944 Fax: (403) 250-9916

Email: info@itres.com
 WWW: <http://www.itres.com>

附件 C-2、雷射掃描儀及數位相機規格表



1 台

空載雷射掃描儀

Optech PegasusHD400(SN: 10SEN274)

- 掃描旋角視域FOV：0~60度
- 脈衝率PRF：100~400kHz
- 掃描鏡頻率：0~140Hz
- 掃描形式：Oscillating, Mirror, Z-shaped
- 高程精度：<5-20 公分, 1 σ , 航高 1200 米
- 水平精度：1/7,500 航高
- 斜距解析度：1 公分
- 最大掃描帶寬：0~0.93航高
- GPS：Trimble
- Position Orientation System：Applanix POS 510
- 作業用途：獲取高精度密佈於地表之三維點位



1 台

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(1 σ)
- 水平精度：1/7,500航高(1 σ)
- 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



1 台

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



1 台

數位相機

PhaseOne iXU-R1000

- CCD-chip:53.4*40.0mm
- 像幅大小:11608x8708 pixels
- 像素大小:4.6um
- 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

定翼機

Cessna 208

- 長度：12.67 米 (41 英尺 7 英寸)
- 翼展：15.87 米 (52 英尺 1 英寸)
- 高度：4.60 米 (15 英尺 1 英寸)
- 翼剖面：NACA 23000 系列
- 展弦比：9.555
- 空重：2067 公斤 (4558 磅)



附件 D-1、教育訓練

本計畫分別於 110 年 10 月 15 日和 110 年 10 月 22 日於農林航空測量所 201 會議室提供有關高光譜影像資料分析、機器學習和實際影像操作之教育訓練 2 場，各場次時數為 4 小時，教育訓練之內容項目與時數分配表如表 D-1 所示。圖 D-1 為本計畫為自行撰寫的實際高光譜影像分類使用者介面，可透過使用者介面了解本計畫中採用的支持向量機和一維卷積神經網路參數設定方式及分類成果。圖 D-2 與圖 D-3 分別為教育訓練的簽到單及現場相片記錄，

表 D-1、教育訓練項目及時數分配

時間	內容	時數	講師
場次 1(110 年 10 月 15 日)			
10:00-11:00	高光譜影像基本概念及近年發展	1	徐百輝
11:00-12:00	高光譜影像分類演算法介紹	1	徐百輝
12:00-13:30	午休		
13:30-14:30	高光譜影像分類演算法介紹(續)	1	徐百輝
14:30-15:30	機器學習演算法介紹	1	徐百輝
場次 2(110 年 10 月 22 日)			
10:00-12:00	機器學習與深度學習於高光譜之應用	2	徐百輝
12:00-13:30	午休		
13:30-15:30	實際高光譜影像分類流程及優化	2	黃琇蔓
備註	上午、下午各有 10 分鐘休息時間，亦可於會後自由討論		




圖 D-1、自行開發之實際高光譜影像分類使用者介面

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重要樹種調查之研究(2/2)」成果報告書

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重要樹種調查之研究(2/2)」
教育訓練簽到表
時間：110年10月15日上午10時00分
地點：台北市中正區和平西路二段100號2樓201會議室

單位	姓名	素(請勾)
	吳以寧	
	林科意	✓
	李銘堯	X
資源調查課	劉國同	
	陳玉雯	
資料管理課	李鴻德	
	陳天駿	
空間測量課	林慧筠	
"	葉堃生	X
"	劉政同	
"	謝幸宜	
"	張昭慶	X
影像處理課	李友園	

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重要樹種調查之研究(2/2)」
教育訓練簽到表
時間：110年10月15日上午10時00分
地點：農林航空測量所201會議室

單位	姓名	素(請勾)
台大土水	徐百輝	
"	黃瑋菱	
華僑大學	楊華智	

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重要樹種調查之研究(2/2)」
教育訓練簽到表
時間：110年10月22日上午10時00分
地點：台北市中正區和平西路二段100號2樓201會議室

單位	姓名	素(請勾)
	吳以寧	
	林科意	✓
影像處理課	李友園	
	楊華智	
資源調查課	劉政同	
	陳玉雯	
資料管理課	李鴻德	

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重要樹種調查之研究(2/2)」
教育訓練簽到表
時間：110年10月22日上午10時00分
地點：台北市中正區和平西路二段100號2樓201會議室

單位	姓名	素(請勾)
國立台灣大學	徐百輝	
	黃瑋菱	X
空間測量課	劉政同	
空間測量課	林慧筠	
"	陳天駿	
"	謝幸宜	
"	葉堃生	X
	許玉昌	X

圖 D-2、教育訓練簽到單



圖 D-3、教育訓練現場相片

附件 D-2、成果交付

本計畫履約期限自決標日次日至 110 年 12 月 17 日止，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 D-22 所示。

一、第 1 期

自決標次日起 20 日曆天內(即 110 年 3 月 25 日前)，繳交工作計畫書一式 12 份及電子檔 1 份，說明本計畫相關工作項目，含預計研究方法、各工作項目之作業方式與流程、作業期程及進度管控、人力分配等章節。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，於限期內繳交修正後工作計畫書電子檔(修正後之工作計畫書視為契約之一部份)。

二、第 2 期

已於 110 年 7 月 10 日前繳交期中報告書一式 12 份及電子檔 1 份，由貴所據以召開期中審查會議，及本團隊簡報和說明。經會議審核通過後，本團隊將於期中會議審查通過後限期內繳交修正後之期中報告書電子檔。

三、第 3 期：

- (一) 期末報告書：已於 110 年 11 月 12 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。經期末審查會議通過後，依審查意見修改並於限期內繳交修正後期末報告書電子檔。
- (二) 成果報告書：修正後期末報告書電子檔經機關審核，通過始得據以印製成果報告書，如未依期末審查意見修改，應限期再修正。
- (三) 教育訓練：於 110 年 10 月 31 日前辦理 2 場至少各 4 小時的教育訓練。已於 110 年 10 月 15 日及 10 月 22 日辦理。
- (四) 成果交付：於 110 年 12 月 17 日前繳交成果，由貴所辦理驗收。
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(容量 2TB 以上)，包含下列內容：
 - (1) 成果報告書電子檔(docx、odt 及 PDF 檔等 3 種格式儲存)。
 - (2) 簡報檔：各期會議、工作會議及教育訓練之簡報(pptx 及 PDF 格式)。
 - (3) 本計畫試驗相關影像檔案、成果及其清單。

表 D-2、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	110 年 3 月 25 日前
	2	修正後期初工作計畫書	電子檔 1 份	期初審查會議通過後限期內
第 2 期	1	期中報告書	書面資料 12 份 電子檔 1 份	110 年 7 月 9 日前
	2	修正後期中報告書	電子檔 1 份	期中審查會議通過後限期內
第 3 期	1	教育訓練	2 場至少各 4 小時	110 年 10 月 15 日 110 年 10 月 22 日
	2	期末報告書	書面資料 12 份 電子檔 1 份	110 年 11 月 12 日
	3	修正後期末報告書	電子檔 1 份	期末審查會議通過後限期內
	4	成果報告書	書面資料 12 份	110 年 12 月 17 日前
	5	外接式儲存裝置，內含成果報告書電子檔、各期會議簡報檔、本計畫試驗相關影像檔案、成果及其清單。	電子檔各 1 份	110 年 12 月 17 日前