林務局農林航空測量所 叢刊 149 號

行政院農業委員會林務局
農林航空測量所

「機器學習於航攝影像森林覆蓋型萃取之研究（1/3）」
成果報告書

全程計畫：自 109 年 3 月至 111 年 12 月止

本年度計畫：自 109 年 3 月至 109 年 12 月止

執行廠商：興創知能股份有限公司

中華民國 109 年 12 月 10 日

目　錄

目　錄.....I
表　目　錄.....III
圖　目　錄.....IV
摘要.....1
第壹章、前言.....3
1-1 計畫緣起及目的.....3
1-2 全程計畫目標.....4
1-3 三年期計畫目標.....5
第貳章、工作範疇與成果摘要.....7
2-1 工作項目.....7
2-2 工作架構.....8
2-3 期程說明.....8
第參章、資料蒐集.....13
3-1 文獻蒐集.....13
3-2 航攝影像蒐集.....21
3-3 現地資料蒐集.....28
3-4 其他與研究相關之資料蒐集.....42
第肆章、航遙測影像分類技術之分析與功能評估.....50
4-1 影像分類技術分析.....50
4-2 開發平台功能評估.....55
第伍章、深度學習演算法之研究探討.....65
5-1 機器學習影像分類演算法分析與評估.....65
5-2 機器學習開發平台分析.....69
第陸章、森林物件萃取標準化流程雛型之建立.....74
6-1 森林物件萃取標準化流程架構規劃.....74
6-2 機器學習模型訓練、判釋與更新之流程.....97
第柒章、教育訓練.....131
7-1 教育訓練規劃.....131

7-2 研討會投稿規劃.....134
第捌章、結論建議與續期規劃.....136
8-1 結論.....136
8-2 建議.....137
參考文獻.....140
附錄一 相關名詞及其說明.....153
附錄二 各階段審查意見與回覆情形.....156
附錄三 文獻總表.....180
附錄四 工作會議記錄.....191
附錄五 教育訓練簡報.....198

表　目　錄

表 2-1 本計畫各期程規劃 10
表 2-2 實際進度表 11
表 2-3 期末進度摘要表 12
表 3-1 農林航空測量所航攝影像圖資規格 24
表 3-2 DMC 航空攝影紀錄檔格式說明 25
表 3-3 國有林事業區檢訂調查項目 29
表 3-4 臺灣地區森林覆蓋面積 36
表 3-5 全國性森林資源調查比較表 36
表 3-6 林型面積占比 37
表 3-7 第四次森林資源調查林型分類對照表 41
表 3-8 第四次森林資源調查林型圖資屬性表 42
表 4-1 影像分類演算法比較表 54
表 4-2 開發平台規格比較 55
表 5-1 深度學習開發程式語言比較 73
表 5-2 深度學習套件比較 73
表 5-3 程式編譯器比較 73
表 6-1 林型區分標準 78
表 6-2 共線條件式參數符號對照 82
表 6-3 林型圖純林樹種清單 89
表 6-4 林型圖純林樹種內各樹種圖框涵蓋數量與平均面積 90
表 6-5 操作情境對照表 98
表 6-6 誤差矩陣對照表 110
表 6-7 樹種判釋分類誤差矩陣 111
表 6-8 自動化流程操作時效紀錄 130
表 7-1 教育訓練議程表 131
表 7-2 國內外重要研討會列表 135

圖　目　錄

圖 2-1 本計畫 109 年工作架構 9
圖 3-1 航攝影像圖資瀏覽服務平台 23
圖 3-2 航空照片範本 23
圖 3-3 本計畫使用之航攝影像位置分布 26
圖 3-4 本計畫使用之航攝影像各月統計 27
圖 3-5 本計畫使用之航攝影像各年統計 27
圖 3-6 檢訂調查工作流程 30
圖 3-7 永久樣區設立流程圖 31
圖 3-8 森林永久樣區分布圖 32
圖 3-9 全島各縣市森林覆蓋範圍圖 35
圖 3-10 森林林型分布圖 38
圖 3-11 數值地形模型比較示意圖 46
圖 3-12 浮水印影響示意圖(TRI) 47
圖 3-13 全臺數值高程模型資料 48
圖 3-14 地形因子萃取結果 49
圖 4-1 像元式分類辨認方式示意圖 56
圖 4-2 多尺度切割法示意圖 57
圖 4-3 SAGA 圖形化介面呈現 60
圖 4-4 CMD 腳本進行專案批次分析 60
圖 5-1 CNN 模型架構 67
圖 5-2 FCN 模型架構 69
圖 5-3 U-Net 模型架構 69
圖 5-4 深度學習開發環境要件 72
圖 6-1 森林物件萃取標準化流程藍圖 75
圖 6-2 森林物件萃取標準化流程雛形 75
圖 6-3 點線面向量圖層網格化示意圖 79
圖 6-4 物空間與相片平面之對應關係 82
圖 6-5 林型圖圖資反投影前後差異 83

圖 6-6 反投影背坡處空間交會 83
圖 6-7 林型圖圖資反投影後圖框交叉扭曲個案情況.....84
圖 6-8 圖框網格化反投影示意圖 84
圖 6-9 林型圖圖框交叉扭曲修正後結果 85
圖 6-10 不同空間解析度導致反投影後空缺差異 86
圖 6-11 以內插補值方法填補網格內所有林型圖純林樹種.....87
圖 6-12 林型圖純林樹種反投影成果與航空照片之套疊.....87
圖 6-13 測試不同內縮範圍以修正系統性對位偏差 88
圖 6-14 標記樹種於航攝影像之分類案例 91
圖 6-15 本計畫使用之 11 項參數特徵案例 92
圖 6-16 各項特徵參數與標記圖框反投影於航攝影像之案例.....93
圖 6-17 樹木色調與顏色範例 95
圖 6-18 樹冠形狀範例 95
圖 6-19 樹木圖案範例 96
圖 6-20 樹木陰影範例 96
圖 6-21 影像遮蔽 99
圖 6-22 影像切片示意圖 100
圖 6-23 資料增強示意圖 101
圖 6-24 各樹種切圖完成後之張數統計 102
圖 6-25 11 類樹種影像裁切之訓練樣本案例 103
圖 6-26 資料集切分示意圖 104
圖 6-27 模型建構與訓練說明 105
圖 6-28 模型設計架構示意圖 106
圖 6-29 交集除以聯集 (Intersection over Union) 109
圖 6-30 各樹種訓練回合之統計情形 111
圖 6-31 判斷正確與錯誤分類統計 113
圖 6-32 各樹種錯誤分類次數統計(1/3) 114
圖 6-33 各樹種錯誤分類次數統計(2/3) 115
圖 6-34 各樹種錯誤分類次數統計(3/3) 116

圖 6-35 單桿狀竹錯誤分類案例 117
圖 6-36 叢生狀竹錯誤分類案例 118
圖 6-37 台灣赤楊錯誤分類案例 119
圖 6-38 相思樹錯誤分類案例 120
圖 6-39 冷杉錯誤分類案例 121
圖 6-40 鐵杉錯誤分類案例 122
圖 6-41 柳杉錯誤分類案例 123
圖 6-42 台灣杉錯誤分類案例 124
圖 6-43 杉木錯誤分類案例 125
圖 6-44 松樹錯誤分類案例 126
圖 6-45 檜木錯誤分類案例 127
圖 6-46 訓練資料特徵貢獻案例 129
圖 7-1 教育訓練照片記錄 132
圖 7-2 教育訓練簽到表(1/2) 133
圖 7-3 教育訓練簽到表(2/2) 134

摘要

本計畫為三期計畫(109 年~111 年)之第一年，結合森林資源調查專業、機器學習與電腦視覺專長，應用航攝影像對森林覆蓋型建立自動化分類技術。基於 DMC 數位航空照片，提出現行森林資源調查架構下，並評估適用於森林覆蓋型之自動化判釋流程的深度學習方法，透過自行開發具有平行處理之程式碼，已可加速與優化數位航空照片影像與數值地形之因子萃取前處理，並嘗試開發深度學習演算法與模型架構與參數優化，已證實自動判釋流程的可用性。

第一年計畫，在資料蒐集方面，首先回顧 60 餘篇有關森林覆蓋型與樹種分類的相關文獻，提供本計畫選擇分類因子參考。本計畫依據第四次森林資源調查的森林覆蓋型圖資，第一年度計畫彙整檢訂調查、永久樣區調查與第四次森林資源調查林型圖中屬於純林樹種的森林覆蓋型之樣本資料；取得 718 幅 DMC 數位影像，以 20 公尺解析度的 DEM 萃取森林覆蓋型分類有關的各項因子，選定 5 項波段因子特徵與 6 項地形因子特徵，共 11 項因子，包括：包含可見光影像中的紅光(Red)、綠光(Green)、藍光(Blue)、近紅外光(NIR)、常態化差值植生指標(NDVI)、數值高程模型(DEM)、坡度(Slope)、坡向(Aspect)、粗糙度(Roughness)、地形位置指數(TPI)、地形堅固指數(TRI)。進行深度學習的人工智慧模型建置之標的樣本，分為訓練與測試之樣本，其比例為 7:3。本計畫針對常見的遙測影像的分類機器學習演算方法進行研析與比對後，決定採用深度學習的卷積神經網路(CNN)進行模型之設計較適用於森林型覆蓋型分類，可持續優化其深度學習模型架構與參數。然而於深度學習模型建立前，本計畫大部分時間投入於影像與 DEM 前處理與分類因子之萃取，以及透過攝影測量方法解決向量之林型圖框標記資料反投影至原始航照上的圖資變形問題。因受限於既有之商業 GIS 軟體的功能與效率，無法

處理大量影像與數值地形數據，雖現行 GIS 軟體中包含許多演算法，但這些軟體普遍適用於專案形式的開發工作，預期將有許多操作上的不便利。因此，本計畫採用 Python 以開源程式碼開發各項分類需求之資料前處理的 GIS 程式工具開發，並可平行運算效率化。使用常見 Tensorflow 與 Keras 深度學習開發套件，並且在 Python Jupyter 的編譯環境下，以實現自動化作業為目標進行開發，已初步完成森林物件萃取標準化流程雛形之建立。上述 Python 程式碼完成之資料前處理之效率化程式，串聯優化其程序後，已可進行 CNN 深度學習模型訓練，建構自動化操作流程雛形。本計畫成果已辦理 4 小時之教育訓練，充分介紹目前初步之成果，並且討論未來改進之要項。

最終以樹種樣本數可達 3000 個以上的 11 類純林樹種分類(包括：單桿狀竹、叢生狀竹、臺灣赤楊、相思樹、冷杉、鐵杉、柳杉、台灣杉、杉木、松樹(二葉松、五葉松等)及檜木)進行辨識之全自動深度學習模型，並且整體準確率可達 65.3%，Kappa 值為 0.618。未來將持續優化自動化流程，包含強化攝影測量校正森林覆蓋型圖框於原始航照位置之疊合，並持續改善資料前處理以及判釋效率，將更進一步測試混淆林型的樹種分類，建構符合現行作業流程需求之客製化與自動化的森林覆蓋型的軟體系統。

第壹章、前言

1-1 計畫緣起及目的

臺灣森林占全島土地面積近六成比例，除林木本身經濟價值外，同時也是國土保安、水源涵養、氣候調節、育樂遊憩以及生物多樣性維護之重要角色。為獲得林地經營所需之土地覆蓋型空間資訊，需藉由森林資源調查，而為獲取森林植群變遷之空間資訊，則需長期持續累積特定植群空間分布資料，並從中獲取研究氣候變遷之線索。

相關空間資訊若採用現地進行地面調查作業，可獲得最真實的資訊，然而森林面積廣闊且多位於坡地不易到達之處，在人力、安全及經費考量下，僅能蒐集有限範圍之樣點資料並統計推估，而無法有效獲得大範圍之空間資訊。藉由航空攝影測量及衛星遙測等技術，則可獲取中、大尺度之空間資訊，其中衛星影像可同時獲得大區域的影像資訊，並以影像分類技術獲得大範圍之空間資訊，惟受限於衛星影像之空間解析度，使其對於植群之紋理特性較為不足，無法進行較細類別之區分；航空測量之尺度介於地面調查與衛星遙測，除了具備與衛星遙測相同的光譜感測特性外，也具備表現紋理特徵之特性。近年快速發展之無人機航遙測技術，能於低空進行拍攝任務，補充航攝飛機較難達成之雲下取像作業，為逐漸被採用之航測輔助工具。

由於現行大面積資源調查及土地覆蓋型更新等，尚需倚賴大量人力進行航攝影像判釋與測繪作業，常因優秀航照判釋人才不易培訓及訓練成效不易掌握，進而影響資料品質與期程，是以有發展科技輔助森林資源調查之必要，本計畫團隊將針對以上關鍵課題進行分析及提出解決方案。

林務局為負責本國航遙測圖資蒐集與產製之政府單位，除連年以先進數位航攝像機進行航空影像之拍攝外，亦建置有大規模之歷史航遙測影像倉儲，持續納管最新航攝影像成果，並提供各界作為判釋調查之基礎影像資料，同時支援林務局森林資源調查與檢訂作業所需之中尺度土地覆蓋型航測資訊。如能在現有基礎上發展機器學習等技術，降低現行人工判釋圈繪作業工作量及作業時程，提高作業效率，則有機會在更穩定的資料標準及較低之人力時間成本下，加速土地覆蓋型資訊之取得、擴大國土資訊取得之範圍，進而提升空間資訊之時間向度，從而掌握變遷資訊，兼而擴大發揮航遙測影像倉儲之功能。

本計畫團隊即欲基於農林航空測量所(簡稱農航所)之航遙測影像倉儲內之歷年巨量航攝影像，應用近年蓬勃發展之機器學習相關技術，發展航攝影像森林物件自動判釋技術，嘗試萃取森林覆蓋型、種類及變異等空間資訊，期能補足傳統人工判釋之不足，降低人為主觀判釋之差異及森林資源調查之成本，進一步經由累積時間向度之森林覆蓋空間資訊，嘗試研究特定物種之影像辨識萃取，評估作為取得植群調查相關研究所需輔助圖資之可行性。

1-2 全程計畫目標

本計畫預計以 3 年為期(109 年至 111 年)，本計畫團隊將藉助科技專業與學術研究，協助整合數值航測、航遙測影像分類、機器學習等相關技術，針對符合未來應用規格之航攝影像或無人飛行載具所拍攝之影像（以地面解析度 0.5 公尺或優於 0.5 公尺，可見光、多光譜或高光譜影像等為原則），研究在現行森林資源調查架構下，提出適用於森林物件自動化判釋流程的機器學習技術並進行相關驗

證，藉以評估機器學習於航攝影像自動判釋輔助森林覆蓋型人工判釋圈繪作業及特定植群分布資訊萃取之可行性。

本案須以機器學習演算相關技術，進行航攝影像中特徵物件萃取為主要研究方向，搭配農航所航攝巨量資料及相關地真資料，進行包含機器學習相關演算法，及高速運算導入等相關測試研究，並在演算法及流程上研究效能提升方案，以進一步加速分類效果與速度。

研究亦應就前述所發展之機器學習相關演算法，以及參考國家航遙測圖資建置情形，研擬制定相關影像特徵規格及流程規範，並以資料庫或其他對應方式建置相關特徵集，以利後續長期資料蒐集與建置所需。

1-3 三年期計畫目標

一、109 年度目標 (本計畫 109 年度目標)

1. 研究區域規劃與資料蒐集；
2. 航遙測影像分類技術之分析與功能評估；
3. 機器學習演算法應用於航遙測影像分類之研究探討；
4. 現行森林資源調查架構下以機器學習技術建置森林物件調查流程雛型；
5. 教育訓練。

二、110 年度預定目標(後續擴充)

1. 研究高解析度航攝及 UAV 影像以機器學習技術自動化萃取森林覆蓋型之演算模式與實作；
2. 評估機器學習相關軟體與國內高速運算資源及測試；
3. 研究機器學習演算法及流程效能提升方案；

4. 以機器學習技術自動萃取森林物件特徵演算法評估測試與調查流程建置；
5. 投稿至少 1 篇論文至國內外期刊或研討會；
6. 教育訓練。

三、111 年度預定目標(後續擴充)

1. 實證區域規劃與資料蒐集；
2. 機器學習之軟體開發與硬體規劃、實作與流程標準化；
3. 現行森林資源調查架構下以機器學習技術自動化智慧判釋森林覆蓋型模式之實測、效能評估及修正；
4. 開發機器學習自動化智慧分析介面與調查流程完整化；
5. 機器學習應用於特定物種自動化偵測之可行性評估；
6. 投稿至少 1 篇論文至國內外期刊或研討會；
7. 教育訓練。

第貳章、工作範疇與成果摘要

2-1 工作項目

本計畫 109 年度研究相關工作項目及內容說明如下：

一、資料蒐集，包含：

(一)文獻蒐集：蒐集整理與研究有關之文獻，並歸納相關方法與未來趨勢，以及敘明採用之方法及原因。

(二)航攝影像蒐集：研究區域之不同時期航攝影像之取得及規格確認，相關影像應包含不同物候時期之表現型，如無合適航攝影像，則應以解析度優於 0.5m 之遙測衛星影像補充之。

(三)現地資料蒐集：研究區域地真資料與圖資蒐集。

(四)其他與研究相關之資料蒐集。

二、航遙測影像分類技術之分析與功能評估：

就研究區內地類之影像光譜、紋理等特徵進行研究測試及特徵選擇等，評估合適的遙測影像分類法及搜尋開發平台，測試運作之可行性。

三、演算法之研究探討：

針對現有機器學習領域之成熟演算法及發展中演算法進行比較，搜尋適合於航攝巨量資料之機器學習演算法及相關開發平台，並測試於不同空間解析度及光譜組成之航攝影像，進行森林物件資訊萃取運算，瞭解其運作成效及規劃後續研究之相關方案。

四、森林物件萃取標準化流程雛型之建立：

針對前述之研究結果，提出現行森林資源調查架構下以機器學習進行森林物件自動化智慧分析模式之流程雛形，並參考國家航遙測圖資建置情形，研擬相關影像特徵規格及規範，作為往後發展對應特徵資料庫之參照。

五、教育訓練：

辦理至少 4 小時遙測影像分類理論與技術相關教育訓練 1 場。本年度研究結果應包含就研究過程及相關討論，提供下一年度研究方向之修正建議。

2-2 工作架構

本年度(109 年)將先完成森林物件自動化智慧分析雛型規劃，首先建立森林物件之訓練樣本，並藉由現行之遙測方法進行森林覆蓋型分類，再進一步由機器學習方法進行分類，嘗試建立自主之程式可進行森林物件分類，並建立森林物件萃取標準化流程雛形之建立及研擬相關影像森林特徵規格及規範，並規劃航攝巨量資料之機器學習演算法及相關開發平台。工作架構如圖 2-1。

2-3 期程說明

本計畫執行期程自簽約日起至民國 109 年 12 月 10 日止，預計期程與成果如表 2-1。另表 2-2 為至期末階段之實際進度甘梯圖，說明各階段之工作完成百分比，而期末進度簡要摘要內容如表 2-3 所示。

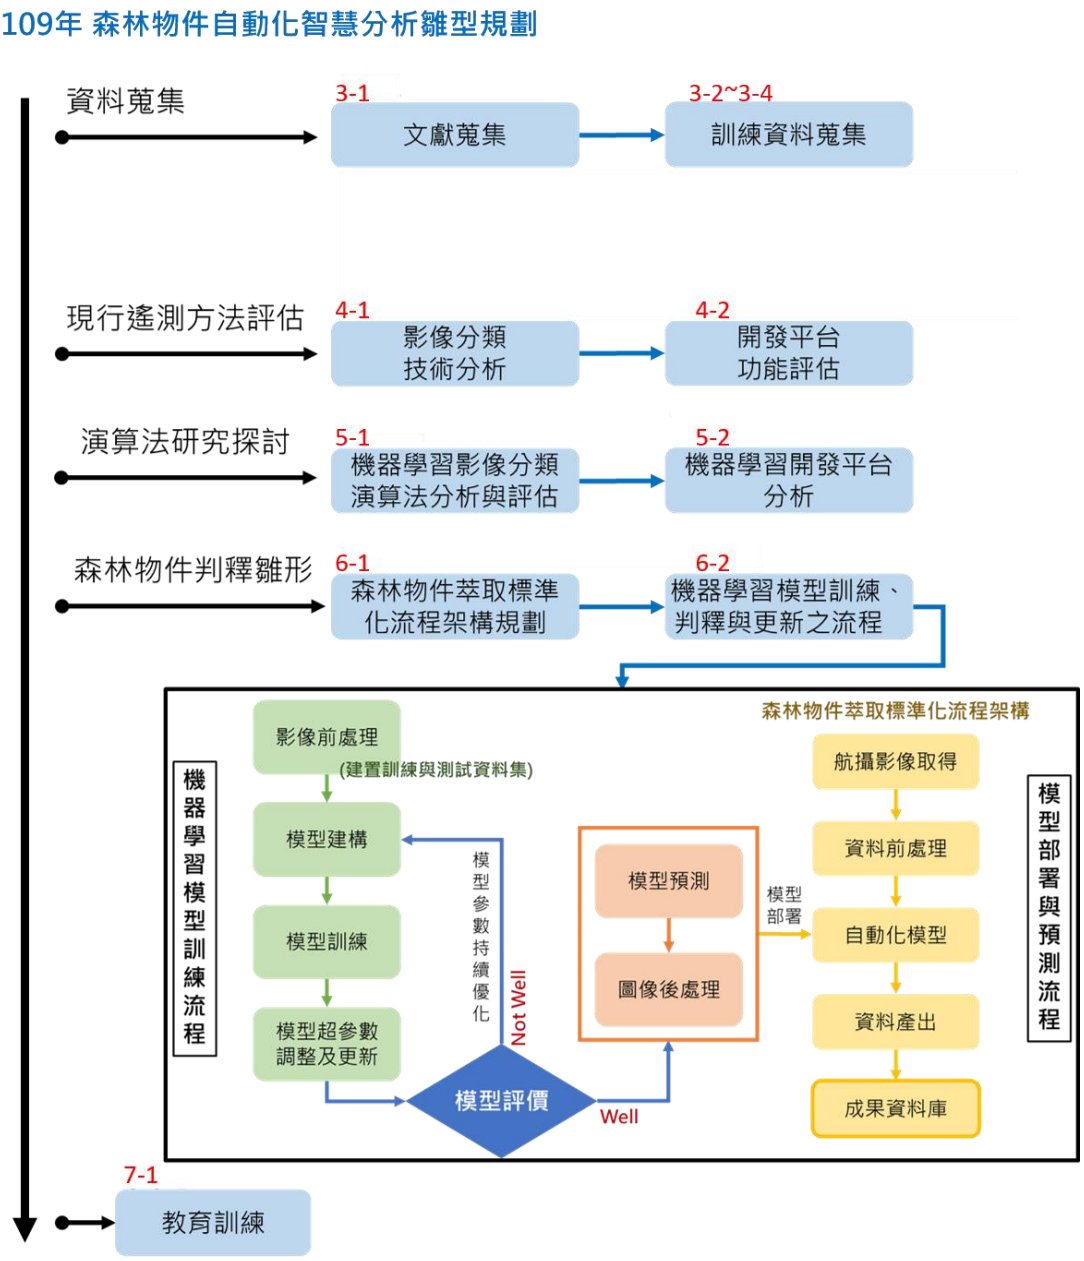

圖 2-1 本計畫 109 年工作架構

表 2-1 本計畫各期程規劃

期程	提送日期	至少應完成項目
第 1 期	決標次日起 20 日內	1. 研提計畫工作項目，含預計研究方法、完成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。 2. 繳交工作計畫書 12 份及電子檔 1 份。
	期初審查會議通過次日起 10 日內	繳交修正後工作計畫書 2 份及電子檔。
第 2 期	109 年 6 月 10 日	1. 完成研究文獻收集、樣區規劃、航攝影像及 UAV 影像資訊獲取、航遙測影像分類技術之初步評估及機器學習演算法應用於航遙測影像分類之初步研究等工作項目。 2. 繳交期中報告書 12 份及電子檔 1 份。
	期中審查會議通過次日起 10 日內	繳交修正後期中報告書電子檔。
第 3 期	109 年 11 月 10 日	1. 辦理 1 場至少 4 小時之教育訓練。 2. 完成資料蒐集、航遙測影像分類技術之分析與功能評估、機器學習演算法應用於航遙測影像分類之研究探討、現行森林資源調查架構下以機器學習技術建置森林物件調查流程等工作項目。 3. 繳交期末報告書 12 份及電子檔 1 份。
	期末審查會議通過次日起 10 日內	繳交修正後期末報告書初稿電子檔。
	109 年 12 月 10 日	1. 成果報告書 12 份。 2. 外接式儲存裝置 1 份（包含成果報告書電子檔、各期會議簡報檔、本案試驗相關影像檔及其清單）。

表 2-2 實際進度表

	工作項目	月次	1	2	3	4	5	6	7	8	9	10	實際完成百分比
		年別	109年度										
		月份	3月	4月	5月	6月	7月	8月	9月	10月	11月	12月	
1	資料蒐集												
	1-1	文獻蒐集											100%
	1-2	航攝影像蒐集											100%
	1-3	現地資料蒐集											100%
	1-4	其他與研究相關之資料蒐集											100%
2	航遙測影像分類技術之分析與功能評估												
	2-1	影像分類技術分析											100%
	2-2	開發平台功能評估											100%
3	演算法之研究探討												
	3-1	機器學習影像分類演算法分析與評估											100%
	3-2	機器學習開發平台分析											100%
4	森林物件萃取標準化流程雛形之建立												
	4-1	森林物件萃取標準化流程架構規劃											100%
	4-2	建立機器學習模型訓練、判釋與更新流程											100%
5	教育訓練												
	5-1	辦理4小時遙測影像分類理論與技術教育訓練											100%
	預定進度累積百分比		10%	20%	30%	40%	50%	60%	70%	80%	90%	100%	

工作計畫書 (4/1)　期中報告 (6/10)　期末報告 (11/10)　成果報告 (12/10)

表 2-3 期末進度摘要表

項次	工作項目	期末進度摘要說明
1	資料蒐集	1. 文獻蒐集於期末階段累計至 60 篇(請參閱參考文獻一章)。 2. 文獻清單彙整總表。 3. 取得 20 公尺解析度 DEM 與其衍生地形資料。 4. 透過光譜計算得到 NDVI 值。
2	航遙測影像分類技術之分析與功能評估	1. 選擇以 CNN+DNN 作為演算法。 2. 選擇以 Python+Jupyter 做為開發平台。
3	演算法之研究探討	持續演算法之更新與優化。
4	森林物件萃取標準化流程雛形之建立	1. 資料前處理作業，含林型圖資反投影套疊至原始航照影像程式。 2. 挑選單桿狀竹、叢生狀竹、臺灣赤楊、相思樹、冷杉、鐵杉、柳杉、台灣杉、杉木、松樹(二葉松、五葉松等)及檜木共 11 種作為判釋樹種。 3. 各樹種採七比三比例建立訓練及測試資料集。 4. 期末階段樹種判釋成果，整體精度 65%，kappa 值 0.62。
5	教育訓練	已辦理教育訓練。

第參章、資料蒐集

為了能在現行森林資源調查架構下，具體實現森林物件自動化判釋之目標，資料的蒐集尤其重要，除了文獻經驗之累積，更攸關資料品質之掌握。因此，本計畫在資料蒐集章節中將其分為四個部分，包含文獻蒐集、航攝影像蒐集、現地資料蒐集與其他相關之資料蒐集。

3-1 文獻蒐集

一、文獻回顧

森林係為重要的自然資源，為達到永續經營之目標，必須先掌握森林植群樹種空間分布與其變遷之空間資訊。對森林資源管理而言，掌握森林生態系統的植被類型及精確的瞭解森林資源的分布，是相當基礎且重要的工作(Shen et al., 2010)。快速、準確與有效率的植物辨識，對於研究和管理生物多樣性是相當關鍵的基礎工作，建立精確植被地理分佈，對於當下與未來的生物多樣性保護更是相當重要的關鍵課題。因此樹種的空間分布資料是森林管理、研究與應用的關鍵資訊，可提供像是森林永續經營(Kou et al., 2018)、生物多樣性監測(Shang and Chisholm, 2014)、氣候變遷(Chen et al., 2015)等相關議題之應用。在既有的森林資源調查與檢訂作業中，透過地面調查作業，可以獲取真實的林地現況資料。然而森林幅員廣闊，在人力、安全與經費的考量之下，要能全面性地調查每一寸土地實為相當困難。植物物種鑑別對林業人員、生態學家、航照判釋員與農民等而言，是一項艱鉅的任務，透過野外觀察鑑識植物種類需要大量的樹木學專業知識。因此透過航遙測技術，實現全面性資源盤點是為必要之作法。而善用航遙測技術在繪製樹種分布的工作上則可提供大空間尺度資訊之優勢(Alonzo et al., 2014)。

應用航遙測影像進行樹種的分類技術，已經有許多相關的研究顯示具有其潛在的價值與挑戰性(Karathanassi et al., 2007; Zhang & Xie, 2013; Nevalainen et al., 2017 ; Xie et al., 2019)。傳統航測判釋樹種分類的方法需要大量的人力和經費(Peerbhay et al., 2013)。近年來，航遙測影像樹種辨識的研究，逐漸由使用單一影像資料，進入到多種或多期影像資料組合(Karathanassi et al., 2007)，多時期影像的導入可能包含有關植被物候，意即植物生長階段的時序變化，以及林分結構的資訊，可以提供更好的分類準確性。應用多元種類與多光譜航遙測於樹種分類的研究，經常以光譜(Spectral)、植生指標(Vegetation Index)、紋理(Texture)、形狀(Shape)、林分結構(Structure)等作為建構分類模型的變數。

近年來機器學習的影像處理技術被廣泛應用於生物種類的識別，許多研究經常透過機器學習演算法，將拍攝的影像資料透過植物特徵為其作出物種判釋。包含傳統的統計分類器，像是判別分析(Discriminant Analysis)、最大概似法(Maximum Likelihood classifier，MLC)。再到機器學習演算法甚至是深度學習演算法，例如隨機森林(Random Forest)、支持向量機(Support Vector Machine)、類神經網路(Artificial Neural Network，ANN)、卷積神經網路(Convolutional Neural Network，CNN)等(Fassnacht et al., 2016; Xie et al., 2019)皆有持續性的應用與發展。有許多研究已經可以透過結合光譜影像與機器學習方法，分類出 5-10 種植物類別(Ghimire et al., 2010; Pal, 2005; Omer et al., 2015; Priedītis et al., 2015, Raczko and Zagajewski, 2017) 。利用 SVM 和 RF 機器學習方法，與使用 Hyperion 和 HyMap 作為影像資料，對德國中部的森林進行五種樹種分類，結果顯示 SVM 總體分類精度為 71%，RF 為 72%(Ghosh et al., 2014) 。而使用 ANN 對波蘭地區五種樹種分類的精度約為 77%(Raczko and Zagajewski, 2017) 。國內研究，早期透過航照數位多光譜，進行林地經營管理上之應用的研究結果顯示，台灣

混淆林型的樹種複雜度高，受陽光強烈照射之樹冠明亮像元較易產生分類錯誤之情形，容易使闊葉樹樹冠區塊較易誤判為竹林類別，且因有部份區域受雲霧干擾，而產生其誤判針葉樹為闊葉樹誤授情形較高(林務局，2011)。使用 WorldView-2 高解析度多光譜影像，利用物件基礎的支持向量機分類法(OB-SVM)，以森林、農地、草地、裸地、濕地、定居地等 IPCC 六個組類的土地被覆型，總體的分類準確度高達 89%，然而，以第四次資源調查林型圖多邊形圖徵進行空間整合分析，建立的混淆林型(例如：針葉樹、闊葉樹、竹類、竹針混、竹闊混、竹針闊混、針闊混、草地、以及農地等)為導向，PB-MLC 及 OBSVM 兩種機制的分類準確度約只有 23% (林務局，2013)。後續有以 DMC 航空像片完成建立常見景觀樹種及木本農作物兩類之植物共選定 29 種，並依據樹冠形狀等逐一記述並歸納成航照判釋檢索表，但仍可能受到陽光、季節與植物的物候而影響判釋(林務局，2014)。

應用衛星或空載的遙測影像資料進行樹種辨識(identification)方法的發展隨著計算機科技、資料科學與統計技術逐漸提高辨識精確性。較早的分類以非監督式(unsupervised, Wright et al, 1980)與監督式(supervised, Settle & Briggs,1987)分類為經典的遙感影像分類技術。而後 1990 年至 2010 年，由於計算機運算的效能大幅的提升，以貝式分類器(Bayesian classifier, Saatchi and Rignot, 1997)、最大概似法分類器(Maximum Likelihood Classifiers, MLC, Warner et al., 2006)和 k-最鄰近法(k-Nearest Neighbors, KNN, Rafieyan et al., 2009)等。近年來，機器學習方法(machine learning, ML)快速的發展為遙測影像的分類提供一個新的途徑，像是決策樹(Classification and regression tree, CART, Pu and Landry, 2012)、隨機森林(Random Forest, RF, Shi et al., 2020; Kampen et al., 2019; Franklin, 2018; Michez et al., 2016; Immitzer et al., 2012)、支持向量機(Support vector machine, SVM, Sothe et al., 2019; Liao et al., 2018; Kulikova et al.,

2007)、深度學習(Deep Learning, Wagner et al., 2020; Nezami et al., 2020; Weinstein et al., 2020; Fricker et al., 2019)等方法。雖然，各種分類方法有助於提高分類的精度，但當樹種間相似性較高、森林冠層結構複雜、林分冠層連續變異度高，增加判釋到林木個體層次的難度。隨著遙測技術的發展，無人機與光達(LiDAR)資料的取得容易，整合不同類型的遙測資料進行樹種分類的一種發展趨勢(Nezami et al., 2020; Sun et al., 2019)。

使用機器學習(ML)或人工智慧(AI)進行圖像辨識，可以藉由大數據分析，和提供有效率方式增進對單一個體、樹種群落和生態系統的理解(Anderson, 2018)。但是植物的特徵在種內與種間有高度的相似性，像是顏色、紋理和光照，因此面臨許多挑戰。Nilsback and Zisserman (2010) 提出了一種視覺詞彙集的方法來描述顏色、形狀、紋理特徵和其他特徵。Zhang and Xie (2013) 應用支持向量機(Support Vector Machines, SVM)和隨機森林(Random Forest, RF) 2 種機器學習方法探索高光譜遙測影像資料(hyperspectral Data)，對於植群分類和監測的潛力。近年來，深度學習架構已經能夠在許多辨識上的問題上獲取高度的正確性(Wagner et al., 2019)。一般機器學習方法是必須透過人為先行選擇特徵，需要大量數據和研究人員標記樣本從頭開始來訓練，再通過演算法找尋物種特徵，而深度學習則可自動從數據中發現越來越高級的特徵。隨著深度學習成為影像辨識的新趨勢，Liu and Kan (2016) 結合形狀特徵與紋理特徵，使用深度信念網路架構(Deep Belief Network Architecture)作為影像辨識分類器。深度學習算法用於土地覆被分類(Arief et al., 2018; Sun et al., 2018)、景觀分類(Liu et al., 2018)、植物物種辨識(Sun et al., 2017)。深度學習為數據分析和計算機視覺提供一個新的途徑。CNN 允許對圖像紋理(即多個相鄰像素的信號)進行有效分析。CNN 具備自動學習功能，可以對紋理進行有效的分析，並確定植物群落或物種所需的決定性

的葉和冠層性狀(Wäldchen et al., 2018)。其中 Unet 是一種用於萃取的特殊類型深度學習方法，其已被證明優於所有傳統分類方法(Ronneberger et al., 2015; Huang et al., 2018)。深度學習優於傳統的機器學習方法，主要是傳統的機器學習方法必須透過手動選擇特徵並通過指令算法萃取特徵，而深度學習網路會自動從資料數據中發現越來越高級的特徵(Lecun et al., 1998)。Wagner et al. (2019)利用 WorldView-3 在 1600 km2 的區域裡，結合 U-net 對範圍內的植物種類進行辨識和分割天然樹種個體。經過多年使用深度學習植物辨識研究發展，可瞭解深度學習技術是一個新的植物辨識發展方向。

一般我們熟知的機器學習方法，係必須透過人為的專業行為來歸納與萃取特徵，如何訓練研究人員處理大批的數據將是一大考驗，接著才通過演算法找到標的物種之特徵，而在深度學習的領域中，自動萃取特徵的能力越來越強。隨著深度學習成為影像辨識的新趨勢，經過多年使用深度學習植物辨識研究發展，顯示使用深度學習方法進行林班地樹種分群與分類之可行性。Inglada 等人(2017)以高解析度時間序列影像，自動生成國家尺度的土地覆蓋圖的方法，描述了 17 種土地覆蓋類別，包括闊葉林和針葉林。Bolyn et al. (2018)利用植生指標時間序列的進行區分 11 個森林類別，獲得 89.5-93.3%的總體分類精度。Persson et al.(2018)的研究顯示使用多時期影像中的所有波段，可以獲得樹種判釋提高的整體準確度。除此之外，近年來快速發展的無人機遙測技術，其經濟性、高解析度、多光譜與高操作彈性等優點，正逐漸成為航遙測的新平台，相當具有潛力發展成輔助森林調查的新技術。

本計畫蒐整國內外森林資源調查機器學習應用案例，並彙整於附錄三，具體摘要技術發展之成果，除了作為本計畫自動化訓練模型實做之依據，亦提供業主作為後續計畫執行之參考。

二、各種判釋方法小結

自從 1960s 以後航空攝影被廣泛使用於識別樹木種類和森林類型，依據航空照片的紋理(texture)、顏色(color) 、色調(tone) 、形狀(shape) 、尺寸(size)和型態(pattern)等定性特徵，進行森林類型或樹種識別。透過人力的方式進行判釋，需要耗費大量的人力與金錢，隨著電腦的進步、各種統計方法的發展、影像種類與解析度的增加，由樹種的分類已經朝向透過電腦進行半自動或自動分類識別單株林木樹冠的方法。

對影像中的物件進行識別，首先要訓練電腦辨認特徵，大多針對影像進行特徵提取，透過像是邊緣檢測(edge detection)、角點檢測(corner detection)或閾值分割(threshold segmentation)，像是 Geometric hashing(Tsai, 1994) 、 Hough transforms(Goldenshluger and Zeevi, 2004)、Speeded Up Robust Features (SURF, Bay et al., 2006)、Features from Accelerated Segment Test (FAST, Rosten and Drummond 2006)、Scale Invariant Feature Transform (SIFT, Karami et al., 2017)等方法皆是用來探索影像特徵技術。這些特徵描述僅是找尋影像中的特徵，還需要與傳統的機器學習分類演算法(例如 K 最近鄰、隨機森林、支持向量機等)或是深度學習分類演算法(CNN、DNN、U-net 等)結合使用，才可以解決電腦視覺的問題。傳統電腦視覺方法必須選擇每一張影像中具有哪些特徵很重要，隨著要分類的種類數量增加，特徵提取變得越來越困難，使得其應用性產生瓶頸。對於影像中的判斷，必須經過漫長的反複過程，決定哪些特徵最能描述不同類別的物體，使得傳統的電腦視覺需要處理大量參數，有時這些參數必須由人為的方式進行調整，才可以獲得較佳的判釋效果。傳統的機器學習演算法與深度學習的演算法進行森林林型物件判釋的研究，大多數使用隨機森林和神經網絡方法所佔的比例較多。兩種方法有其優勢與缺點，隨機森林是由隨機資料所產生的決策樹集合，透過每個決策樹對影像資料進行判釋與輸出分類標籤。而神經網絡是透過

神經元與連接神經元的網絡進行資料的計算，若缺少神經元或之間的連結性，神經元就無法運作，通常神經元的計算法會按層分組並處理每層中的數據，逐步傳遞給下一層，並做出最終判釋的結果。

與傳統的機器學習分類算法相比，深度學習(deep learning)由於計算機的計算能力、硬體容量、影像解析度的進步得以快速發展，提供比傳統方法更高的準確性，加速了電腦視覺的應用程式普及。深度學習應用於影像處理領域，提供解決圖像分類、分割、檢測等工作。人工神經網絡(ANN)是一種受人腦功能啟發所研發的演算法，其由許多稱為神經元(neurons)計算單元組成，神經元各自執行簡單演算，並相互做出決定。利用小單元之間的相互作用，比傳統以統計參數為主分類技術更有效，特別是對於複雜的非線性數據或影像，神經網路的概念可以實現更好的容錯性和對新數據的適應性。像是卷積神經網絡(CNN)之類的深度學習方法，使用大數據和豐富的計算資源，來提高預測性能，使物體識別能力的巨大進步(Voulodimos et al., 2018)。CNN 使用權重的值矩陣(也稱為過濾器)，即透過權重的值矩陣對圖像進行空間卷積，來檢測整個影像中否存在特徵(例如邊緣)。而深度學習的 CNN 可以具有幾對卷積層和池化層，完全連接與將前一層的體積展平為特徵向量，然後將輸出層通過密集網絡計算輸出類別/特徵的得分。深度學習使用了類似學習的概念，從影像中盡可能萃取出多個特徵，並由這些特徵形成影像特徵的定義，可以想像為單詞集合，並用這些單字對影像中存在的特徵類別進行標註，形成高效率非監督地學習。深度學習透過神經網絡發現了影像類別中的基礎模式，並反覆地進行訓練(training)形成影像判釋模型，已針對每個特定類別自動萃取最具描述性和顯著性的特徵，目前較多的研究顯示 CNN 的性能遠優於傳統算法。

從回顧的文獻中，在 1990 年代，開始透過許多傳統的統計方法，像是回歸分析(regression)、線性判別分析(linear discriminant analysis, LDA)、主成分分析(principal component analysis, PCA)或廣

義線性模型（generalized linear models, GLM）等，用以建立樹種與森林類型空間分佈的預測，這些方法雖然會應為判釋的林型種類複雜性與類別數量有所不同，大致上平均的判釋約總體精度約為 0.3-0.8 之間，而近年來將機器學習應用到影像分析中的分類器，大多應用於 4 至 40 種樹種，分類準確性(Classification accuracies)約為 0.6 至 0.9，顯示應用傳統的機器學習方法與深度學習方法，有助於提升影像判釋的結果。在各個文獻中對於林型的判釋，使用到的林分特徵參數，基本包含樹冠顏色與樹冠紋理作為輸入資料，而近年來，由於航遙測的影像資料取得方便與種類多元，也逐漸加入樹冠高程模型、光譜特徵與植生指標等資料。通常無論是傳統或深度學習的分法對於單純林有較好的辨識效果，對於混淆林由於樹種的種類多元，則會產生明顯辨識上的困難性，影響辨識的結果。

雖然，深度學習方法相較於傳統方法，在影像判釋的工作更有效，但從資料輸入、編輯程式、訓練與過程與傳統方法相比，在資料輸入的部分，傳統的方法較多僅能使用資料表格資料(data frame)，像是經標籤好的森林類型屬性資料表，而神經網絡可以使用許多不同的數據類型，像是直接輸入影像矩陣。在編輯程式的部分，傳統的方法通常可以更有效地以更少的程式碼解決問題，深度學習則需要較高的程式編輯工作；在訓練模型的部分，傳統的方法對於簡單的顏色閾值和特徵計數算法，對任何圖像都執行相同的操作都可以提供通用且快速應用。深度學習則需要訓練資料集，透過神經網絡學習所設定的辨識目標特徵，如果訓練的基礎架構不好，則對於不同的圖像可能效果不佳，又在訓練過程中，傳統方法簡單且運算過程具有完全的透明度，可以從訓練的任何步驟參數結果，判斷訓練的程序是否具有成效。然而，深度學習則是透過神經元的交互作用，難以透過手動方式調整模型的參數，因為 CNN 或 DNN 內部有數百萬個參數，每個參數之間都有復雜的相互關係，因此深

度學習的模型也配批評為像是黑匣子，具有不透明的訓練過程(O'Mahony et al., 2017)。

3-2 航攝影像蒐集

本節規劃航攝影像盤點工作，將透過農航所與其「航攝影像圖資瀏覽服務平台」(圖 3-1)進行影像種類、規格與編碼之釐清，確認適用於本計畫機器學習訓練樣本資料之特性，最後再基於現地調查資料之需求確認對應的圖幅影像檔案。以下針對農航所現有航攝圖資進行盤點：

一、航空照片類

航空照片係由航攝飛機攜帶精密「空中照相機」自空中往下拍照，將地面上地物、地貌做永久真實記錄。航空照片是中心投影，無固定比例尺，因此不能當地圖使用。2001 年之前為黑白航空照片，2001 年起則陸續改為彩色航空照片，依照片產品分為三類。第一為航空照片影像檔，利用蔡司高精密影像掃描儀，將類比航照底片掃描建置成高解析(14μ)之影像檔，及以數位攝影機拍照的 ADS 與 DMC 影像數值資料檔。第二為原始航空照片，利用航空照片影像檔，輸出黑白航空照片、彩色航空照片(圖 3-2)，照片尺寸為 30cm×30cm 與 16cm×30cm。最後是局部放大的航空照片，依所需地點及年份查詢，選擇合適之航空照片影像檔，使用繪圖軟體局部裁切後，輸出放大之影像，照片尺寸為 30cm×30cm 與 50cm×50cm。

二、像片基本圖類

係以中心投影像片，用微分糾正方法，改正移位及比例尺之誤差，糾正成正射投影像片，並於上加繪等高線及地物與註記說明(如圖號、圖名、版次及固定比例尺，圖面上有等高線、河流、

街道、文字註記、圖例及坐標等)，成為像片圖，以像片圖作為基本圖者稱為像片基本圖。目前農航所唯一供應的是林區像片基本圖，該圖為國有林地林業經營改革方案下，實施林業經營計畫檢訂調查工作所測製之像片基本圖，比例尺為 1/5000。

三、正射影像類

為能迅速將航攝影像提供應用，2001 年 9 月起以藉由空中 GPS 儀器搭載 IMU 系統資料，經解算獲取相機拍攝瞬間的位置及姿態與數值航照影像，搭配數值地形模型(DEM)將中心投影之航空像片，逐點糾正成正射投影，並加註說明(如圖號、圖名、坐標及固定比例尺)製成正射影像，其可供應之產品包含正射影像圖與正射影像檔。前者，利用數位正射影像資料檔以精密繪圖儀輸出，圖資尺寸為 60cm×75cm，比例尺為 1/5000。後者，將中心投影之航空像片，利用數值航測影像工作站、數值立體測繪系統，逐點糾正成正射投影，消除像片上的投影誤差，所製作之數位正射影像資料檔，比例尺為 1/5000，檔案格式為 tif 影像、tfw 坐標檔頭資料、dxf 圖框註記，地面解析度為 25cm、37.5cm 或 50cm。

除上述內容亦綜整影像圖資產品規格如表 3-1。本計畫除了配合現地資料的選定，尚考慮數位航攝的高品質、近紅外光波段(NIR)涵蓋之周全、圖幅高地面解析度與未來航攝任務之延續，規劃優先使用 2007 年之後的 DMC 數位航空照片，記錄規格如表 3-2。

目前根據林型圖範圍分布之位置，由貴所協助檢索取得 718 幅當時用於樹種人工判釋之航空照片，做為本計畫主要的訓練樣本資料庫，資料容量大約 750 GB。影像年份介於 2007 年至 2014 年之間。除了航空照片原始影像，亦涵蓋各影像拍攝時使用的方位參數，包含相機拍攝時之位置(TWD97_E、TWD97_N 、TWD97_H)與姿態角(ω、φ、κ)，以做為正確重建拍攝角度姿態之參數，所有航空

照片分布位置如圖 3-3 所示。另外，為了解航空照片時空屬性，統計拍攝月分(圖 3-4)與拍攝年份(圖 3-5)，已提升訓練資料特性之掌握。

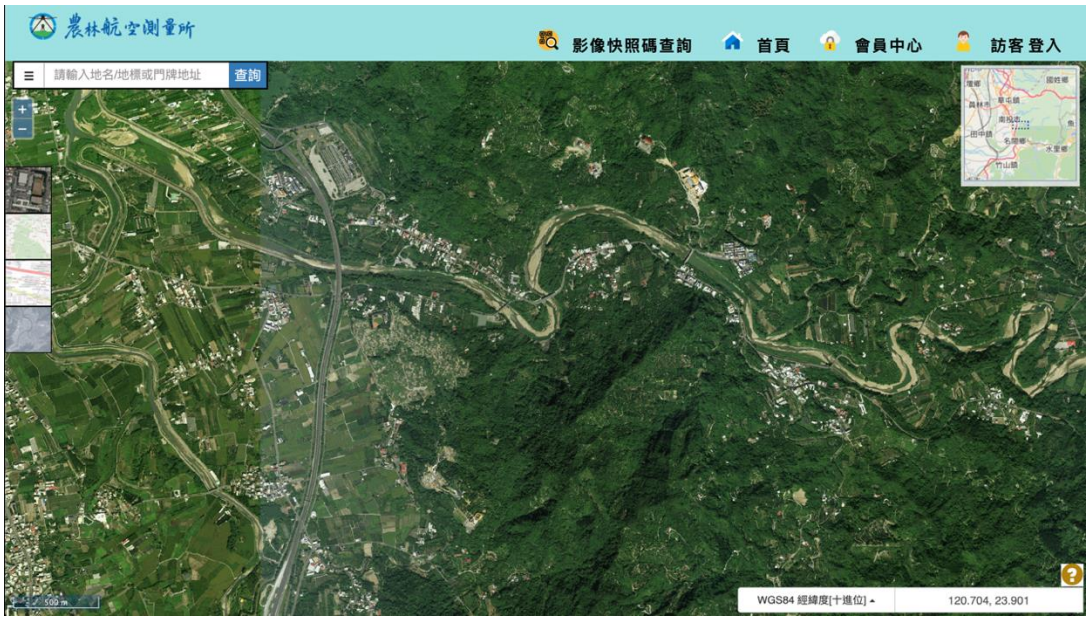

(資料來源：農林航空測量所官網)

圖 3-1 航攝影像圖資瀏覽服務平台

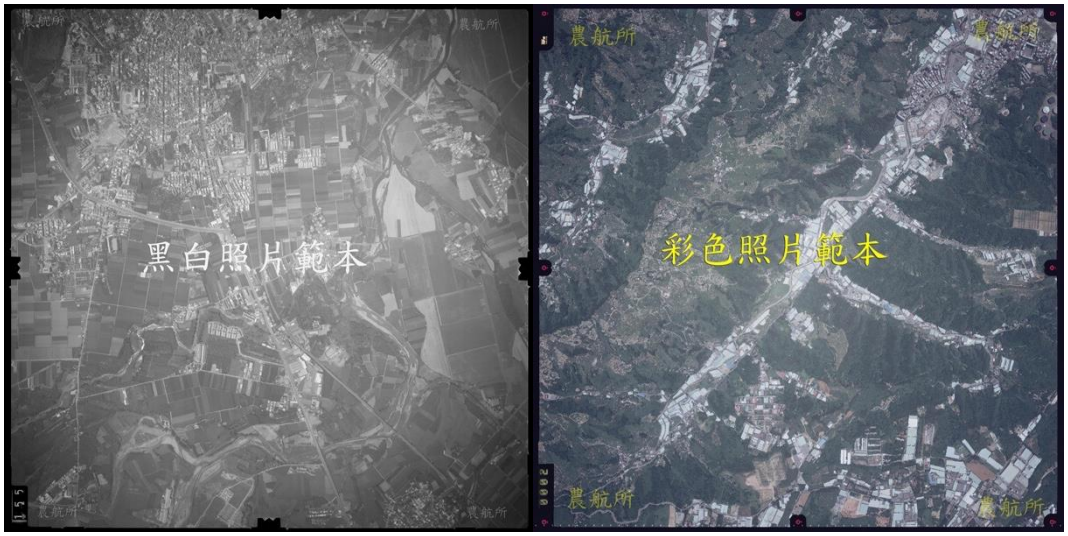

(資料來源：農林航空測量所官網)

圖 3-2 航空照片範本

表 3-1 農林航空測量所航攝影像圖資規格

圖資總類		規格	比例尺	備註
航空照片	彩色/黑白、DMC 數位航空照片(未放大)	相紙，30×30cm、16×30cm	無固定比例尺	1973~2001 年間為黑白照片 2001 年以後為彩色照片 2008 年以前為傳統底片掃描影像 2008 年以後陸續改為數位影像(含 NIR)
	彩色/黑白、DMC 數位航空照片(局部放大 10 倍)	相紙，30×30cm、50×50cm		
	黑白照片掃描影像檔	光碟片，14μm，tif 格式		
	彩色照片掃描影像檔	光碟片，14μm，tif 格式		
	DMC 數位影像檔	光碟片，13824×7680pix，tif 格式		
	ADS 數位影像檔	光碟片，以 1/5000 基本圖幅計，tif 格式		
像片基本圖	林區像片基本圖	紙圖，60cm×76cm	1/5000	含林班、小班編號、林相、林齡級、材積級、等高線、河流、道路、重要地標等標註
	金門衛星影像圖		1/5000	全屬機密級
正射影像	正射影像圖	紙圖，60cm×76cm	1/5000	含圖框坐標，無其他標註
	正射影像檔	光碟片，地面解析度 25、37.5、50cm，(含 tif 影像、tfw 坐標檔及 dxf 圖框註記檔)		

(資料來源：農林航空測量所官網)

表 3-2 DMC 航空攝影紀錄檔格式說明

欄	欄名	範例	備註
1	NAME	070510	拍攝日期
		b	航高代號
		21	航線
		0001	影像編號
		a	品質(a 佳、b 有碎雲或霾氣)
2	E	201250.207	X 坐標 TWD97
3	N	2666169.734	Y 坐標 TWD97
4	H	2568.975	橢球高 TWD97
5	E	200421.79	X 坐標 TWD67
6	N	2666375.375	Y 坐標 TWD67
7	H	2550.117	正高 TWD67
8	LN	21	航線
9	DATE	960510	日期
10	TIME	1130	曝光時間[時、分]
11	SEC	20.772	秒
12	MAPID	95213061	基本圖圖號(有圖號表示該照片落於對應圖號中心點 300 公尺)
13	SC	4	相機代號(4 表示使用 DMC 數位航空攝影機)
14	RI	1	航攝目的(1 台灣全區航攝、2 多光譜掃描、3 水稻、4 其他、5 災害)
15	MP	y	可否製圖(y 適合 1/5000 製圖、n 不適合)
16	DP	36	航向(36 北向、18 南向、其他)
17		DMC	解算程式

(資料來源：森林資源調查暨國有林事業區檢訂土地覆蓋型及航照樣點圖資更新作業手冊)

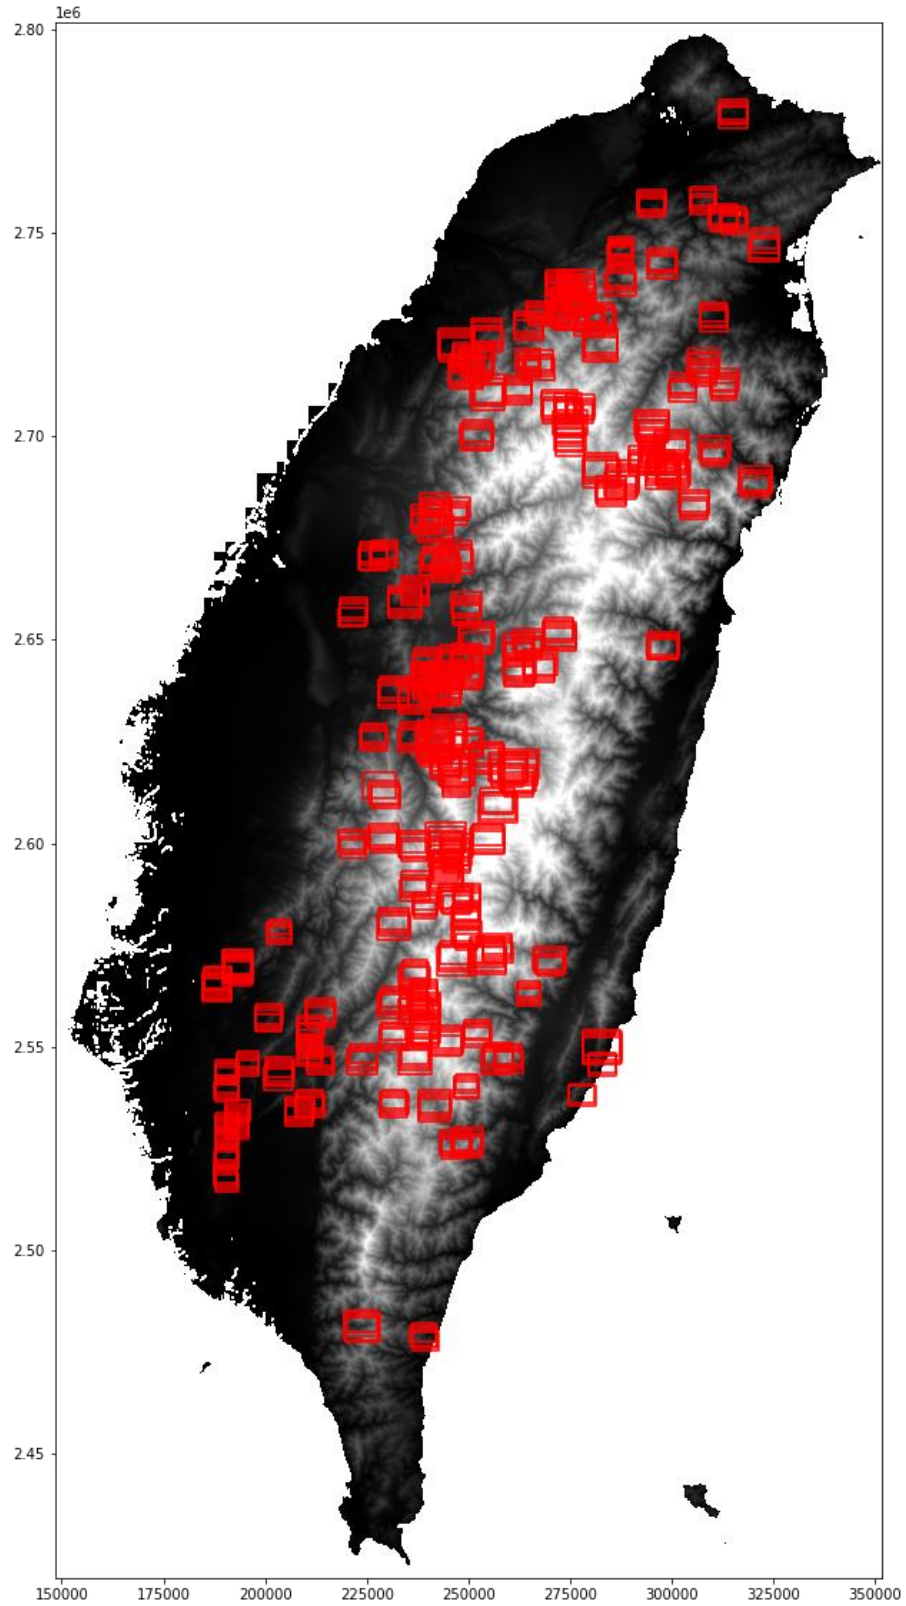

圖 3-3 本計畫使用之航攝影像位置分布

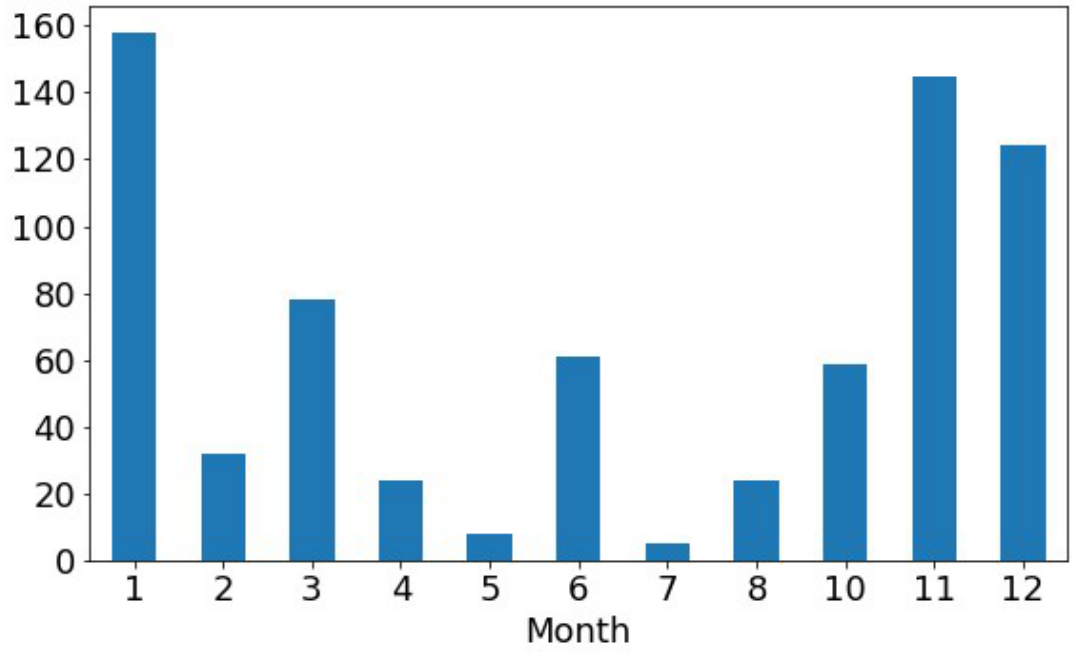

圖 3-4 本計畫使用之航攝影像各月統計

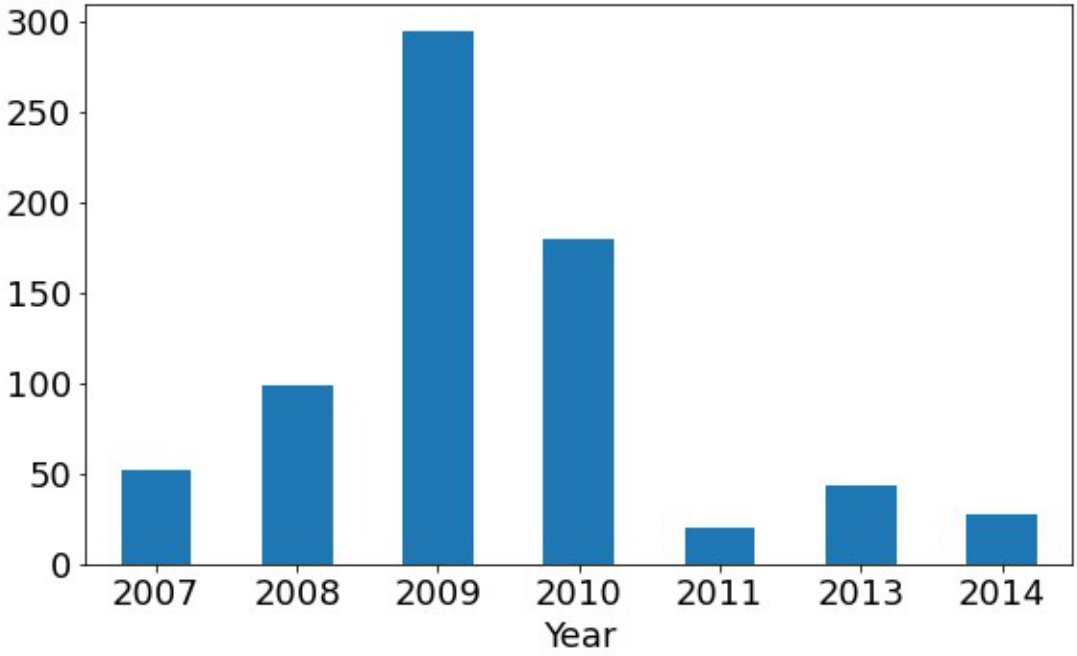

圖 3-5 本計畫使用之航攝影像各年統計

3-3 現地資料蒐集

森林資源調查為提供森林資源經營之資訊來源，亦為森林經營決策之依據。近年來由於森林資源在經濟面、社會面、資源面及國際面所扮演的角色有所轉變，因此以往的各項森林資源調查，是否能提供各層面之資訊需求，實有探討之必要。森林資源調查除一般學術單位或研究機關，依其需求進行森林資源資料之收集、分析、研究之外，林務局亦為業務推動建立更具系統性之調查計畫，辦理不同尺度的調查，當中最為嚴謹重要的延續型調查有三，「國有林事業區檢訂調查」、「永久樣區調查」以及「全國性森林資源調查」。三項計畫豐富的現地調查資料，即是機器學習模型訓練之重要學習依據，配合相應的航攝影像資料，選定適切的現地調查成果將提升本計畫分析分類之成效，以下針對這些調查計畫逐一說明之。

一、國有林事業區檢訂調查

為收集、查核、更正事業區各種相關經營資料，並編訂撰寫各林區森林生態系經營等計畫，國有林事業區檢訂工作對於林業經營尤其重要。透過檢訂調查了解土況與林況，已達蓄積量評估之依據。臺灣國有林事業區經營計畫發展甚早，最早可追朔自日據時代(約 1926 年)即開始編訂，並持續辦理檢訂更新，原則以每 5 至 10 年檢討一次，歷經多次的政權變化逐漸建立其調查項目(表 3-3)與調查流程(圖 3-6)。

由工作流程悉知，目前檢訂調查工作主要係利用航空照片及像片基本圖協助進行林況地況調查，並將其調查結果儲存於林班基本圖與森林調查簿資料庫。然而，在過去雖有良好的規劃立意，但實務上常因調查技術、人力與經費所限制。鑒於 2008 年展

開的第四次全國性森林資源調查任務，國有林事業區檢訂調查也即告暫停。

表 3-3 國有林事業區檢訂調查項目

調查類型與綱要規定	調查項目	紀錄細項
地況調查 經營計畫綱要規定：「地況調查應就其位置、氣象、水文、地勢、地質、土壤、沖刷、地位、地利及土地利用情況調查蒐集之。」	林地位置記述	管理所別、縣市、鄉鎮、集水區、林區、事業區、工作站、林班、小班。
	土地記述	作業級、調查方法、交通狀況、方位、標高、地位、傾斜度、土壤性質、土壤深度、土壤結合度、土壤濕度、地表植物、森林副產品、更新幼苗。
林況調查 經營計畫綱要規定：「林況調查應以小班為單位，按現有林相、樹種、林齡、作業法、蓄積量、林木生長及枯損量、立木度、鬱閉度、立木之利用區分、副產物、地表植物等調查蒐集之。」	林地狀況	小斑面積、地種、林相、造林性質、造林年度、林齡、鬱閉度。
	立木資料	樹種、公頃株數、公頃材積、混淆率、特定地點、其餘新增副檔

(資料來源：行政院農業委員會林務局國有林檢訂調查制度之探討)

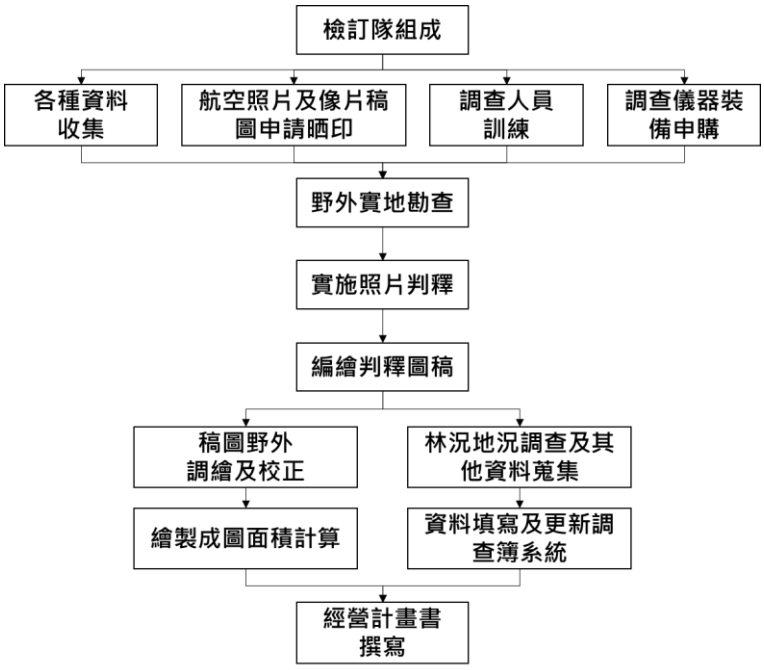

(資料來源：改繪至行政院農業委員會林務局國有林檢訂調查制度之探討)

圖 3-6 檢訂調查工作流程

二、永久樣區調查

為達到有效掌握林分時間及空間之動態演變之目標，林務局設置永久樣區，進行長期監測以觀測林分生長，森林組成、結構、蓄積等動態變化和對不同林分處理反應之狀況，實為建立有效林分經營體系中不可或缺的一環。而所謂永久樣區(Permanent Sampling Plot，PSP)係指一個取樣單位在設置及記錄之後，可持續於下一次的調查工作中，在相同位置進行重覆測量，以了解不同時間狀態之變化，引用國立中興大學森林調查測計與空間資訊研究室馮豐隆教授於森林測計學課程之永久樣區設立流程如圖 3-7。因林業之經營屬於長期性之工作，在時間推移的過程中，林分的變化過程，是林業經營者最希望能夠掌握的資訊，這也顯示設立永久樣區的嚴謹性與必要性，其樣區分布如圖 3-8。

林務局於 87-91 年依序初設森林永久樣區，並規劃每 5 年複查 1 次。調查重點為林木或林型的定期生長量。透過提供健全的現地

調查資訊，以協助主管機關建立完善的森林監測系統。在永久樣區係與全國森林資源調查之系統樣區進行整合並定期辦理複查。探究其調查立意，永久樣區調查與檢訂調查均係為了充分掌握森林資源與林木蓄積，所進行的大規模野外巡查，調查項目繁多，且忠實記錄了樣區內所有動植物生態情況，唯缺乏完整的空間關係與概況描述，在對應本計畫之森林覆蓋型在空間分類之需求上，尚有諸多不易比對之困難點，故目前主要拿來檢驗模型之分類成果與標記資料的準確性，無法立即在本年度計畫進行分類模型時成為學習標的。因此，接續盤整全國第四次全國森林資源調查成果，以確認可用的現地調查資料。

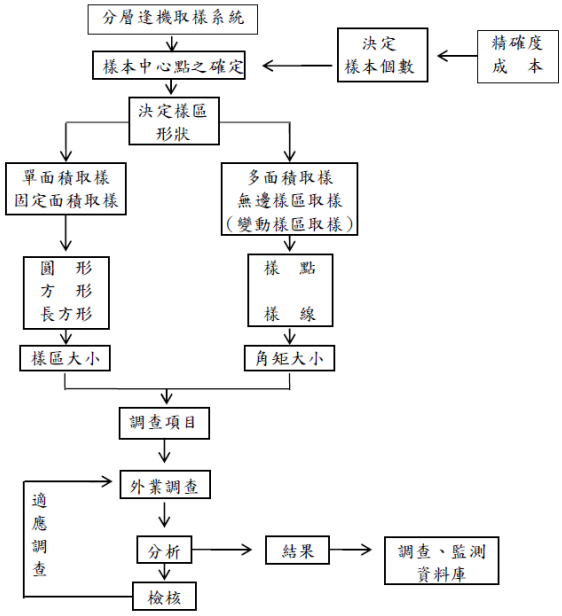

圖 3-7 永久樣區設立流程圖(馮豐隆，2005)

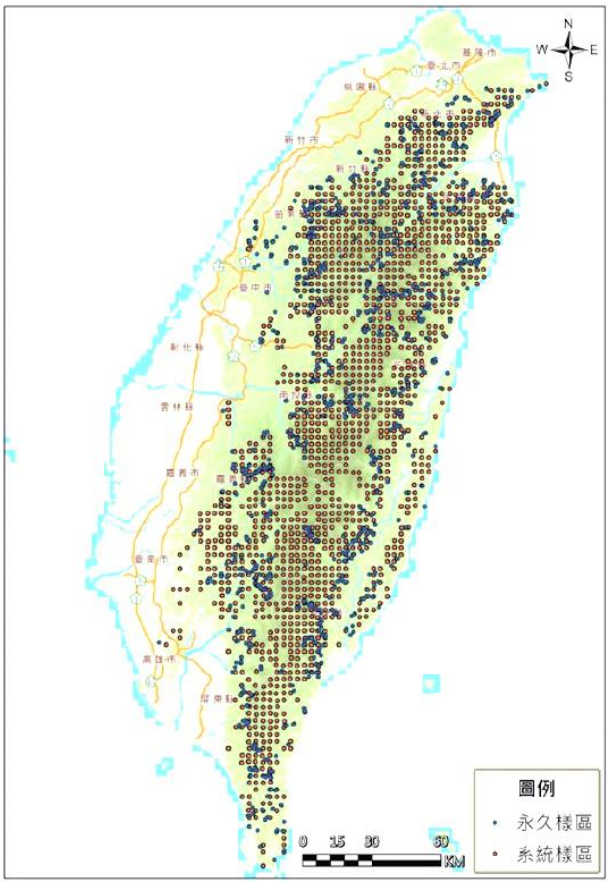

(資料來源：行政院農業委員會林務局第四次全國森林資源調查報告)

圖 3-8 森林永久樣區分布圖

三、全國性森林資源調查

森林是臺灣的命脈，占有全島土地面積近 6 成的比例，分布如圖 3-9，統計如表 3-4，除林木本身的經濟價值外，對於國土保安、水源涵養、育樂遊憩以及生物多樣性的維護，均扮演重要角色。承襲至 2005 年的「京都議定書」與 2012 年的「哥本哈根協訂」，國內「溫室氣體減量及管理法」已於 2015 年 7 月 1 日公告施行，依據該法第八條規定政府機關權責，林業部門應推動森林資源管理、生物多樣性保育及碳吸收功能強化；而第十三條則規定，中央目的事業主管機關應進行排放量之調查、統計，並定期提報中央主管機關，換言之，林業主管機關應定期進行森林碳匯量調查與統計，並提報中央主管機關。因此，自 1954 年以來，林

業相關單位就開始於各個階段執行了不同目的的森林資源調查計畫，以平均15年至20年的更新頻率，至今已完成了四次的全國性森林資源調查。四次的調查均採用航空照片配合地面樣區取樣調查，以獲取森林資源的資訊，唯因應各次調查的目的與方法設計略有差異，比較表詳如表3-5。自2008年林務局啟動第四次全國森林資源調查工作，此次調查主要依循三項原則執行。

(一)航攝影像之選定

航遙測影像在世界各國森林調查工作中均扮演重要的角色，但依據國土大小，適用載具影像也有所差異。衛星遙測能發揮在短期內擷取大範圍區域內地表的變動資訊的功能，適合幅員廣大的國家，如美國、日本、中國...等。然而臺灣幅員狹小、地形陡峭且森林組成複雜，衛星遙測的應用與解析尚有其限制，因此第四次森林資源調查仍以航攝影像為基礎。

(二)樣點的一致性選取

儘管取樣密度依據各國林型分布與地形條件有所不同，但「系統取樣」與「連續複查」幾乎已成為各國一致採行的標準作業方式，國內過去第二、三次森林資源調查即已採用系統取樣方式，但因當時取樣設計的差異，樣點分布位置不同，使其成果僅能反應各次調查當時整體森林資源的現況，無法進一步掌握不同林型之生長枯死等資訊。因此，在第四調查在取樣位置與調查規劃上，儘可能與第三次調查取得一致，以利於相互比較與後續應用。

(三)調查成果更新維運原則

參考國際上重要國家的森林資源管理可見，現行森林資源調查資訊均配合複查頻率每5年即發布乙次，此外聯合國糧農組織自 1990 年起，每 5 年定期發布全球森林資源狀況評估報告，相較之下，我國歷次全國森林資源調查間隔將近 20 年，更新頻率已無法滿足現代資訊需求，亦無法與國際接軌，因此本次資

源調查的同時，亦應思考所得成果的更新與維護機制，適時對外公布，以滿足外界對於森林資訊的需求。

依循上述原則，第四次全國森林資源調查工作項目包含林地清查、森林林型圖繪製(表 3-6、圖 3-10)、土地利用型圖繪製、森林蓄積調查(地面樣區調查、航照樣點判釋)、林地以外之森林覆蓋調查，以及野生動物調查等。

在綜整本計畫研究之目的，考量樣區調查比對上的困難，優先採用第四次全國性森林資源調查森林林型圖作為主要的現地資料，因此在接續章節將針對林型圖的產製進行細部說明。

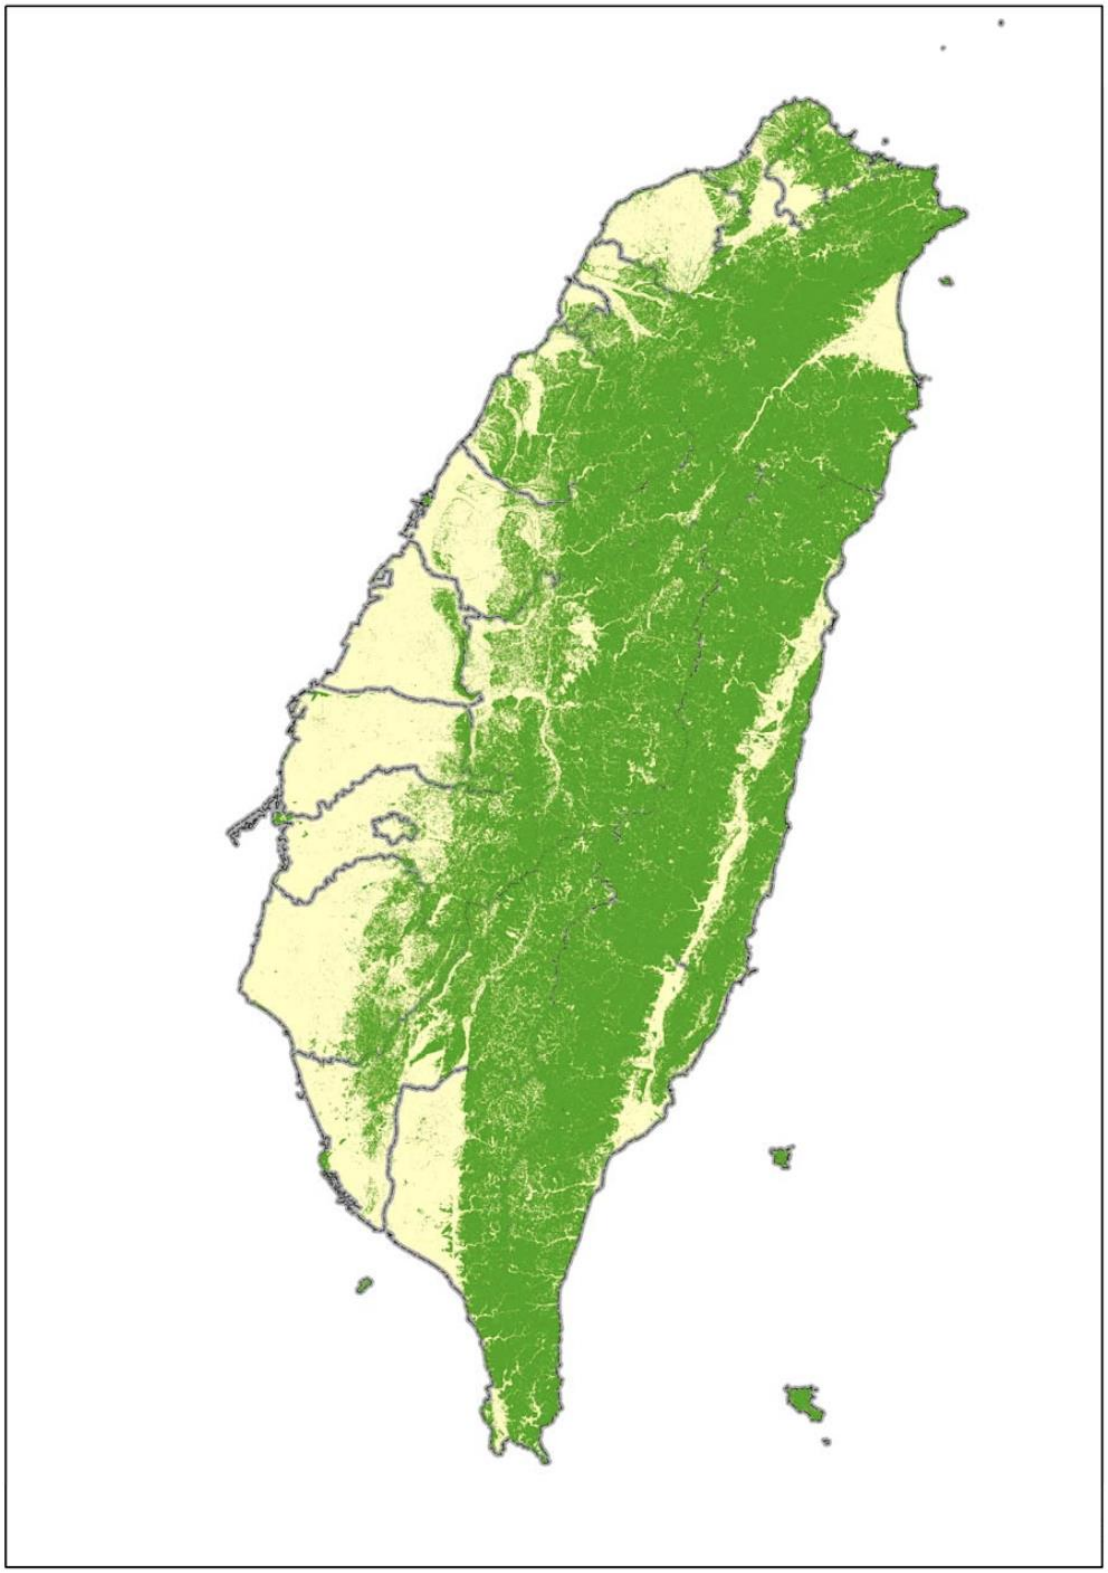

(資料來源：行政院農業委員會林務局第四次森林資源調查報告)

圖 3-9 全島各縣市森林覆蓋範圍圖

表 3-4 臺灣地區森林覆蓋面積

區位	總面積(公頃)	森林覆蓋面積(公頃)	覆蓋率
林地	1,993,205	1,781,660	89.38%
其他土地	1,625,791	415,430	25.24%
合計	3,618,996	2,197,090	60.71%

(資料來源：行政院農業委員會林務局第四次森林資源調查報告)

表 3-5 全國性森林資源調查比較表

項目/次別	第一次	第二次	第三次	第四次
調查時間	1954~1956	1972~1977	1990~1993	2008~2010
主辦單位	農復會	林務局	林務局	林務局
拍攝航向	東西向	南北向	南北向	南北向
涵蓋範圍	未覆蓋全臺	覆蓋全臺	覆蓋全臺	覆蓋全臺
照片樣點	37,945 點	134,046 點	286,925 點	191,240 點
地面樣區	545 個	4,132 個	3,996 個	3,648 個
取樣方法	雙重分層取樣	雙重分層取樣	分層取樣	航照樣點雙重取樣
樣區狀態	五層同心圓	樣線變動面積	固定矩形	固定矩形
樣區決定	以 Neyman 公式計算地面樣區，依最適分配決定	系統取樣後再逢機取樣	系統取樣	系統取樣
調查方法	同心圓樣區調查	水平樣線調查	水平樣線調查	水平樣線調查

(資料來源：從京都議定書看台灣的森林資源調查)

表 3-6 林型面積占比

林型	總面積(公頃)	覆蓋率
闊葉樹林型	1,469,898	67%
針葉樹林型	299,216	14%
針闊葉樹混淆林	171,346	8%
竹林	112,549	5%
竹木混淆林	114,900	5%
待成林地	29,181	1%
合計	2,197,090	100%

(資料來源：行政院農業委員會林務局第四次森林資源調查報告)

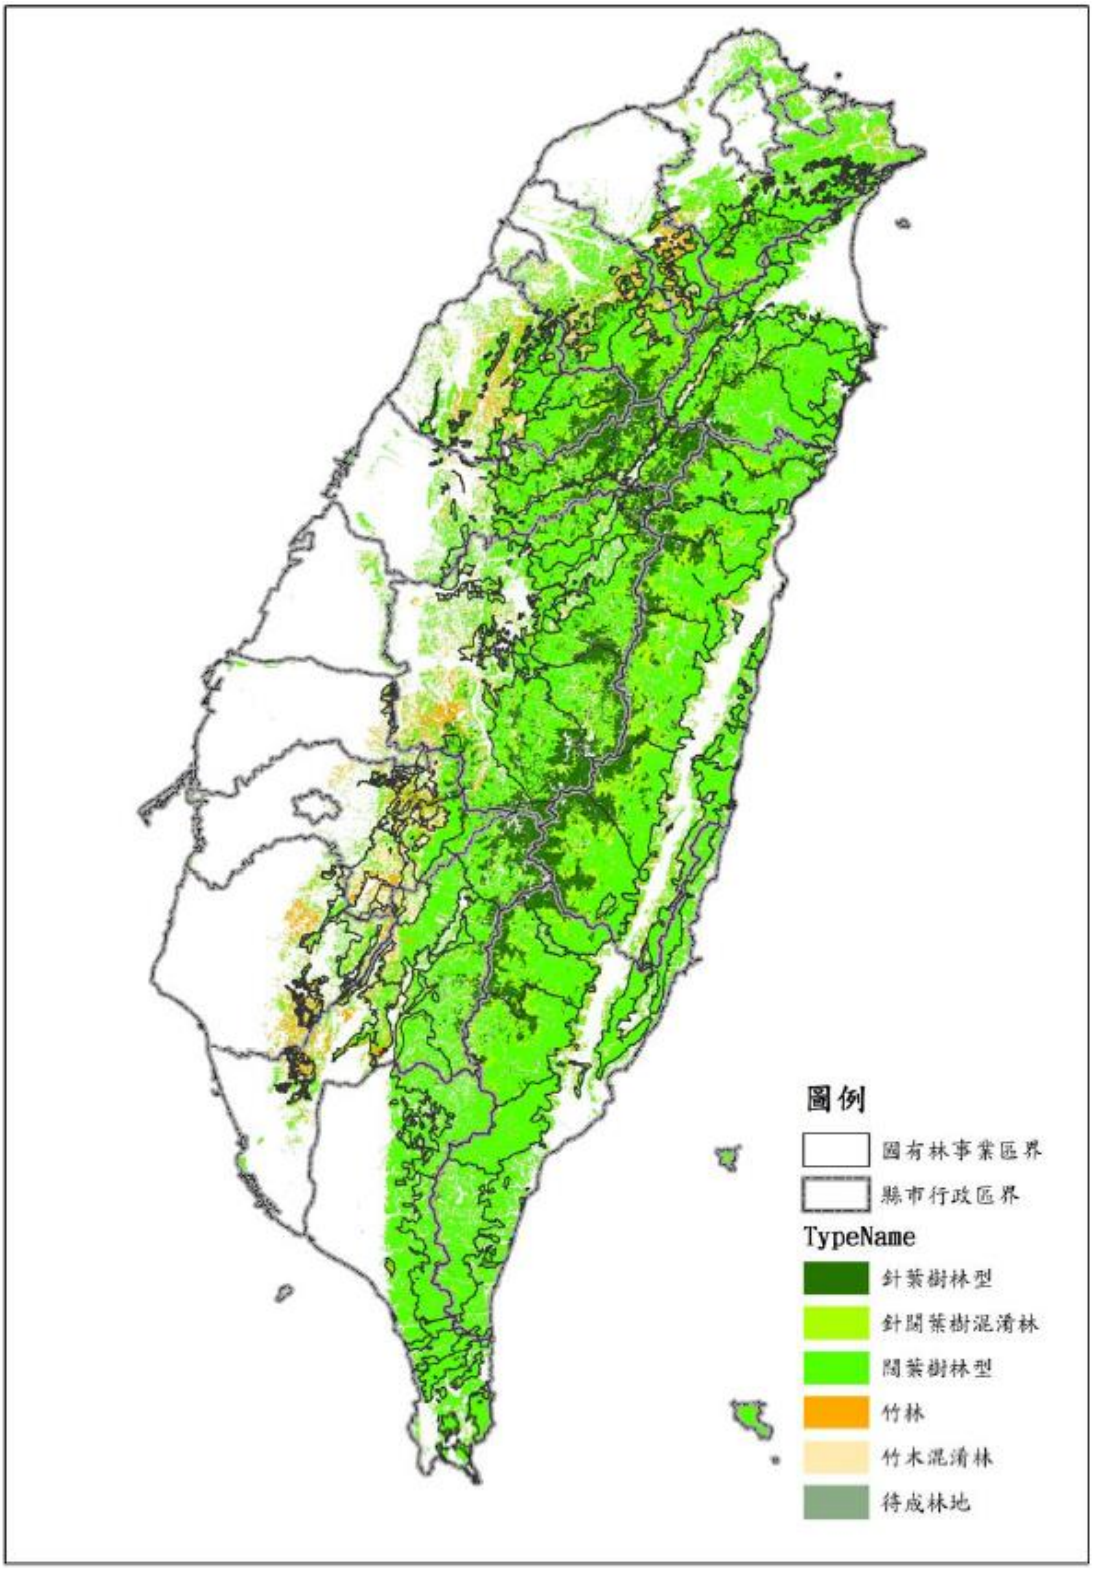

(資料來源：行政院農業委員會林務局第四次森林資源調查報告)

圖 3-10 森林林型分布圖

四、第四次全國性森林資源調查林型圖

此次森林林型圖編修與產製，係基於農航所空載數值航照相機或掃描儀所拍攝之航空照片(地面解析度達 25 公分)，以人工的方式進行判釋與分類，配合相關圖資進行數化。整個林型判釋與數化之工作係由林務局所屬 8 個林區管理處同步進行，為減少人為判釋造成的成果差異，設計集中式的空間資料庫進行成果管理，並以固定的圖幅單元(約 7,000 公頃)分配執行判釋作業。待林管處完成專案判釋後，再經由農航所進行檢核，始能上傳至資料庫。

現行林型分類係採二層級分類作法，除了考量與國際接軌外，亦能與內政部分類系統相互對應，以利成果整合及相互流通。第一層分類參考聯合國間氣候變遷特別委員會(IPCC)所訂定之溫室氣體調查指南（IPCC 2006 Guidlines）中「農業、森林與其他土地利用」(Agriculture, Forestry and Other Land Use，AFOLU)，將土地使用分成「森林」、「農田」、「定居地」、「草原」、「濕地」、「其他土地」等六大類別；第二層分類則是依據森林經營管理需要再予以細分，其中森林依其針葉樹種、闊葉樹種、竹類組成比例，分成針葉樹林型、針闊葉樹混淆林、闊葉樹林型、竹林、竹闊混淆林、竹針混淆林、竹針闊混淆林等林型，另由於聯合國農糧組織(FAO)對於原生育地之林木成熟後能達到所定義閾值之土地亦視為森林，因此對於林地中之廢耕地、伐木跡地、森林火災跡地等，如有稚樹天然更新或新植造林地，仍可歸為森林類別，歸類為「待成林地」，林型判釋後，必須再判釋註記主要組成樹種，並以二種為限。表 3-7 列出本次森林資源調查林型及土地利用行之類別，及與第三次森林資源調查和內政部國土利用調查分類系統之對照表。

根據第四次森林資源調查報告中，森林林型圖資第一層分類中「林地 FL」子類別包含「01 針葉樹林型」、「02 闊葉樹林型」、「03 針闊葉樹混淆林」、「04 竹林」、「05 竹闊混淆

林」、「06 竹針混淆林」、「07 竹針闊混淆林」與「08 待成林地」，共計8項。考量現行已可利用衛星影像判釋林型圖資之第二層分類已有較佳之成果，因此本計畫優先著重於特定樹種的辨識，在與貴所確認後選定 11 種樹種進行模型訓練，分別包含檜木(紅檜、扁柏)、松樹(二葉松、五葉松等)、杉木(巒大杉、杉木等)、台灣杉、柳杉、鐵杉、冷杉，屬於「01 針葉樹林型」；相思樹與台灣赤楊屬於「02 闊葉樹林型」；而叢生狀竹與單趕狀竹則為「04 竹林」。

本計畫自農航所取得第四次全國森林資源調查林型圖資，除了林型分類的幾何圖形，亦包含相關之屬性，欄位彙整如表 3-8 所示，其中屬性表內提供與林型相關之欄位包含 IPCC 名稱(即第一層分類)、差異形態名稱(即第二層分類)、主要樹種及次要樹種，以利資料前處理時，可有效取得各樹種分類範圍。

有別於其他科學領域，森林資源調查之現地資料在臺灣實為珍貴且稀有，一次次的大規模野外調查，從規劃到實測，再到分析，消耗的人力與時間成本都相當可觀，更遑論臺灣地形變化起伏大、物候條件複雜、生物多樣性高。然而，正因為如此正確，掌握現地資料十分重要，而良善的資料品管亦是建立機器學習方法之核心任務。本計畫探究上述相關森林資源調查報告，並彙整林務局與農航所之現地資料，依資料品質與適用性進行盤點與更新，建立具高度適用性的自動化森林覆蓋分類模型。

表 3-7 第四次森林資源調查林型分類對照表

第一層分類 (IPCC name)	第二層分類 (type name)	內政部國土 利用調查	第三次森林 資源調查
林地 FL	01 針葉樹林型 02 闊葉樹林型 03 針闊葉樹混淆林 04 竹林 05 竹闊混淆林 06 竹針混淆林 07 竹針闊混淆林 08 待成林地	02 森林使用土地	011 冷杉天針 ~ 190 人竹闊針混等 44 個林型類別 650 伐木跡地
農田 CL	21 稻作 22 茶園 23 果樹 24 檳榔 25 其他農作地	01 農業使用土地	620 茶園 ~ 640 其他墾地等 13 個類別 730 水田 760 土場
草地 GL	31 灌木林 32 天然草生地 33 箭竹地 31 牧草地	09 其他使用土地 (草生地 0903)	600 灌木林 611 天然草生地 612 箭竹地 613 牧草地 740 防火線
濕地 WL	41 人工濕地(漁塭、水庫、水池) 42 天然濕地(河床、溪流、湖泊) 43 紅樹林	09 其他使用土地 (濕地 0902) 04 水利使用土地	790 漁塭、水庫、水池 930 河床、溪流、池沼水面
定居地 SL	51 道路 52 墓地 53 工礦開採區 54 農(林)業附帶設施 55 其他建物	03 交通使用土地 05 建築使用土地 06 公共使用土地 07 遊憩使用土地 08 礦鹽使用土地 09 其他使用土地	700 道路 710 建築用地 770 墓地 750 工礦用地 780 鹽田
其他土地 OL	61 裸露地 62 其他(雲層遮蔽、陰影)	09 其他使用土地 (裸露地 0904)	900 裸露地

(資料來源：行政院農業委員會林務局第四次森林資源調查報告)

表 3-8 第四次森林資源調查林型圖資屬性表

欄位名稱	範例	欄位名稱	範例
航測 Block 編碼	95192038	VerifyDeptName	農航所
圖框編碼	95192038	DTIME	2010/10/12 上午 08:20:27
主要樹種百分比	50	FID_CountyUnion3D	993
次要樹種百分比	50	FID_縣市界	6
IPCC 名稱	林地	OBJECTID	6
差異形態名稱	針葉樹林型	C_CODE	10014
功能性分類代碼	1200	C_NAME	台東縣
主要樹種	鐵杉	Shape_Leng	573570.708871
次要樹種	松樹（二葉松、五葉松等）	FID_國有林林班界圖編製成果	3395
使用者代碼	138	WKNG	26
IPCC 分類代碼	1	CMPT	29
數化立體像對	090318h_38~0166_rgb.sup/090318h_38~0167_rgb.sup	DIST_C	台東處
數化單位名稱	農航所	WKNG_C	關山
數化人員名稱	陳 OO	DIST	07
數化單位代碼	09	AREA	10743348.8536
是相鄰專案共邊圖徵	-1	小班	<Null>
VerifyPass	1	林地分區	<Null>
VerifyUserID	137	鬱閉度	<Null>
VerifyUserName	傅 OO	公頃材積	<Null>
VerifyDeptID	09	SHAPE_Length	61.265159
		SHAPE_Area	32.916252

3-4 其他與研究相關之資料蒐集

針對其他相關資料之蒐集，根據文獻蒐整以及貴所諮詢結果，本計畫著重於可提升訓練成效之參數進行說明，包含數值地形模型(DTM)與正規化差異植生指數(NDVI)，期透過數值地形的修正，與近紅外光波段的融合，有效提升航空照片訓練之準確性。

一、數值地形模型

數值地形模型(Digital Terrain Model，DTM)，一般可解釋為用數值坐標表示的地形模型，亦即用三度空間 X、Y、Z 坐標值來表示的地表位置和高程的一種模式稱為數值地形模型，簡稱數值地形。DTM 最早由美國麻省理工學院提出，發展至今應用範圍甚廣，如防救災、建築景觀設計、水文分析、國土利用、地形分析等，都可以藉此得到更好的資訊萃取與數據分析。

通常是從像片立體模型上，依規則網格及特徵點分布方式，逐點量測地表各點之高程及位置，製成數值地形檔。按分析之需求，可從數值地形檔轉繪為其他地理資訊，例如等高線、地形圖、主題圖、坡度圖、面積、體積、地形起伏分析圖等。亦可將數值地形資料直接供像片正射糾正時，作為影像之高程控制。模型高程點之間隔愈小，則所測得之數值地形愈精確，惟測量費用及時間亦必相對增加。除此之外，依據資料萃取的差異可再分為數值高程模型(Digital Elevation Model，DEM)與數值表面模型(Digital Surface Model，DSM)。DSM 除了紀錄地形高程資訊，也連帶保留了地表以上的物件高程資訊，這個物件可能是植被樹林或人造結構物等，DSM 與 DTM 之差異呈現如圖 3-11；DEM 與 DTM 均表示為地形的高程資訊，而根據林木的物候特性，地形高程資訊可能反應物種的差異，因此需透過現地調查之坐標，萃取 DTM 高程資訊。本計畫在貴所協助下優先取得 5 公尺 DEM 進行測試，但受限於資料管理之限制，僅能取得地形因子，無法取得原始高程，加上細看時有明顯之機關浮水印，考慮到影響地形因子參數之萃取(圖 3-12)，難以將正確的參數應用於訓練過程。因此，內政部開放資料「20 公尺網格數值地形模型資料」(如圖 3-13 呈現)，將做為本計畫航空照片對位之依據，同時也透過該資料產致地形因子並於接續章節說明之。

二、地形因子萃取

延續數值地形模型之導入構想，亦可由 DEM 模型資料萃取重要的地形因子，來強化地形特徵於森林物種之關聯性。本計畫研擬五項地形參數，包含坡度(Slope)、坡向(Aspect)、粗糙度(Roughness)、地形位置指數(Topographic Position Index，TPI)，與地形堅固指數 (Terrain Ruggedness Index，TRI)。以下針對各項因子之定義，提出說明。

1. **坡度**：坡度分析即是計算兩相鄰像元間的數值變異率，亦即地表的陡緩程度，在輸出圖層中，每個像元都有一個坡度值。因此，數值越低者，表示地形越平坦；數值越高者，表示地勢越陡峻。
2. **坡向**：坡向反應斜坡的方向。以 DEM 計算坡向時，通常定義坡向為過網格單元所產生的曲面上，某點切平面的法線的正方向在平面上與正北方之夾角，即法向量水平投影量的方位角。坡向的值介於 0 至 360 度。
3. **粗糙度**：粗糙度為地形的變異程度，主要利用數值統計的方法來表示地表平坦、地形高差變化的參數，是反映地表起伏變化和侵蝕程度的量化指標，包含有地形高程標準差、坡度標準差、坡度和坡向的變異數等。
4. **地形位置指數(TPI)**：是一種用於區分地形特徵的數值指標，包含峽谷、平地或斜坡，可透過計算中心網格與周為網格高程差之平均計算之。參考方程式如式 3-1，其中 e 表示為中心網格高程值。

$$\mathrm{TPI} = e - \sum_{i=1}^{8} e_i/8$$

式 3-1

5. **地形堅固指數(TRI)**：是一種用於表達數值高程網格相鄰單元之間的高程差量。透過計算中心網格與周圍八個網格個別的高程差，並針對差值進行平方取平均。參考方程式如式 3-2，其中 e 表示為中心網格高程值。

$$\mathrm{TRI} = \sum_{i=1}^{8} |e - e_i| / 8$$

式 3-2

三、常態化差值植生指標

常態化差值植生指標(Normalized Difference Vegetation Index，NDVI)又稱為標準化植被指數，是一種植被偵測指標，最常應用在評估該目標地區綠色植被的生長狀況，以簡單的數學計算方法萃取，透過計算近紅外光波段與紅光波段二者之間的差值除以二者之和，其公式如式 3-3。NDVI 能顯示出植物生長、生態系的活力與生產力等資訊。數值愈大表示植物生長愈多，是眾多植被偵測指標中最簡易快速的指標計算方法。於此，本計畫特別選用涵蓋了近紅外光波段之航空照片，來增加 NDVI 特徵指數，以強化樹種分類之訓練。

$$\mathrm{NDVI} = \frac{(NIR - RED)}{(NIR + RED)}$$

式 3-3

實際上，樹種生長之物候特性與地形因子，均有其高度相關性，但亦包含著複雜的運作機制需要深入測試。因此，本計畫優先導入 6 項地形因子(圖 3-14)與 1 項植被指標進行訓練。同時，亦透過資料蒐集研析未來精進模型之解決方案。

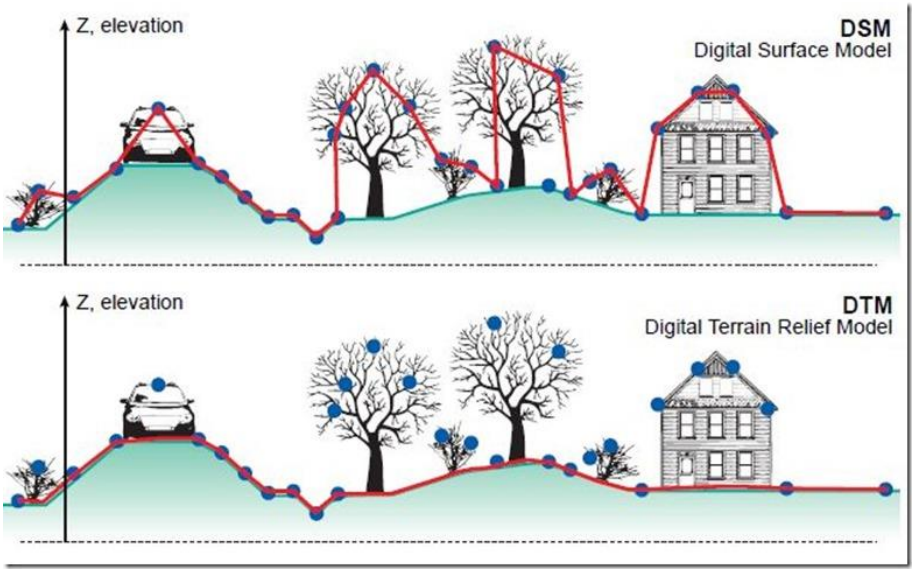

圖 3-11 數值地形模型比較示意圖

5米

20米

圖 3-12 浮水印影響示意圖(TRI)

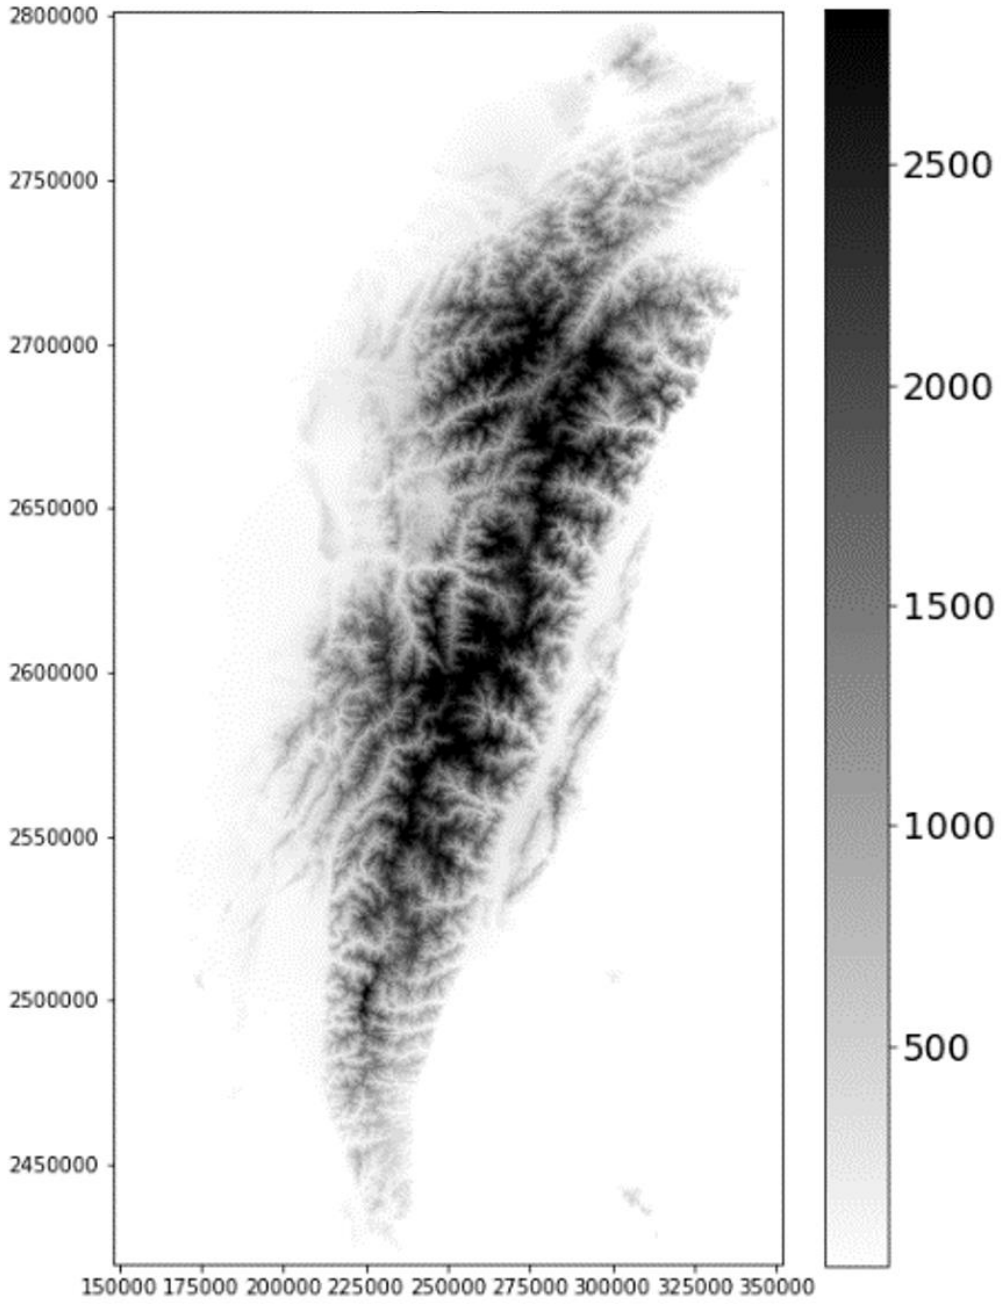

圖 3-13 全臺數值高程模型資料

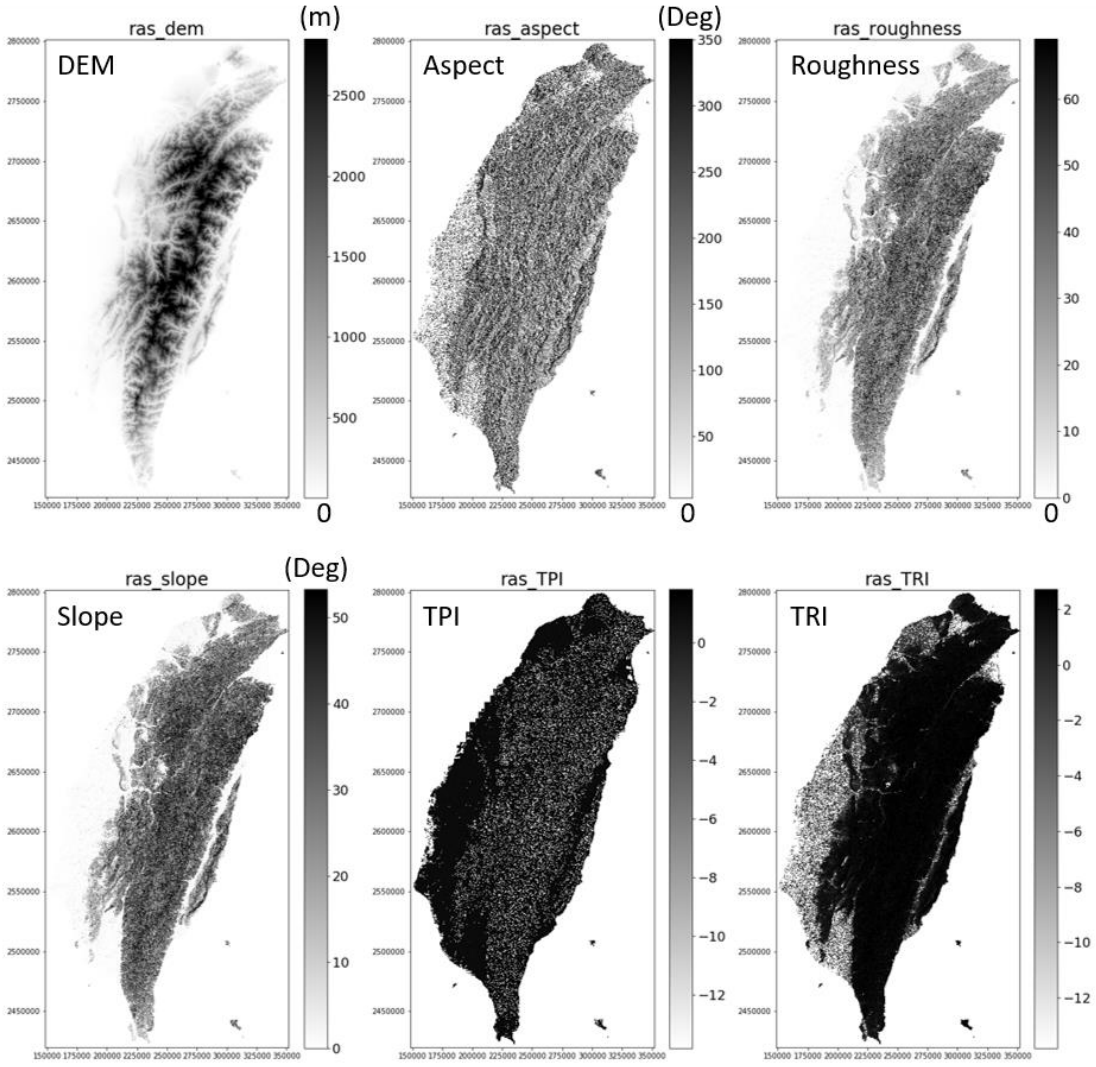

圖 3-14 地形因子萃取結果

第肆章、航遙測影像分類技術之分析與功能評估

影像分類技術用於航遙測資料之應用發展甚早，在各種環境資源調查的議題中，習慣使用航遙測影像的網格空間資訊進行地表物件分類，雖然判釋精準度不及專家人工實測，但確實可以大幅減低分類工作的人力、時間成本。本計畫依循文獻收集之結果，彙整現行常見的航遙測分類技術，了解技術邏輯、演進與應用發展之現況，透過表格的羅列具體呈現分析成果。除此之外，相應的遙測影像開發平台功能評估，同樣也會以綜整視覺化界面、遙測演算法功能模組與服務應用領域之比較，使用表格具體羅列。除了可作為模型實做分類測試之參考，亦提供業主作為後續計畫執行之依據。以下將針對傳統分類技術與遙測開發平台進行初步分述。

4-1 影像分類技術分析

在傳統的影像分類工作中，經常根據波段光譜特徵來加以群聚與分類，配合統計方法計算群體樣本的特徵向量，再逐一判斷個體像素(像元)的離散程度，例如標準差、協方差等量化指標，配合專家經驗設定門檻將其進行分類。綜上所述，影像分類技術係按照概率統計的規律，建立適當的地物判別函數，將這些分散的集群區分割出來，然後再對個體做出判別及歸類。

本計畫針對傳統航遙測影像分類方法進行研析與比較，依照試驗樣區的有無，可將影像分類方法概分為監督式分類(Supervised Classification)與非監督式分類(Unsupervised Classification)。此外，隨著電腦視覺技術的發展，紋理分析(Texture Analysis)與模糊理論(Fuzzy Theory)的提出，亦使得分類的方式有了新的發展，以下就分類方式逐一介紹之。

一、監督式分類

在監督式分類中，每一項判釋類別都需要一組訓練樣本，這一組樣本包含許多從已知判釋類別影像獲取的資料，同時提供給資料一標記(Labeled)資訊，以利分類時進行判斷。因此，透過訓練樣本可建立一個學習模式，依照此模式推測輸入資料之成果。

在監督式分類過程中，最常處理之兩類問題包含迴歸及分類。若資料為針對數值上的預測，可利用迴歸函式進行預測模擬的結果，應用面向可預測市場動向，包含進銷庫存、價格分析及銷售量預測；若資料需進行分類時，通常檢視類別的機率，判定資料歸屬於哪個類別，常見應用包含偵測垃圾郵件、語種或語音之偵測及識別。監督式分類主要方法為一未知點透過模型分析掌握其距離哪一組訓練樣本之統計特性最近。在影像判釋的程式邏輯中，所謂最近於某一訓練樣本特徵，係指在特徵向量統計上的距離。選擇的訓練樣本多數是分析者認為具有代表性的地區，因此該方法較適合運用於對判釋地區地物較熟悉的案例。

監督式分類之最大特點為由於有訓練樣本之輸入，其成果之準確率較高，但訓練樣本需要提供標記資訊，需要耗費較多人工作業標註，對於較大之資料量，較難以採用此分類方式進行。

二、非監督式分類

在非監督式分類中，未判釋資料不需訓練樣本的資料先進行訓練，即可提供無標記之資訊進行分類或分群，減少資料前處理進行標記之作業。透過大量資料之訓練即可找尋各分類間之相似特徵，有效建立分類模型。

在非監督式分類過程中，最主要運用於分群(Clustering)中，先檢視大量的未判釋資料特徵向量值，根據這些資料的特性將它們分成不同的群集亦稱群集類別，使類別間之差異大於類別內之差異，常見之應用包含分析消費者行為及用戶體驗。實際上，同

一類別的資料向量點在資料向量空間圖上位置相近，不同類別的向量點則在圖上較為遠離。如果資料向量的分向量代表不同波段的反應，最終的類別即可稱為光譜類別(Spectral Classes)，與資訊類別(Information Classes)區別。資訊類別是指分析者關心的地面覆蓋物類別。一般而言，非監督式判釋可用於較不熟悉之地區，或需快速取得大量判釋成果時。

三、紋理分析法

紋理是物體表面固有的一種特性，影像中的區域常呈現出紋理性質。紋理基本上是影像描述亮度變化頻率的方式，又可稱為組構，在航遙測影像中經常以地物的形狀、大小、空間分布、優勢方位、均質程度或亮度規律變化描述之。另外，紋理與尺度有著密切的關係，一般僅在一定的尺度上可觀察，而對於紋理的分析則需要在恰當的尺度上進行，且紋理具有區域性質的特點，通常被看作局部區域中像素與像素之間的一種度量。

紋理分析法主要針對紋理特徵之萃取，由於紋理特徵為物體表面之特性，無法完成反映其本質。而紋理特徵較大的特點為其對於雜訊之抵抗能力較佳。另外，對於影像進行紋理分類之過程中，被歸為同類的影像畫面具有相同紋理的特性，可得到旋轉不變性(Rotation Invariant)的特性，如局部二值型態(Local Binary Patterns，LBP)特徵，推導出對任何單調的灰度及尺度變化都能顯示不變性。

該方法較適合運用於具有疏密或粗細等方面較有清楚區分之紋理特徵。一般常用的紋理分析方法包含統計方法、結構方法與頻譜方法。統計方法較基本之方式採用灰階直方圖描述紋理；結構方法的原理基於同種紋理是由較小單元的紋理元素利用一定規律的形式重複排列組合而進行之紋理分析；頻譜方法則是著重於取得亮度之間變化的特性分析，如斑點均質性及排列規則性。

四、模糊分類法

模糊理論最早由 Zadeh 於 1965 年所提出，被認為在是與非之間存在灰色地帶，不確定性事物的歸屬可用概率的方式加以表示，以顯示它模糊性及不確定性，是一門將模糊概念以量化而成的學問。模糊理論係以模糊集合(Fuzzy Set)為基礎，其基本精神是接受模糊性現象存在的事實，處理概念模糊不確定的事物為其研究目標，並積極的將其嚴密的量化成電腦可以處理的訊息，不主張用繁雜的數學分析即模型來解決模型。

模糊理論發展至今已接近三十餘年，應用的範圍非常廣泛，從工程科技到社會人文科學都可以發現模糊理論研究的蹤跡與成果。在遙測影像分類的過程，一些地物往往存在模糊邊界，要明確的判定地物類別的邊界相當困難，對於這種邊界不明顯的狀況，可以利用模糊理論加以解決。透過建立最大似然比的模糊分類模式，以計算模糊性類別的歸屬概率。然後再利用最大似然比模型分類法，對過渡的類別進行分類。

本計畫蒐整四種常見影像分類演算法，分述包含其邏輯特色、優點特點與應用面相，同時摘整於表 4-1。基於這些經典演算方法，本計畫以自動化為目標，發展符合林型樹種分類需求之機器學習方法，突破巨量資料應用之限制。

表 4-1 影像分類演算法比較表

影像分類演算法	常用演算法	優點	應用面向
監督式分類	1. 最鄰近法 (k-Nearest Neighbors) 2. 線性模型 (Linear Models) 3. 決策樹 (Decision Trees) 4. 隨機森林 (Random Forests) 5. 類神經網路 (Neural Networks)	有訓練樣本可有效提高分類準確率。	1. 已知土地利用 2. 市場價格預測 3. 垃圾郵件偵測 4. 語音手寫辨識
非監督式分類	1. K-means 2. 密度空間分群 DBSCAN (Density-based Spatial Clustering) 3. 階層式分群法 (Hierarchical Clustering) 4. 主成份分析 PCA (Principal Component Analysis) 5. t 分佈隨機近鄰嵌入 t-SNE (t-distributed Stochastic Neighbor Embedding 6. 最大似然估計 MLE (Maximum Likelihood Estimation)	訓練資料不需透過人力處理標記。由模型自行摸索潛在的分類規律。	1. 未知土地利用 2. 巨量資料分類 3. 消費行為分析
紋理分析法	1. 灰度共生矩陣 GLCM (Gray-Level Co-occurrence Matrix) 2. 自相關函數 (Autocorrelation) 3. 半變異數函數 (Semi-Variogram) 4. 馬爾科夫隨機場 MRF (Markov Random Field) 5. 吉布斯隨機場 GRF (Gibbs Random Field) 6. 自迴歸模型 AR (Auto Regressive model) 7. 小波轉換 (Wavelet Transform)	具有較佳的抗雜訊能力，與矩陣旋轉不變性。	1. 影像紋理分析 2. 遙測農業應用
模糊分類法	1. 隸屬函數 (Membership Function)	用以解決分類目標邊界模糊的問題。	1. 機械控制工程 2. 圖像文字識別 3. 專家決策系統 4. 自然語言處理 5. 心理性向分析 6. 污染檢測方法

(資料來源：本計畫彙整)

4-2 開發平台功能評估

近幾年，市面上的遙測影像分析開發平台百家爭鳴，常見的地理資訊系統軟體如 eCognition Developer、SAGA GIS、ArcGIS、QGIS 等。不論是付費軟體或開源軟體，在功能開發、介面操作的設計上均有各自的特色與優勢用戶，簡易的規格比較如表 4-2。以下將針對各項開發平台，逐一進行產品簡介與功能評估，並以表格綜整其產品特性與優劣比較。同時理解在森林物件分類的工作中，如何依需求設計作業流程，並參考現有平台操作方法、分析架構與演算法特性。

表 4-2 開發平台規格比較

開發平台	eCognition	SAGA	ArcGIS	QGIS
商標圖示				
開發維運	Definiens & Trimble	University of Göttingen & SAGA User Group Association	ESRI	OSGeo
發行日期	1994	2004	1999	2009
最新版本	9.5	7.6	10.5	3.10
系統平台	跨平台	跨平台	Windows	跨平台
軟體類別	商用軟體	開源軟體	商用軟體	開源軟體
軟體特色	商用的物件式影像分析演算法應用軟體。可建立專家系統，協助專案專業處理。	免費的自動化地理空間資訊分析系統模組。支援跨平台、跨環境彈性整合不同軟體。	自然與人文地理空間分析模組化工具組。從網路服務到單機操作，功能完整，效率高。	免費且輕量的地理空間分析模組化工具組。功能整合完善，開源擴充彈性佳。

(資料來源：本計畫彙整)

一、eCognition Developer

eCognition Developer，簡稱 eCognition 是一套由德國 Definiens Imaging 公司所研發的物件導向遙測影像分析開發環境，其結合了模糊分類的專家系統，突破了傳統商業遙測軟體，多僅依靠光譜資訊進行分類的侷限性。其應用層面甚廣，包含基本的地物分類與萃取、災損評估與變遷分析、點雲資料分類、林業管理與林木盤點、都市計畫等。以下就代理商官方簡介說明 eCognition 其開發平台之優勢。

(一) 物件式影像分析技術

近幾年來物件式影像分析技術(Object-based Image Analysis，OBIA)逐漸成為影像分類法的主流，其概念就是在分類前先將影像分割(Segmentation)成許多「區塊」，這些區塊又稱為「物件」。除了利用影像光譜值來區分不同的類別外。物件還有更多的特徵，例如大小(Size)、紋理(Texture)、形狀(Shape)、脈絡(Context)等，OBIA 即結合上述因子輔助辨別影像上的物體，類似於人眼辨識的機制，比像元式分類成果更為準確、可靠。如圖 4-1 所示，像元式分類就有如拿著顯微鏡來辨認桌子的顏色；而物件式分類則可以看到桌子較完整的全貌。

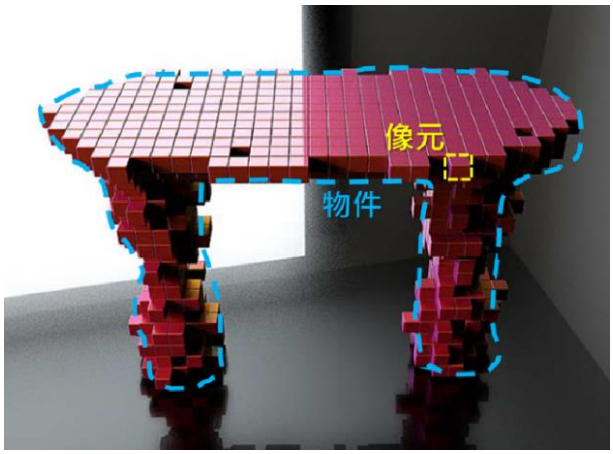

圖 4-1 像元式分類辨認方式示意圖

(二) 多尺度影像分割方法

影像分割技術類似物以類聚的概念，原理是根據顏色、紋理或形狀等特徵把影像劃分成若干互不重疊的區域，其方法很多，例如著名的 K-平均演算法(K-means Clustering)、區域成長(Region Growing)等。而 eCognition 以使用多尺度切割法(Multiresolution Segmentation)著稱，針對其他演算法截長補短，除了考慮光譜一致性外，光譜的權重、初始區塊的大小與形狀等幾何條件，都能自行調整以找到最符合的分類目標，當尺度(Scale)愈大時可得到較概括性的成果；而尺度愈小時的切割成果則愈精細。以圖 4-2 為例，黃框內之草坪區為例，當尺度為 150 時分割結果為完整的草坪區，自動忽略較細微的特徵；若縮小至 80 時，不僅可辨識內部的小土丘，更將草地細分為淺色草皮與深色草皮。根據不同的分類目的可以有不同的分割參數。

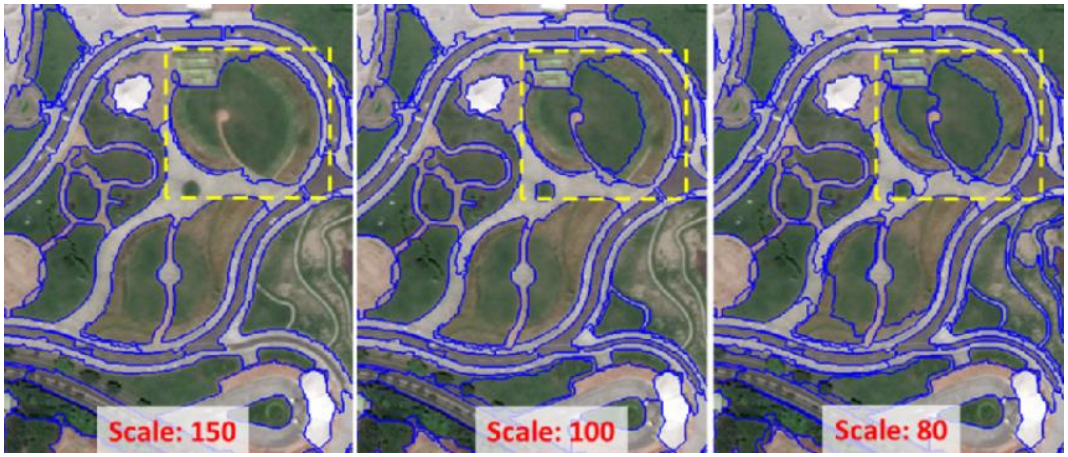

圖 4-2 多尺度切割法示意圖

(三) 知識導向的分析架構

eCognition 可以整合多種感測器、平台以及各式解析度的地理資料同時進行分析處理，除了影像外更包含各式網格(Raster)、向量(Vector)以及點雲(Point Cloud)數據。而使用者在

了解不同的資料內涵後，可以基於自身知識(Knowledge-based)以內建的上百種演算工具搭配特徵因子，建構一套專屬特定分類目標的影像分析準則(Rule Set)，並且將其直接打包成一個專家知識庫，對於類似的分析目的隨即可以直接套用，而準則直中所記錄的分析參數也可以彈性調整。

(四) 監督式分類模組更新

監督式影像分析是假設使用者對各類別差異不必過於了解，僅透過樣本選取，軟體會針對選取的樣本進行機器學習，自行找出各類別間的光譜差異，以類似大數據 AI 的概念自動化分析影像上性質相同的區塊，此種分析方法相比非監督式較不耗費人力，且在演算法日新月異的情況下，其分類的精度也能達到一定的水準，近年來 eCognition 也積極增進監督式分類模組，如 SVM、CNN 等機器學習分類法都可以在軟體中使用。

二、SAGA GIS

SAGA(System for Automated Geoscientific Analyses)其全名為自動化地球科學分析系統，這是一套由德國漢堡大學(University of Hamburg)與哥廷根大學(University of Göttingen)自然地理學系共同發起的地理空間資訊開源軟體。該軟體著重發展各項演算法之模組化開發，跨平台、介面化之設計提供開發人員更加簡易的操作方法。在可視化(GUI)介面的協助下，能夠更輕易地操作不同類型、署性的空間資料。以下就其開發平台特性優勢進行說明。

(一) 地球數據分析與應用

SAGA 最初就是為地形資料分析而生，例如地形陰影套繪、河川流域應用、地圖投影轉換等。進階發展至今更集結了多樣的地科統計方法、地形資料分析與動態數據模擬。地科統計方法例如殘差(Residual)分析、克里金法、迴歸(Regression)分析、方差(Variance)分析。而地形資料分析例如坡度曲率計算、河川

流路分析，集水區劃定、太陽輻照度、海拔高度計算等。另外，動態數據模擬則包含地形指數模式(Topographic Index Model，TOPMODEL)、侵蝕作用等。

(二) 演算法模組功能串接

SAGA 致力於提供地球科學家一套簡單上手、方便有效的開發平台，以協助他們實現更專業的地球科學研究方法。透過獨有的 SAGA API (Application Programming Interface)介面基礎即可輕易的串接各種演算法。專案操作上首次的執行可利用圖形化介面(Graphical User Interface，GUI)確認流程與演算法架構，包含檔案管理、數值統計、屬性表格、地圖資料、向量圖層等(圖 4-3)，透過完整的底層語言 C++進行串接，除此之外可透過 CMD (Command)撰寫腳本對專案進行批次分析(圖 4-4)，亦能複製相同的專案流程在類似的工作流程中快速執行。

(三) 跨平台多元資料整合

SAGA 是一個開源的 GIS 軟體，為了讓使用者能夠更加彈性的進行分析工作，除了支援 Windows 與 Linux 的跨平台開發，也保留了與其他軟體協作應用的空間，例如在 QGIS、Kosmo 或 R 的環境中直接呼叫使用 SAGA GIS 模組，顯現其高度相容性與應用性。

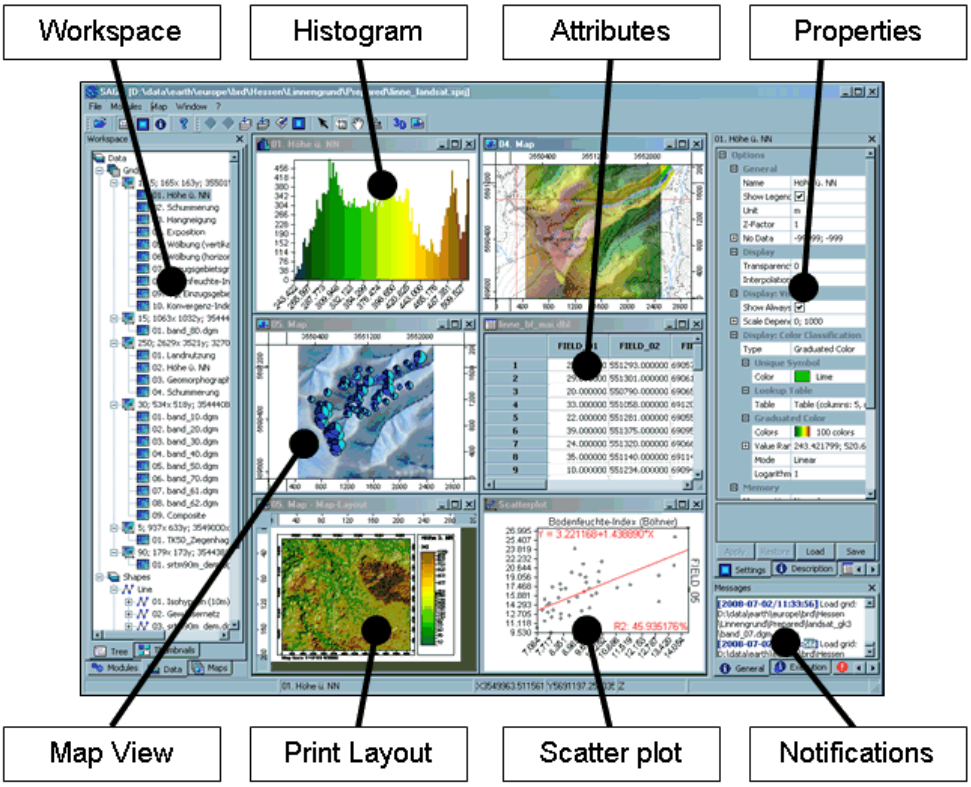

圖 4-3 SAGA 圖形化介面呈現

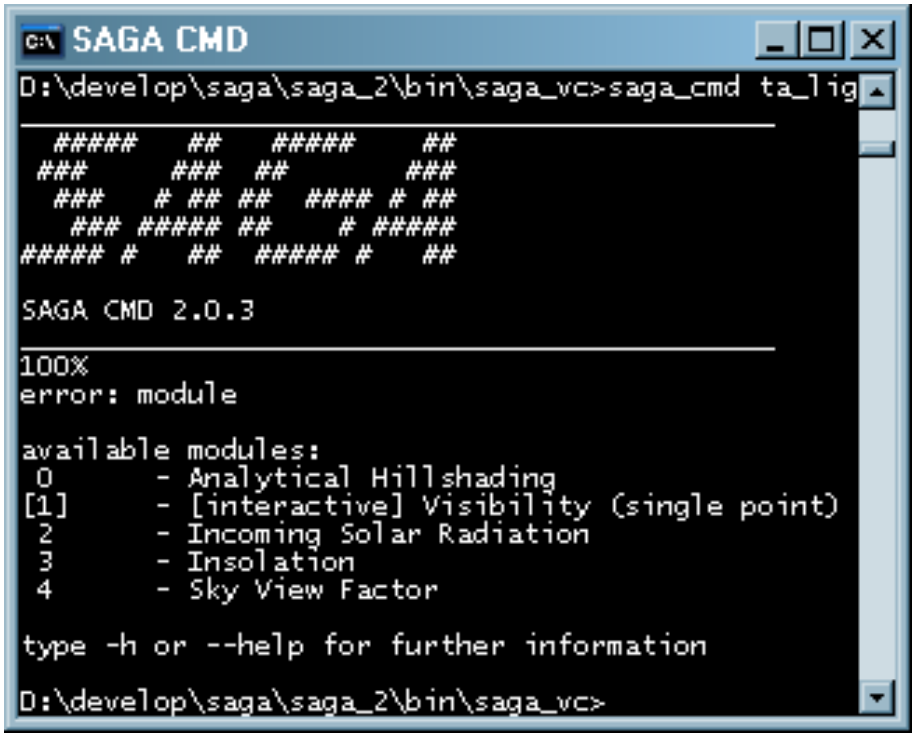

圖 4-4 CMD 腳本進行專案批次分析

三、ArcGIS

ArcGIS 是一款由 ESRI 出品的一個地理資訊系統系列軟體的總稱。主要功能特色包含空間資料分析、現地調查整合、地圖數據繪製、三維地理資訊、遙測影像處理，以及資料集合管理。其依不同應用平台又可分成三種版本。桌面版本，依功能等級可區分為 ArcReader、ArcView、ArcEditor 和 ArcInfo。另有免費的 GIS 瀏覽器稱作 ArcGIS Explorer Desktop；伺服器版本，同樣依功能等級分為基本款 ArcWMS (Web Mapping Server)、標準款 ArcGIS Server 與進階款 ArcGIS Image Server；行動裝置，包含 ArcGIS for Windows Mobile 、ArcPad 、Explorer for ArcGIS (iOS) 、ArcGIS (Android)等。比起前述的兩套軟體，ArcGIS 顯然已經是一個配備完整的軟體家族，除了各家雷同的地理空間資訊分析方法，更著重於資料管理、資料整合與流程傳接的應用，以下將針對其特點與優勢進行說明。

(一) 地理數據資料庫搭建

ArcGIS 整套開發平台係圍繞著地理資料庫(Geodatabase)所構建的，它使用對象關係型資料庫來儲存空間數據，是一個儲存數據集的容器，同時可以簡單的將空間數據和屬性資料綁定起來，包含拓撲數據也能夠儲存，並對其特性進行建模。假設在表示道路交叉時可以對道路之間的相關性進行設定，而要素類別(Feature Classes)則扮演著重要的角色，在地理資料庫中能夠在一個文件中儲存多個要素或者是多種類型的要素，大幅提升資料管理的效率。在 ArcGIS 中，Geodatabase 則以三種不同格式儲存包括 FGDB(File Geodatabase) 、 PGDB(Personal Geodatabase)，和 ArcSDE Geodatabase。

(二) 軟體功能元件整合

ArcGIS 桌面版本是由許多的應用程式元件(Components)所組成，以功能包含最完整的 ArcInfo 來說，應用程式元件會包

含，ArcMap，是最基本的應用程式元件，主要用來處理 2D 的空間資料，可以進行製圖、編輯與地圖空間分析；ArcCatalog，可用來管理空間資料，進行資料庫的簡易設計，並記錄與展示詮釋資料(Metadata)；ArcToolbox，地理資料處理工具的主要集合，整合在 ArcInfo 介面中提供使用者各種資料處理之需求；ArcGlobe，可以 3D 立體地球儀的方式來展示、編輯或分析三維空間地圖；ArcScene，則是提供單純的三維資料展示、編輯、分析之介面功能；最後的 ArcReader，則是基本的展示工具，在完整安裝時也會連帶安裝。

(三) 商業服務與社群後援

ArcGIS 商用服務發展已餘 20 年，所累積的資源與用戶為軟體本身搭起更強而有力的版本優化服務，不論在教育訓練的辦理、技術與資安支援、技術社群的組織或全球性的技術會議研討，促使 ArcGIS 有全球最多的使用者，健全的開發體系使得模組設計更能貼近其需求。

四、QGIS

QGIS(Quantum GIS)是一友善的開放原始碼地理資訊系統，其使用 GNU 通用公眾授權條款(GNU General Public License)授權，屬於開源地理空間基金會(OSGeo，Open Source Geospatial Foundation)的官方計畫。在 GNU 的授權下，開發者可以自行檢閱與調整程式碼，並保障讓所有使用者可以免費且自由地修改程式。QGIS 致力於發展使用簡單的 GIS 系統開發，除了一般常見的 GIS 功能，更提供開發者以底層的程式語言，以 Python 或 C++自由的進行擴充與開放使用，包含不同資料、領域需求的瀏覽、管理、編輯、分析與製圖功能。除了自發性的開發社群系統維護，QGIS 也提供商業化的客製開發服務。

2008 年，在中央研究院人文社會科學研究中心地理資訊研究專題中心的支援下，開啟了 QGIS 中文化套件服務，大幅降低國內初學者的使用門檻，以期讓愈來愈多的使用者能利用 QGIS 於生活或研究中。隨著協作團隊的擴增 QGIS 在短短的十年之間蓬勃發展，其可支援之功能堪比 ArcGIS，以下就其開發平台特性進行說明。

(一)結合開源套件功能強化

QGIS 由 Gary Sherman 於 2002 年開始萌芽，並於 2004 年成為開源地理空間基金會的一個孵化專案。以 C++寫成，並允許開發者整合使用 C++或 Python 寫成的外掛程式強化使用者需求。除了 Qt 之外，QGIS 還使用了 GEOS 和 SQLite 作為軟體運作的核心。同時也支援 GDAL、GRASS GIS、PostGIS 和 PostgreSQL 等相關套件，提供使用者進行分析與應用。

(二)跨平台開源軟體優勢

QGIS 支援多平台應用，可以在多種作業系統上執行，包括 Mac OS X、Linux、UNIX 和 Microsoft Windows。對於 Mac 用戶，QGIS 相對於 GRASS GIS 的優勢在於它不需要 X11 窗口系統，而且介面更簡潔、快速。Quantum GIS 也可以作為 GRASS 的圖形化使用者介面使用。相較於商業 GIS，Quantum GIS 的檔案體積更小，需要的記憶體和處理能力也更少。因此它可以在舊的硬體上或 CPU 運算能力被限制的環境下執行。此外，QGIS 是基於 GPL 釋出的自由軟體，可以被修改以執行其他或更加專業的任務，例如國際開源衛星影像資料下載。另外有很多外掛程式可以用來擴充相容性和功能。

實務上，本計畫使用之航攝影像資料拍攝圖幅寬廣、空間解析度極高，再加上同一個地區可能有數次的拍攝記錄，這使得影像存取量龐大，資料容量高達 750GB。在既有的 GIS 軟體中處理這樣龐

大的資料，需消耗大量的運算資源，可能因此降低資料分析的效率，縱使提升硬體資源加裝 GPU，軟體相容性設計也未必能夠有效支援。於此，本計畫透過 Python 開源程式碼開發機器學習演算法，方能在程式設計上考量快速運算之需求，有效應用多核心平行運算，實現快速運算分析、消化大量資料之目標。

第伍章、深度學習演算法之研究探討

5-1 機器學習影像分類演算法分析與評估

機器學習的議題近年來之所以有了爆炸性的成長，有很大一部分來自對於圖像處理技術的成熟，而且這樣的技術甚至已經可以達到商業化所需的程度。在處理「影像分類(Classification)」問題時，最常使用卷積神經網路(Convolutional Neural Network，CNN)演算法，其相關論文早在 1998 年就已經被發表，然而在當時礙於硬體運算速度的限制，演算法並未被普及應用。時至今日這樣劃時代的演算法，隨著硬體技術的提升，也已經在機器學習圖像辨識領域中盛行多年。然而，當圖像處理進階到「影像分割(Segmentation)」的問題，則必須在做好物件分類的原則下，辨識目標物件的輪廓或範圍，有別於 CNN 演算法的使用，必要時需透過更進階、複雜的演算法架構來達到此目的。以下將以兩大影像處理目標，影像分類與影像分割，分述其適用之演算法。

一、影像分類演算法 CNN

在傳統遙測影像判釋領域中，經常使用人工篩選或紋理濾波器的方法來萃取影像特徵，在深度學習領域中，這樣的特徵可視為卷積(Convolution)，搭配以網格為基礎的分類方法，對影像中每一個像素的各波段數值組成進行類別的預測。然而，這樣的做法容易遭遇兩個問題，其一，紋理濾波器的篩選必然侷限於當次案例使用的資料集，假使更換了資料集，例如航攝地點的不同或地形光影的改變，就必須重新打造濾波器以適應新的資料集。如此一來，除了標準難以定義外，每次訓練都必須耗費大量專業人力，才能取得較為理想的判釋結果。其二、以網格為基礎的分類方法，很難考慮到目標物件複雜的形狀特徵，以及完整的全域圖

幅資訊，雖配有濾波器可做紋理特徵的篩選，但仍就侷限於局部性的偵測，當目標物件涵蓋範圍過大時，將出現判讀上的缺漏。

如前所述圖像處理之所以困難，係因為電腦在解讀影像的方式與人類視覺有著極大的差異，其必須以像素為單位，逐一進行理解或辨識。一張由512×512個像素組成的彩色影像，對電腦而言僅僅只是一個 512×512×3 的三維數值陣列，如何從這些數值陣列進行有意義的辨識，即是深度學習熱烈討論的議題。但對人類而言解讀的是影像全貌，這些數字代表的顏色與強度，能讓我們輕易的辨識出圖像上的物件，甚至包含背後複雜的情境都能掌握。CNN 演算法即是在這樣的背景下誕生，其核心概念便是考量到鄰近像素的相互關聯性，之後再進行辨識。舉例而言，一張影像中包含許多橘色的像素，光就這樣的資訊很難辨識出影像裡的貓。但假使這些橘色的像素群聚為特定形狀，例如貓的頭部、尾巴，則可能有較多的資訊來輔助判斷，辨識出影像裡的貓。同理，透過特定的森林群聚之樣態、顏色或紋理...等特徵，可透過 CNN 演算法進行分類辨識的學習。

實作上，CNN 會透過無數特定形狀的窗格對影像進行掃視，並檢視哪一個窗格與影像局部特定位置有高度的特徵相似，也許是紋理亦或輪廓的相似。假若兩個相似度高的窗格與局部影像，以矩陣方式相乘，便能得到較高的分數。用這樣的條件作為抓出特定物件的判斷標準，當無數個可疑的特徵窗格，通過模型的嘗試與學習後，就能夠對物件進行精準的分類。如圖 5-1 可見，最左側為輸入的原始影像，通過多層的 CNN 特徵萃取工具，將影像特徵濃縮成一條較小維度的向量，每一個維度即代表著某一特定影像特徵，最後再將濃縮的特徵放回深度神經網路(Deep Neural Network，DNN)分類器，即可成功進行影像辨識。因此，相同的做法，本計畫可透過蒐集而來的航空照片進行特徵之萃取，並基於森林林型圖純林樹種建立學習之目標特徵。

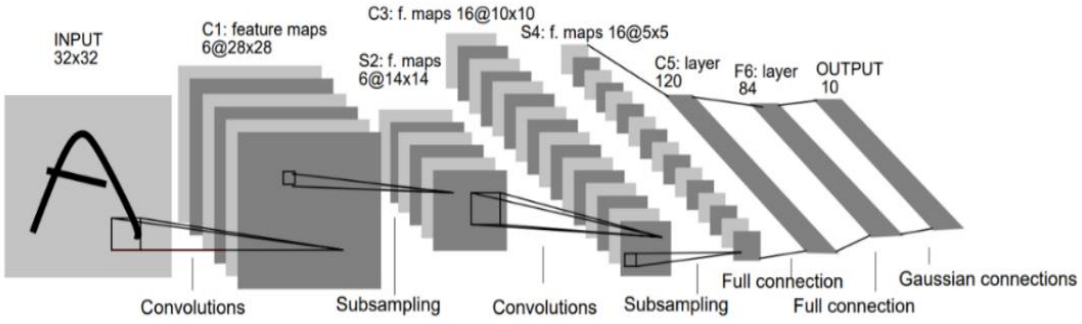

圖 5-1 CNN 模型架構

二、影像分割演算法 U-Net

當分類目標底定，需要進一步透過影像分割演算法，明確辨識目標物件在影像中的位置與輪廓。相較於影像分類演算法，模型架構更為複雜，早期有不少透過全卷積網路(Fully Convolutional Network，FCN)的影像分割案例，如圖 5-2，建立在 CNN 的基礎架構上，為了達到分割的目的，需要得到每個像素的分類預測值，於是將濃縮後的特徵向量，需再透過 CNN 採樣的方式恢復為原尺寸，如此便能對每一個像素進行分類，進而達到影像分割的目的。然而，實務運作上效果時常不如預期，近幾年取而代之的 U-Net 演算法有著更理想、廣泛的應用成效。

U-Net 架構是在 2015 年被提出來的影像分割模型，如圖 5-3 所示，該演算法與 FCN 相似同樣透過 CNN 萃取影像特徵向量，但在恢復原尺寸的影像放大過程中，除了放入萃取出的特徵向量外，另外增加了影像合併(Concatenate)的步驟。在濃縮過程中，將大小相同的影像進行合併，被增強的向量特徵同時反映在恢復原尺寸的所有像素中，進而增加影像辨識的精準度。簡言之，U-Net 演算法擅長處理影像中較大的目標物件分割問題，例如衛星影像的雲層分割、土地利用分割...等，都有相當多的應用案例。

本計畫透過深度學習方法建立森林覆蓋型類別辨識模型，依據模型的需求設計，預計將同時牽涉到「影像分類」與「影像分

割」。對每一個切割好的影像單元，做出各樹種即為「影像分類」，採用 CNN 演算法架構，其架構單純通常會可以有不錯的分類表現，但其空間解析度僅止於切割好的影像單元，需透過移動窗格將分類結果細化到像素單元。直接地對每一個影像像素做分類，將相同類別的像素進行群聚分割即為「影像分割」。

需特別提及的是，由於需將 CNN 影像單元的分類細化到像素單元，本計畫首先對原始影像透過移動窗格進切割，窗格之間可能相互交疊，接著採用 CNN 影像分類模型對每一個切割後的影像進行分類，並將該切割後影像所有像素視為同一分類結果，然後把每一像素的分類結果寫回其在原始影像中像素的位置，如此一來，原始影像中的每個像元便會有多個窗格的判釋結果，最終將原始影像每個網格中的多個判釋結果進行平均，以獲得每個像元的分類結果。

考量到分割模型對於多類別分類的效果仍比較有限，且最終判釋全台森林覆蓋型時的資料不平衡比例非常懸殊，本年度優先採用「影像分類」模型進行模型訓練，確保林地分類模型之正確性。

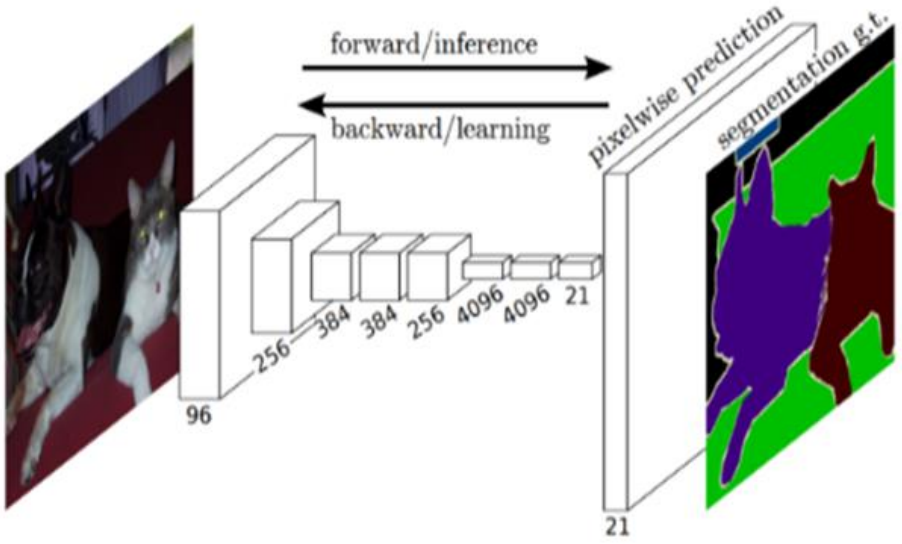

圖 5-2 FCN 模型架構

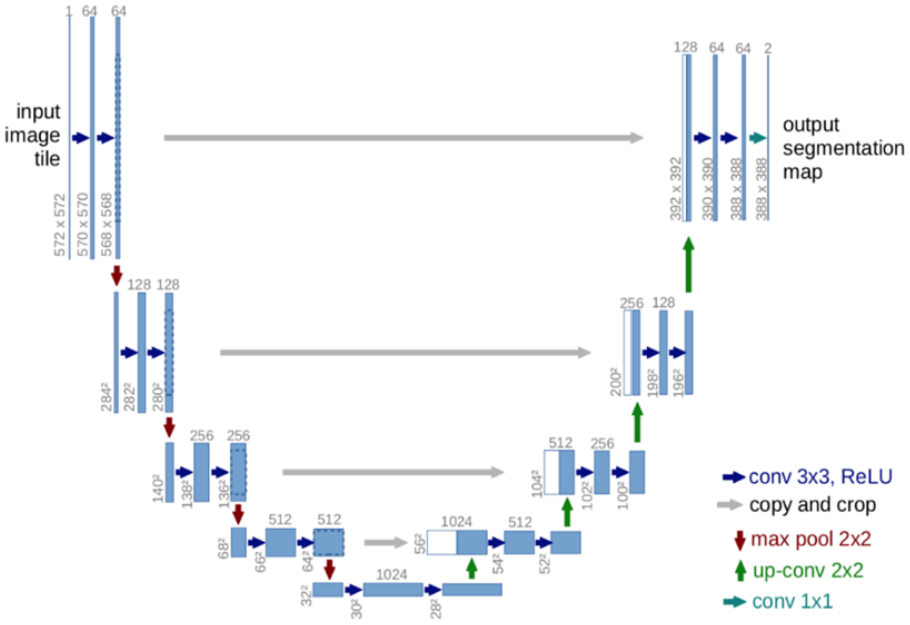

圖 5-3 U-Net 模型架構

5-2 機器學習開發平台分析

機器學習開發平台係為相關演算法開發過程中，必備的程式語言(Programming Language)基礎設施、深度學習框架(Deep Learning

Framework)，與程式編譯工具(Integrated Development Environment ，IDE)，如圖 5-4 所示。本節將彙整與說明常用的開發平台，係為後續演算法開發工作之基礎。

一、程式語言

在機器學習與深度學習程式開發過程中，選用的程式語言須考量三個原則，包含「套件完整性」、「開發速度」以及「執行速度」。首先，「套件完整性」將可協助專案工程師專注於開發專業領域分析模組，無須重複撰寫基礎演算法，選擇具有完整套件支援的程式語言開發，將有效提升開發效率。再者，「開發速度」可以讓工程師快速地嘗試新的想法與參數，在專案研究階段扮演著重要的角色，同時因為受到程式的簡易程度與易讀性所影響，因此開發速度的快慢，亦會影響專案共同開發難度以及上手難度。最後，「執行速度」則在 AI 模型開發與部署過程中扮演重要的角色，在開發上可以快速地嘗試想法並實踐，在部署上可以快速運算出結果，快速處理大量的資料。深度學習模型開發領域中以 C/C++或 Python 為主，列表比較如表 5-1。

具有 AI 完整套件支援的程式語言為 Python，由於其為高階語言，語法簡單易懂，也無須做記憶體管理，為現行 AI 開發領域最廣泛應用的語言，在廣泛社群的支援下，無論在 AI 領域或是地理資訊領域，套件完整性都是無庸置疑的。惟其運行效率略差於 C 與 C++，不過在前處理的部分地理資訊圖資大量仰賴 GDAL，模型訓練部分則仰賴 Tensorflow 或是 PyTorch，無論 GDAL、Tensorflow 或是 PyTorch 底層接是透過 C 或 C++完成，Python 只是提供一個簡易操作的介面，Tensorflow 或是 PyTorch 也都可以透過 GPU 進行加速。因此，本計畫使用 Python 作為主要開發語言。

二、深度學習框架

由於大多數的主流 AI 都已經可以支援各語言、各深度學習演算法以及 GPU 運算功能，且開發程式之語法經過多年改版都已非常簡潔直觀，因此實務上可用性與執行效率已不是最主要的考量，「部署穩定性」與「社群支援度」則是其關注焦點。關於「部署穩定性」，由於許多專案逐步從研究階段轉換到生產階段，因此近期才開始收到關注。其所考量的情境是，當大量且高頻的使用模型進行預測時，如果不能有穩定的輸出結果，將導致服務中斷。「社群支援度」在框架選擇中亦是非常重要的議題，其主要原因在於，AI 模型理論發展上已有一定的困難度，實作上更是龐大複雜的工程，因此幾乎不可能真正知道框架當中每一個環節的實作方法，若沒有龐大的使用社群，在除錯的過程中所耗費的時間將非常可觀，若能有龐大的社群可以在網路上找到相關解答，可大大提高開發效率。在深度學習模型開發領域中，最被廣泛使用的套件為 Tensorflow 與 PyTorch，列表比較如表 5-2。

誠如表格所示，在部署的穩定度比較上，Tensorflow 因為從 2015 年便開始發展，較 PyTorch 的 2017 年早，因此現階段業界仍以 Tensorflow 為大宗，觸及部署議題的頻率與開發環境都比 PyTorch 為高。考慮社群支援度，Tensorflow 是現今最廣泛使用的深度學習框架，社群的廣泛程度更是於庸置疑，亦是本計畫主要使用的深度學習框架。

三、編輯工具

撰寫程式碼需要簡潔且便利的介面，因此需尋找相應的編輯工具(IDE)。每一種不同的應用所強調的編輯工具特性不盡相同，普通軟體開發較強調多介面比較，如同時顯示多份檔案、或同時整合命令提示字元執行指令。深度學習方面不需要這些功能，開發過程中既不會同時開啟多個進行編輯檔案，亦不會大量使用命

令指令列進行測試，深度學習開發工具比較強調即時互動性、資料視覺化方便性以及記憶體暫存方便性，需要即時觀測資料的組成與樣態，並視覺化呈現，因此需選擇互動性較強的開發工具。Python 開發領域中以為 Jupyter Notebook 及 Vscode 為主，列表比較如表 5-3。

綜合比較之下，由於深度學習模型測試中，記憶體暫存可將大量時間處理完的資料暫時存放在記憶體當中，待後續分析使用到時可以快速取得。另外在視覺化部分 Jupyter 因為整合了多種 python 視覺化套件，常用的 Matplotlib 套件甚至可以像網頁一樣提供互動式的資料統計圖表，比較進階的 leaflet 套件亦可以直接將地理資訊圖層呈現在地圖上。於此，本計畫使用 Jupyter 為主要的開發工具。

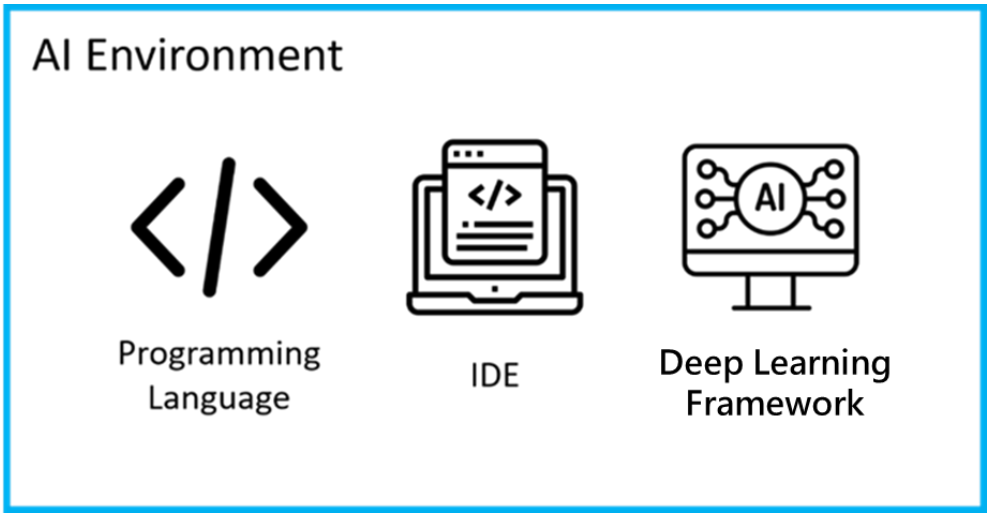

圖 5-4 深度學習開發環境要件

表 5-1 深度學習開發程式語言比較

比較項目	C/C++	Python
語言類型	低階語言	高階語言
學習難度	高	低
AI 套件完整性	低	高
記憶體管理	需要	少部分需要
開發速度	慢	快
運行速度	較快	快
優勢	運行速度快	開發速度快

(資料來源：本計畫彙整)

表 5-2 深度學習套件比較

比較項目	Tensorflow	PyTorch
部署穩定性	高	尚可
社群支援度	高	尚可
模型支援	多種	多種
GPU	可	可

(資料來源：本計畫彙整)

表 5-3 程式編譯器比較

比較項目	Jupyter Notebook	VSCode
專注語言	Python	All
適合應用	AI	網頁
類別	輕量級	輕量級
記憶體暫存	有	無
資料視覺化	強	尚可
DataCube	有	無
優勢	互動性強	多介面整合

(資料來源：本計畫彙整)

第陸章、森林物件萃取標準化流程雛型之建立

6-1 森林物件萃取標準化流程架構規劃

本計畫歷經完整的資料蒐集過程，理解林務局森林管理規劃之演進，並且規劃出在現行森林資源調查下的森林物件萃取標準化流程雛型，該流程係以深度學習技術為基礎，以建立自動化萃取流程為目的，真正落實應用於未來的圖資更新作業中。其參考規劃之藍圖如圖 6-1，整體而言可分為兩個部分，首先是以林型圖純林樹種與航攝影像為核心基礎，通過圖資套疊前處理整理訓練資料，接著再運用於深度學習模型之訓練，提取特定樹種，以強化現行作業效率與分類正確性。而第二部份則是依循既有圖資更新作業，定期更新以逐步優化深度學習訓練模型。

除此之外，本計畫進一步拆分森林物件萃取標準化流程，如圖 6-2，根據電腦視覺相關處理原則，將其分為「深度學習模型訓練流程」，及「模型部署與預測流程」，透過模型評價的過程確認模型運做之成效。後續章節將以此流程為基礎分述相關工作內容。

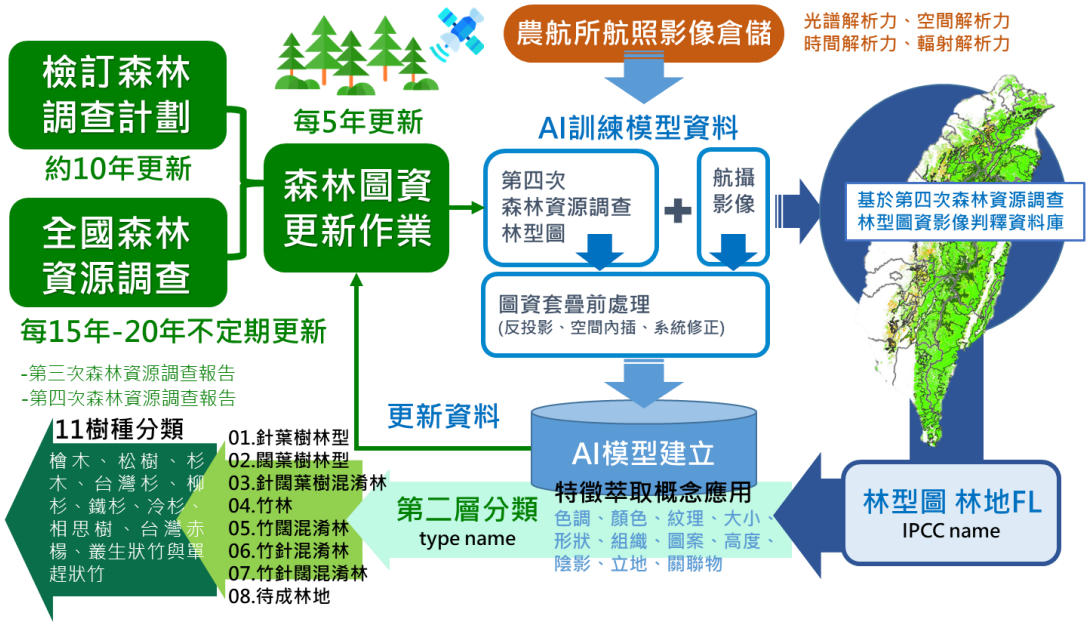

(資料來源：本計畫繪製)

圖 6-1 森林物件萃取標準化流程藍圖

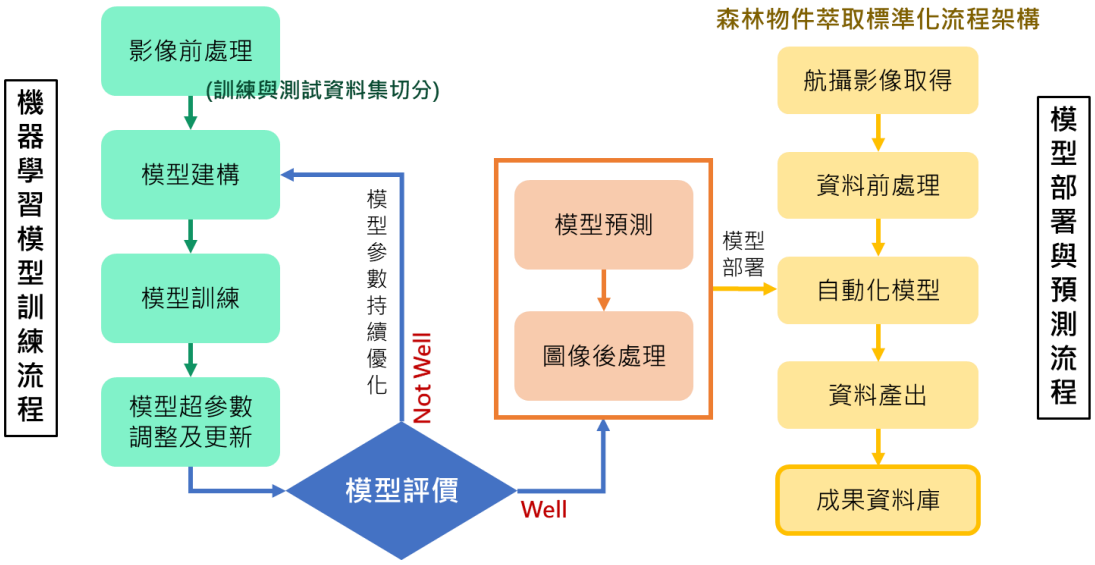

圖 6-2 森林物件萃取標準化流程雛形

一、現行森林資源調查與圖資更新作業

現行林務局更新森林資源調查成果，主要分為四項定期更新計畫，分別為全國性森林資源調查、永久樣區調查、國有林事業

區檢訂調查，以及所謂的圖資更新作業。計畫調查目的與更新內容均有所差異。

全國性森林資源調查，為 15 年至 20 年更新一次的全國性調查計畫，目前已執行四次，最後一次於 2010 年完成調查，調查內容包含林地清查、森林林型圖編修、土地利用圖編修、森林蓄積調查(地面樣區調查、航照樣點判釋) 、林地以外之森林覆蓋調查，以及野生動物調查等。此外，林務局於1998~2002年依序初設森林永久樣區，並規劃每5年複查1次。調查重點包羅萬象包含林木、林分、地景、地理、物化環境、野生動植物與社經文化。希望透過重覆性調查正確掌握林業經營之動態。而有關國有林事業區檢訂調查，為能適時反應國有林事業區可用之森林資源，林務局特別針對國有林地辦理嚴謹的查核、編定作業。該作業每 5 至 10 年檢討更新一次。根據上述三項的調查成果，林務局即辦理圖資更新作業，針對相關圖資如林班基本圖(林班邊界)、森林調查簿(更新屬性資料)...等，進行每5年一次的更新工作。

本計畫依循 2018 年修訂之「森林資源調查暨國有林事業區檢訂土地覆蓋型及航照樣點圖資更新作業手冊」掌握林地土地覆蓋型數化處理原則如下。

1. 當林地面積大於 0.5 公頃、樹冠覆蓋率高達 10%以上，或原生育地林木成熟後(待成林地)符合前述條件者需要數化；面積未達 0.5 公頃者不數化，應納入鄰接且較大面積之土地覆蓋型圖徵。
2. 影像判釋為相同樹種，惟疏密度或冠幅有差異時，因樣點 判釋已有疏密度及冠幅資料，可直接數化為同一圖徵。
3. 相同林型橫跨稜線、溪溝時，可直接以相同林相之邊界數化，不必刻意隨地形區分為不同圖徵。

4. 林型區分標準：(表 6-1)

(1) 針葉樹林型：針葉樹佔林冠面積 80%以上、竹類佔全林冠面積未達 20%者。

(2) 闊葉樹林型：闊葉樹佔林冠面積 80%以上、竹類佔全林冠面積未達 20%者。

(3) 針闊葉樹混淆林型：針、闊葉樹均佔林冠面積 20%以 上、80%以下，且竹類佔全林冠面積未達 20%者。

(4) 竹林：竹類(箭竹除外)佔全林冠面積 80%以上，針、闊葉樹均未達林冠面積 20%者。

(5) 竹闊混淆林：竹類(箭竹除外)佔全林冠面積 20%以上、80%以下，闊葉樹佔林冠面積 20%以上、80%以下者，且針葉樹佔林冠面積未達 20%者。

(6) 竹針混淆林：竹類(箭竹除外)佔全林冠面積 20%以上、80%以下，針葉樹佔林冠面積 20%以上、80%以下，且闊葉樹佔林冠面積未達 20%者。

本計畫基於林務局圖資更新作業所更新之森林林型圖，規劃作為森林物件萃取模型設計之學習目標。並且優先使用農航所常態性航拍任務下的 DMC 航空照片進行模型之訓練，探究其效益與可行性之餘，同時評估提升精度之方法，以利未來於拍攝原始影像後可直接透過模型進行分類作業。

表 6-1 林型區分標準

林型	針葉樹	闊葉樹	竹類
針葉樹林型	80%以上		
闊葉樹林型		80%以上	
針闊葉樹混淆林	20~80%	20~80%	
竹林			80%以上
竹闊混淆林		20~80%	20~80%
竹針混淆林	20~80%		20~80%

(資料來源：森林資源調查暨國有林事業區檢訂土地覆蓋型及航照樣點圖資更新作業手冊)

二、深度學習模型訓練實作標準化作業

為了擺脫巨量影像軟硬體處理之限制，滿足實務運作自動化需求，並透過深度學習方法突破既有的作業分類方法。本計畫透過樹種分類的研究過程，制定標準化作業方法，一方面提升樹種分類精準度，亦大幅提升巨量高解析影像之處裡效率。以下將透過圖資網格化、圖資反投影、數值地形內插、系統性修正，與分類樹種篩選，逐步說明作業流程與標準化方法。

(一)林型圖樣本圖資網格化

本計畫使用農航所提供的原始 DMC 航空照片，與第四次全國森林資源調查之林型圖資向量檔(Shapefile)，以建立具深度學習框架之訓練方式。為了能更加靈活的應用向量多邊形(Polygon)資料所包含的資料屬性特徵，並便於相關作業均能在同一個作業環境下被自動化執行，圖資網格化係為首要工作，將向量平面資訊映射匹配於航空照片網格上，稱之網格化(Rasterize)，並轉以網格資料格式儲存之。平面空間點(Point)、線(Line)、面(Polygon)網格化示意如圖 6-3 所示。轉換過程中應將對應屬性的樹種代碼作為標籤(Labeled)，以利記錄各網格相應

之樹種。作業上，網格結構資料能夠精準的完成樹種屬性之對位，以便提升樹種特徵萃取之效率，並達成深度學習模型建置所需資料之前處裡。

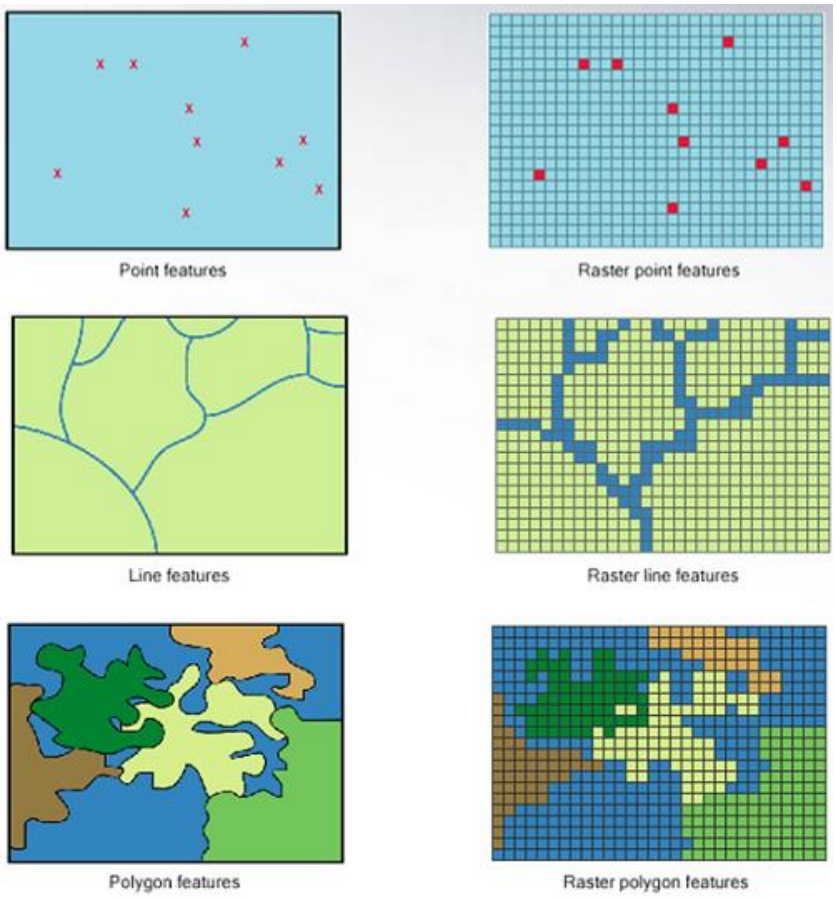

圖 6-3 點線面向量圖層網格化示意圖

(二)樣本圖資反投影

實務上，考量航空照片拍攝時通常並非垂直地面拍攝，但林型圖資的產製，卻是基於正射影像所圈繪的空間紀錄，因此無法直接套疊網格化的圖資與航空照片。為此，本計畫研析反投影方法，參考攝影測量定義之原則，將林型圖資的空間位置反向計算，以取得對應航空照片上的平面位置關係，以利模型

精準訓練。以下針對其計算原理、實作問題與解決辦法分步驟進行說明。

1. **攝影測量共線條件式：**是應用於攝影測量中描述目標點與其相應像點及投影中心三點共線的數學方程式。圖 6-4 顯示真實物空間與相片平面空間之空間關聯性，基於飛機拍攝時所記錄的方位參數，可取得包含相機坐標、攝影機焦距、物空間坐標、地面坐標與旋轉矩陣係數等參數，即可建立所謂的共線條件式。如式 6-1 所示，相關參數名詞與符號對應如表 6-2。

$$x_i = x_0 - f\frac{m_{11}(X_i - X_0) + m_{12}(Y_i - Y_0) + m_{13}(Z_i - Z_0)}{m_{31}(X_i - X_0) + m_{32}(Y_i - Y_0) + m_{33}(Z_i - Z_0)}$$
$$y_i = y_0 - f\frac{m_{21}(X_i - X_0) + m_{22}(Y_i - Y_0) + m_{23}(Z_i - Z_0)}{m_{31}(X_i - X_0) + m_{32}(Y_i - Y_0) + m_{33}(Z_i - Z_0)}$$

式 6-1

2. **數值地形空間反投影：**為正確反映林型圖在航空照片之位置，本計畫考慮使用數值高程模型(DEM)的高程資訊，為林型圖帶上空間高程屬性，然後再透過共線條件式完成反投影的數學關係式計算，其案例結果如圖 6-5 所示，同一個樹種範圍(紅框)，在正射影像(左圖)與航空照片(右圖)，顯示出反投影後造成的圖框變形。
3. **反投影圖框交叉變形：**在林型圖資尚未網格化前，就進行反投影測試，發現許多原先為封閉向量的圖框，受資料遮蔽與投影變形之影響，反投影後出現在相片上同一位置，或是位置相反，導致出現變形甚至圖框邊界交叉的現象。實際探究投影過程發現，航空照片拍攝視角多半不與地面垂直，當遭遇地形起伏，出現背坡、陰影或是攝影死角時，這些位置資訊就無法被記錄在像空間上。如圖 6-6 所示意，攝影機鏡頭

位置 O 點，理論上需紀錄地面上同一直線下的 A 點、B 點、C 點、D 點與 E 點於影像上的 P 點成像，但實際上影像只能對距離最近的 A 點記錄成像。基於此原因產生向量圖框交叉，導致反投影計算結果與 GIS 的 Polygon 拓樸相違背。

4. **反投影像空間圖框修正：**為解決圖框交叉的問題，應考慮光線直線前進的特性，在同一個像空間位置上，除了距離鏡頭最近的面坡處被記錄下來，其餘背坡處資訊應被捨棄。實作上，即利用相機物空間位置與地面被記錄的點位進行距離計算，投影線上距離最近的點位屬於有效資訊將被保留下來。如圖 6-7 的林型圖資案例所示，橘色框線為反投影後回到照片像空間的林型圖圖框，原先的封閉曲線在經過反投影計算後遭到扭曲變形，無法形成一個完整圖框；藍色框線為經過修正後之反投影林型圖圖框，可明顯察覺兩者差異。而修正方法為將向量圖框網格化。圖框網格化反投影示意如圖 6-8，向量圖框反投影(左圖)意指林型圖框投影至航攝影像上，網格化圖框反投影(右圖)則是將向量圖框網格化後再投影至航攝影像上，透過將向量圖框網格化，修正反投影圖框交叉之問題。修正案例結果如圖 6-9 所示，修正前(左圖)與修正後(右圖)比較可見圖框更加完整合理，原先圖框交叉的地方基本上都已改正。

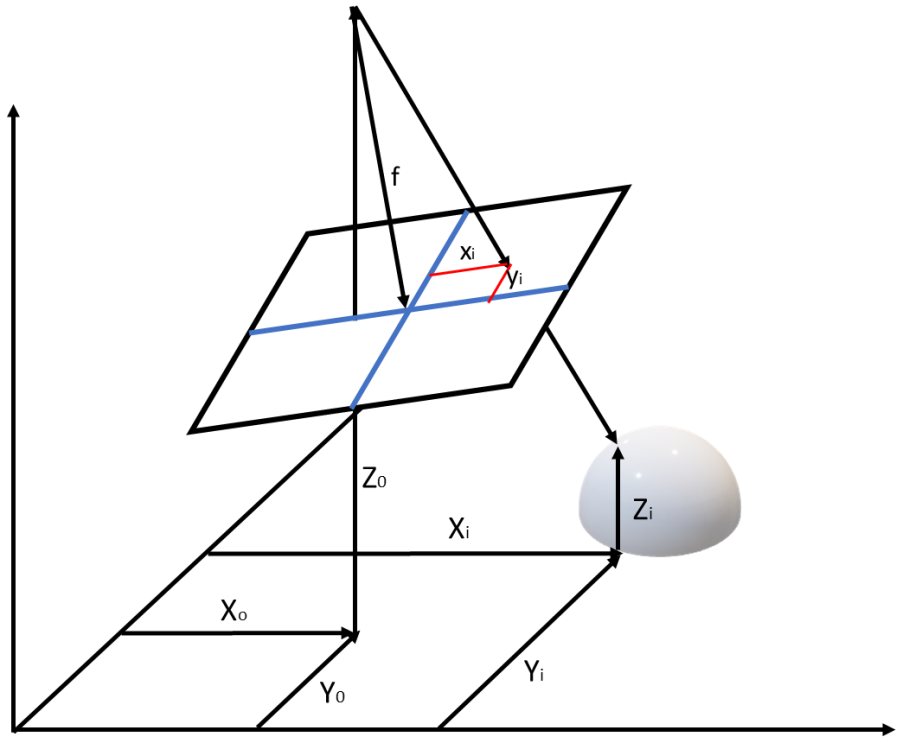

圖 6-4 物空間與相片平面之對應關係

表 6-2 共線條件式參數符號對照

參數	參數名稱
x_0, y_0	像主點的像平面坐標
x_i, y_i	相片上任意點 i 的像平面坐標
f	攝影機焦距
X_0, Y_0, Z_0	投影中心的物空間坐標
X_i, Y_i, Z_i	相片上任意點 i 在物空間的三維坐標
m_{11}~m_{33}	三維旋轉矩陣的乘積

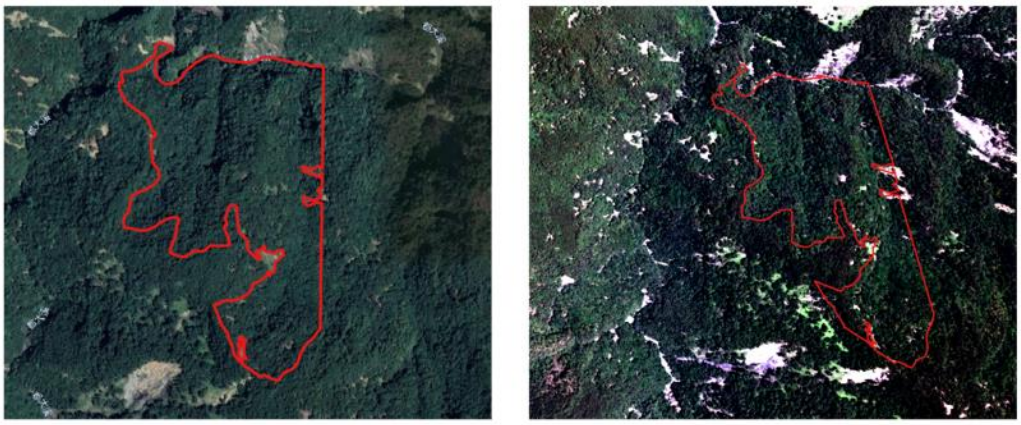

圖 6-5 林型圖圖資反投影前後差異

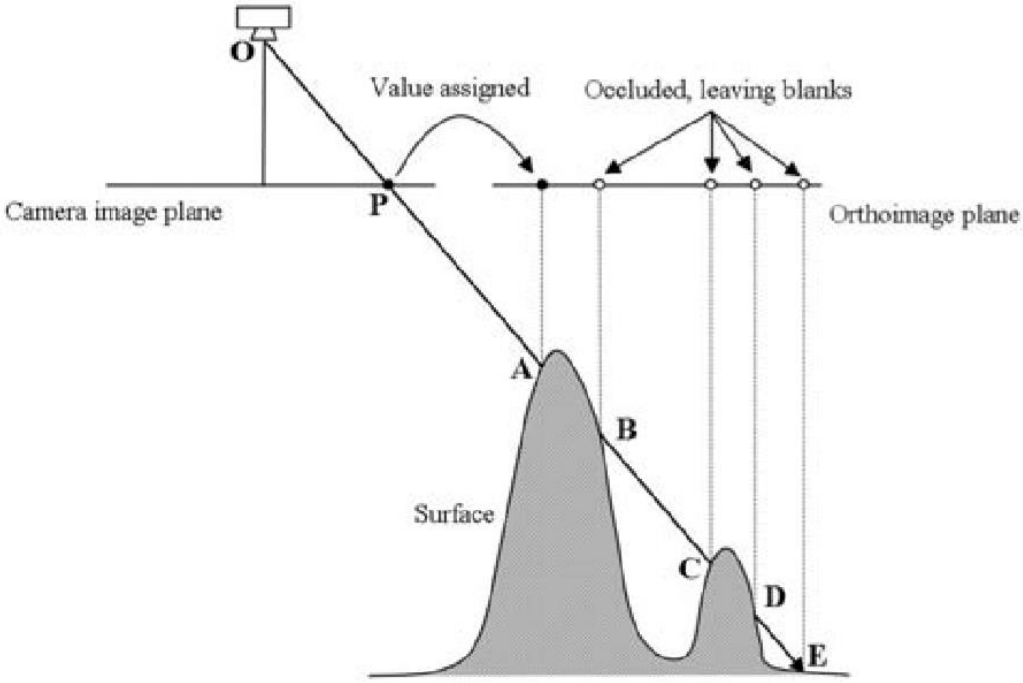

圖 6-6 反投影背坡處空間交會(Sheng et al., 2003)

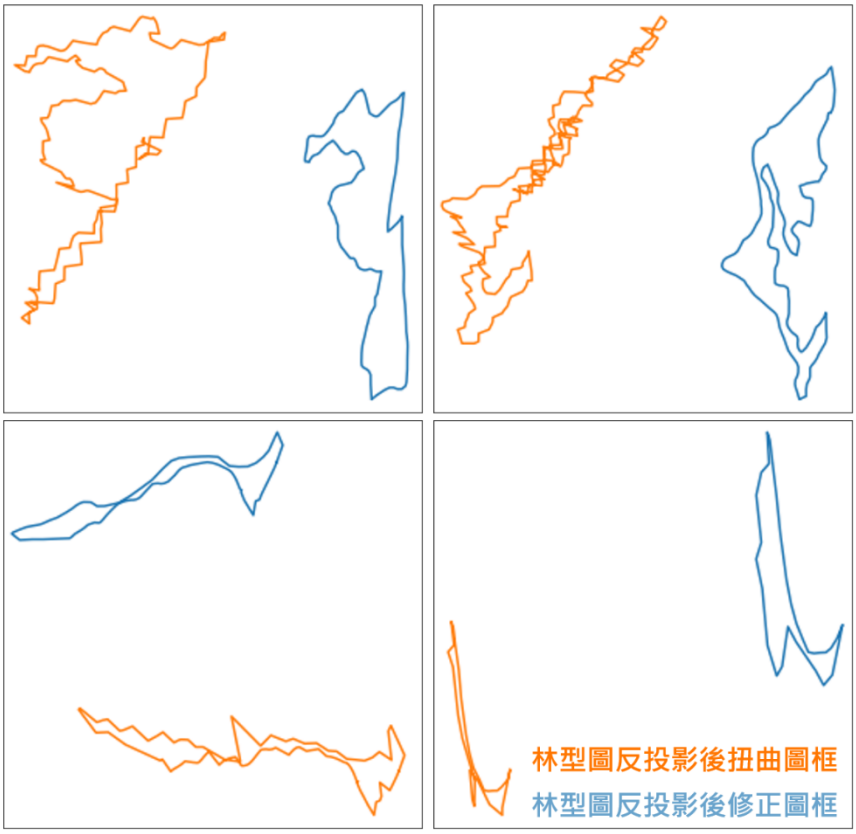

圖 6-7 林型圖圖資反投影後圖框交叉扭曲個案情況

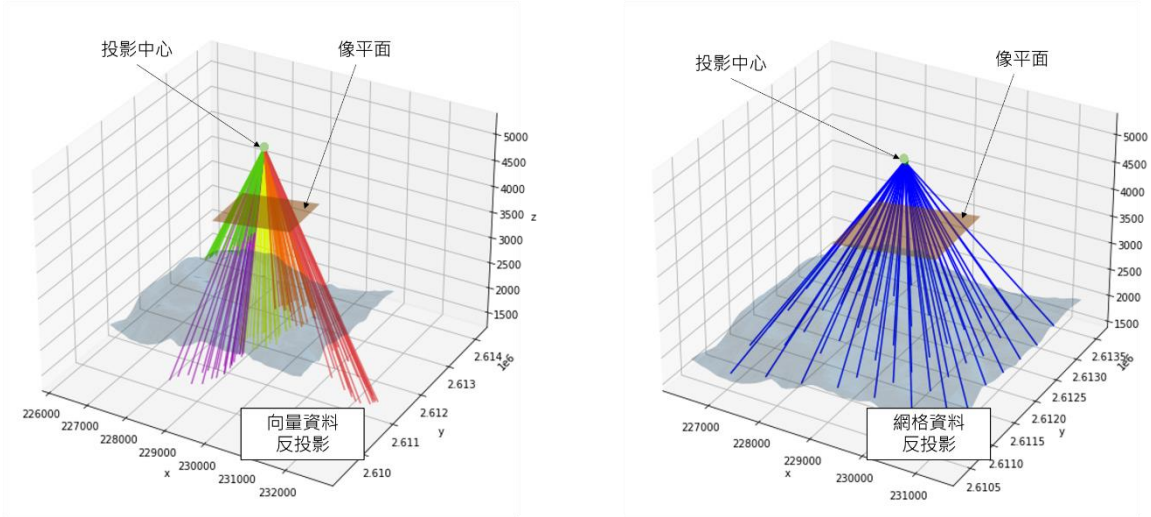

圖 6-8 圖框網格化反投影示意圖

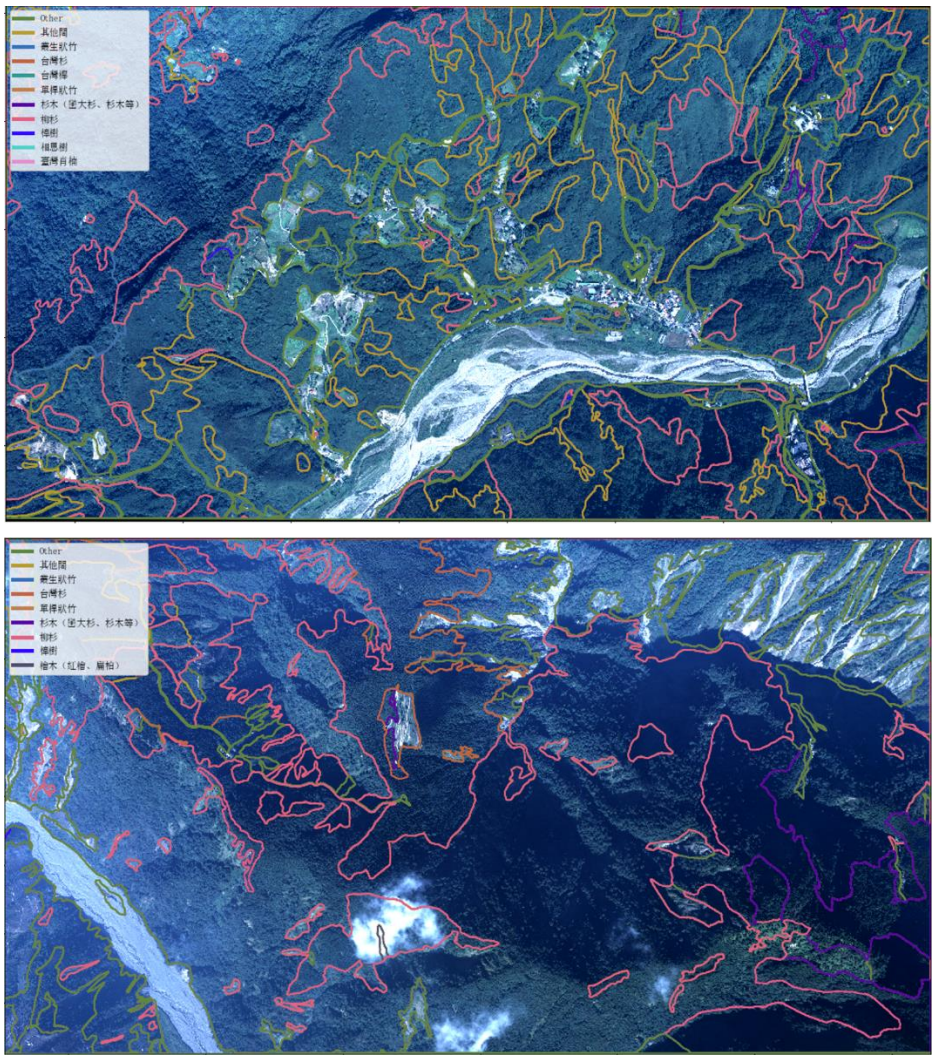

圖 6-9 林型圖圖框交叉扭曲修正後結果

(三)內插補值與投影系統性修正

本計畫使用 20 公尺空間解析度之 DEM 進行林型圖反投影，但由於航空照片(0.5 公尺)與 DEM 空間解析度差異太大，致使像空間的投影結果產生許多不連續的空隙間距，如圖 6-10 所示。為了改善此問題，將 20 公尺空間解析度之 DEM 以三次內插方法(Cubic Interpolation)內插，致使高程資訊平滑化以縮減不連續空隙之間距，其成果如圖 6-11 所示。

然而實際完成影像對位後，仍存在對位偏移之問題，經測試可能係由航攝任務所紀錄之航高誤差，或因使用 DEM 而忽略

了樹冠高度所致。如圖 6-12 所示，綠色範圍為反投影後之結果，套疊航空照片後發現顯著的系統性偏差，而且偏移的距離隨著拍攝中心距離越遠越顯著。對此，為顧及分類模型訓練之進度，使用緩衝範圍的概念，考量縮減圖框是為了解決偏移問題，而偏移主要是受到樹高所影響，故今年度先以定值縮減圖框範圍以確保圖框內均為正確的訓練目標樹種，而台灣樹種平均高度約為 25 公尺，經過不同內縮範圍測試，包含 0、10、20 與 30 公尺(圖 6-13)，最終以選定 25 公尺內縮最為合適。

至此，通過上述步驟流程完成航空照片與林型圖純林樹種對位之訓練資料前處理工作，同時自動化的流程操作程式也在分析過程中一併完成，以其接續進行深度學習模型之訓練。

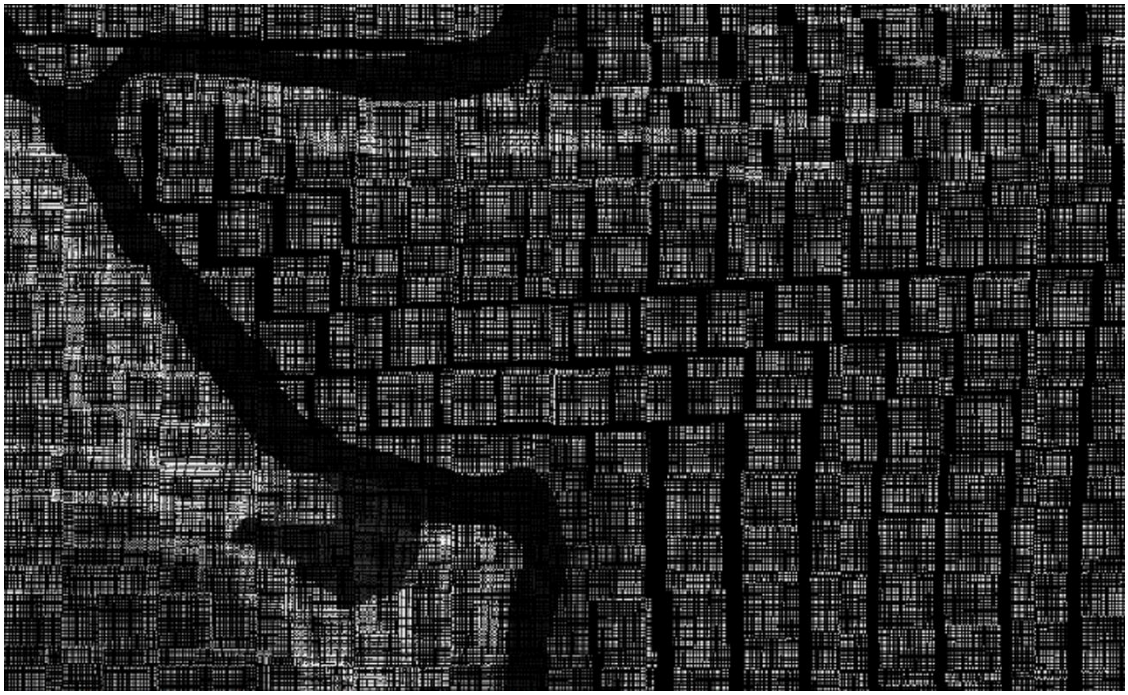

圖 6-10 不同空間解析度導致反投影後空缺差異

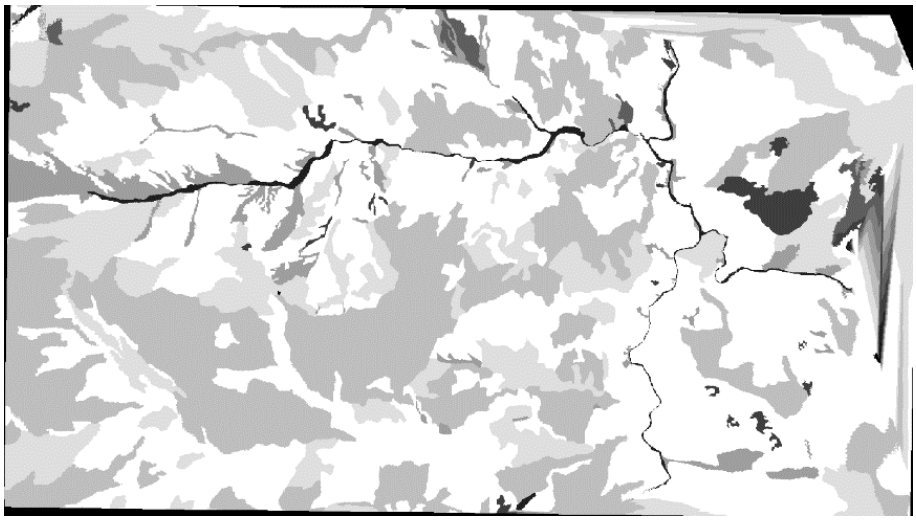

圖 6-11 以內插補值方法填補網格內所有林型圖純林樹種

圖 6-12 林型圖純林樹種反投影成果與航空照片之套疊

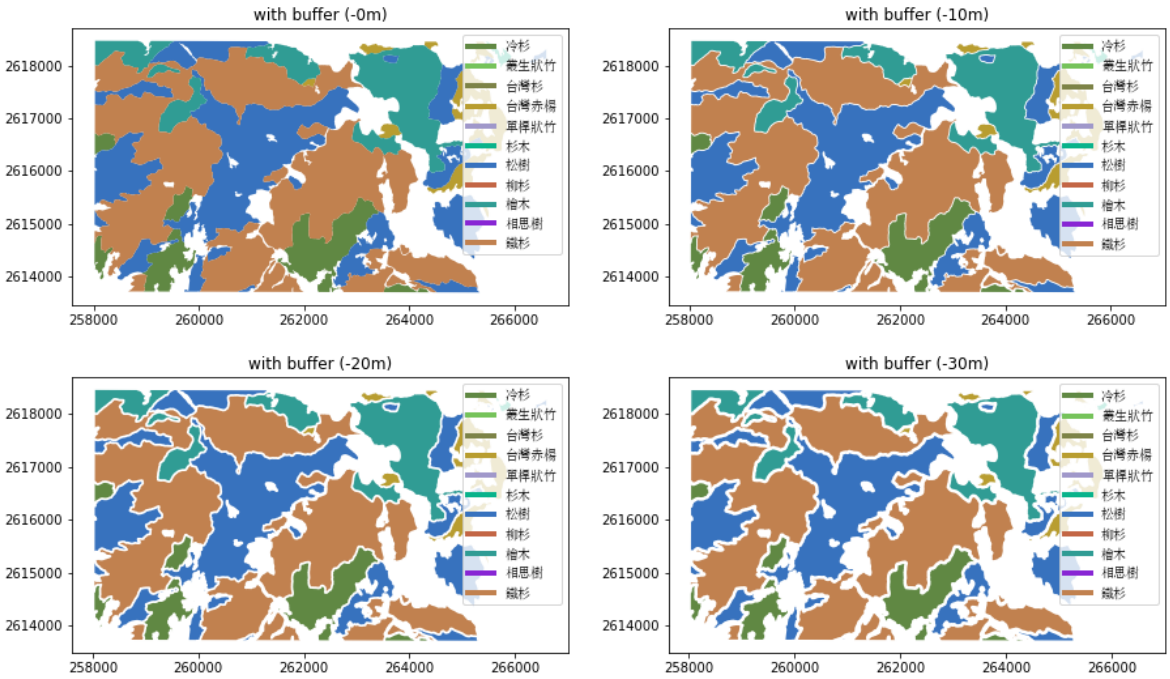

圖 6-13 測試不同內縮範圍以修正系統性對位偏差

(四)分類樹種篩選

考量現行已可利用衛星影像判釋林型圖資之第二層分類已有較佳之成果，同時為了確保樹種分類深度學習模型能夠有效的實作，具體提升既有的樹種判釋作業，本計畫優先選擇外型比較容易辨識的樹種，做為今年度主要的分類目標，在貴所與計畫顧問的建議下彙整樹種清單如表 6-3，包含針葉林種 8 種、闊葉林種 7 種與竹類 2 種。為了確保訓練成效符合需求，進一步由林型圖純林樹種內統計各樹種圖框(polygon)數量與平均面積，以單一類別資料總量和實際面積，再一次地篩選合適的訓練樹種，如表 6-4 所示，最終選擇 11 項樹種包含針葉林種 7 種，包含檜木(紅檜、扁柏)、松樹(二葉松、五葉松等)、杉木(巒大杉、杉木等)、台灣杉、柳杉、鐵杉、冷杉；闊葉林種 2 種，包含相思樹與台灣赤楊；竹類 2 種，包含叢生狀竹與單桿狀竹。最終配合航攝影像圖幅完成反投影資料標記，如圖 6-14 所示。

(五)訓練指標特徵產製

本計畫基於資料蒐集成果，選定訓練目標樹種，裁切訓練資料，並建立 11 項訓練資料特徵參數，如圖 6-15 所示，包含可見光影像中的紅光(Red)、綠光(Green)、藍光(Blue)、近紅外光(NIR)、常態化差值植生指標(NDVI)、數值高程模型(DEM)、坡度(Slope)、坡向(Aspect)、粗糙度(Roughness)、地形位置指數(TPI)、地形堅固指數(TRI)，至此完成所有影像套疊前處理，並再接續章節說明資料訓練之流程，各項特徵參數與標記圖框反投影於航攝影像之案例，如圖 6-16 所示。

表 6-3 林型圖純林樹種清單

類別	樹種
針葉林種	冷杉、鐵杉、檜木(紅檜、扁柏)、台灣杉、杉木(巒大杉、杉木等)、臺灣肖楠、柳杉、松樹(二葉松、五葉松等)
闊葉林種	相思樹、大葉桃花心木、台灣赤楊、銀合歡、光臘樹、台灣櫸、木油桐
竹類	單桿狀竹、叢生狀竹

表 6-4 取得之林型圖純林樹種內各樹種圖框涵蓋數量與平均面積

類別	樹種	林型圖 樹種圖框數量	平均面積 (平方公尺)
針葉林種	*松樹(二葉松、五葉松等)	13,529	66,059.73
	*柳杉	9,983	31,230.37
	*冷杉	5,930	46,873.66
	*鐵杉	11,217	68,445.88
	*檜木(紅檜、扁柏)	6,966	65,864.47
	*杉木(巒大杉、杉木等)	3,888	21,107.04
	臺灣肖楠	1,872	5,902.44
	*台灣杉	1,076	39,975.24
闊葉林種	*台灣赤楊	1,037	46,519.48
	*相思樹	593	49,683.74
	光臘樹	48	100,245.54
	大葉桃花心木	16	16,259.45
	台灣櫸	64	42,482.11
	木油桐	70	19,964.02
	銀合歡	1	184,389.24
竹類	*叢生狀竹	36,399	16,864.43
	*單桿狀竹	20,160	17,960.75
*註：本計畫選定之目標分類樹種			

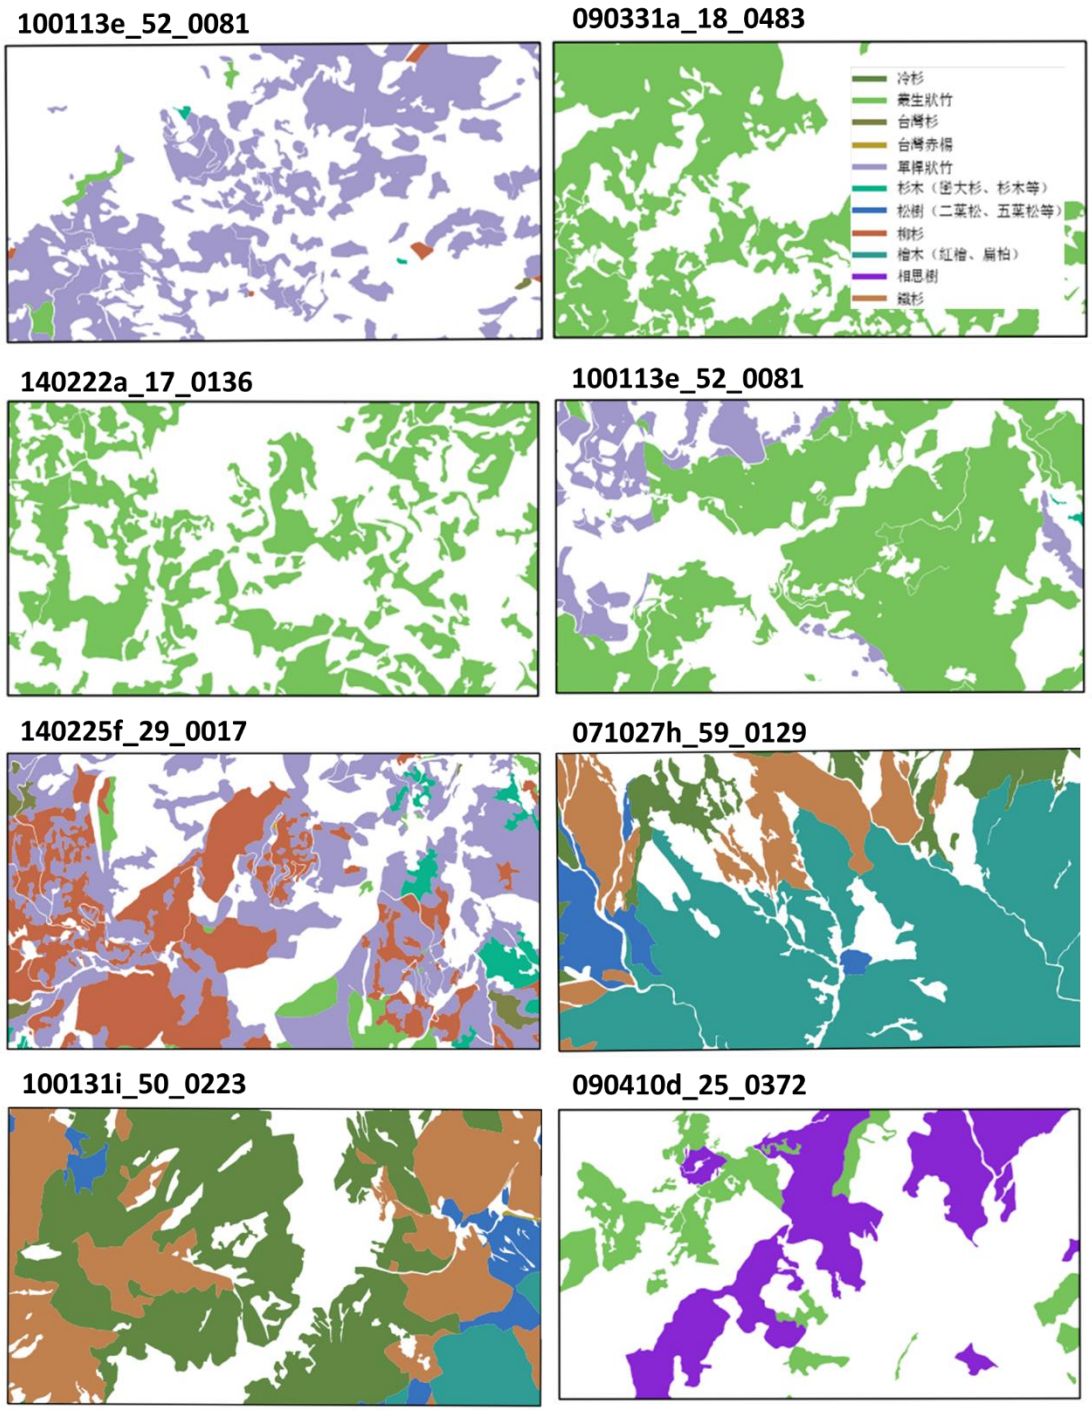

圖 6-14 標記樹種於航攝影像之分類案例

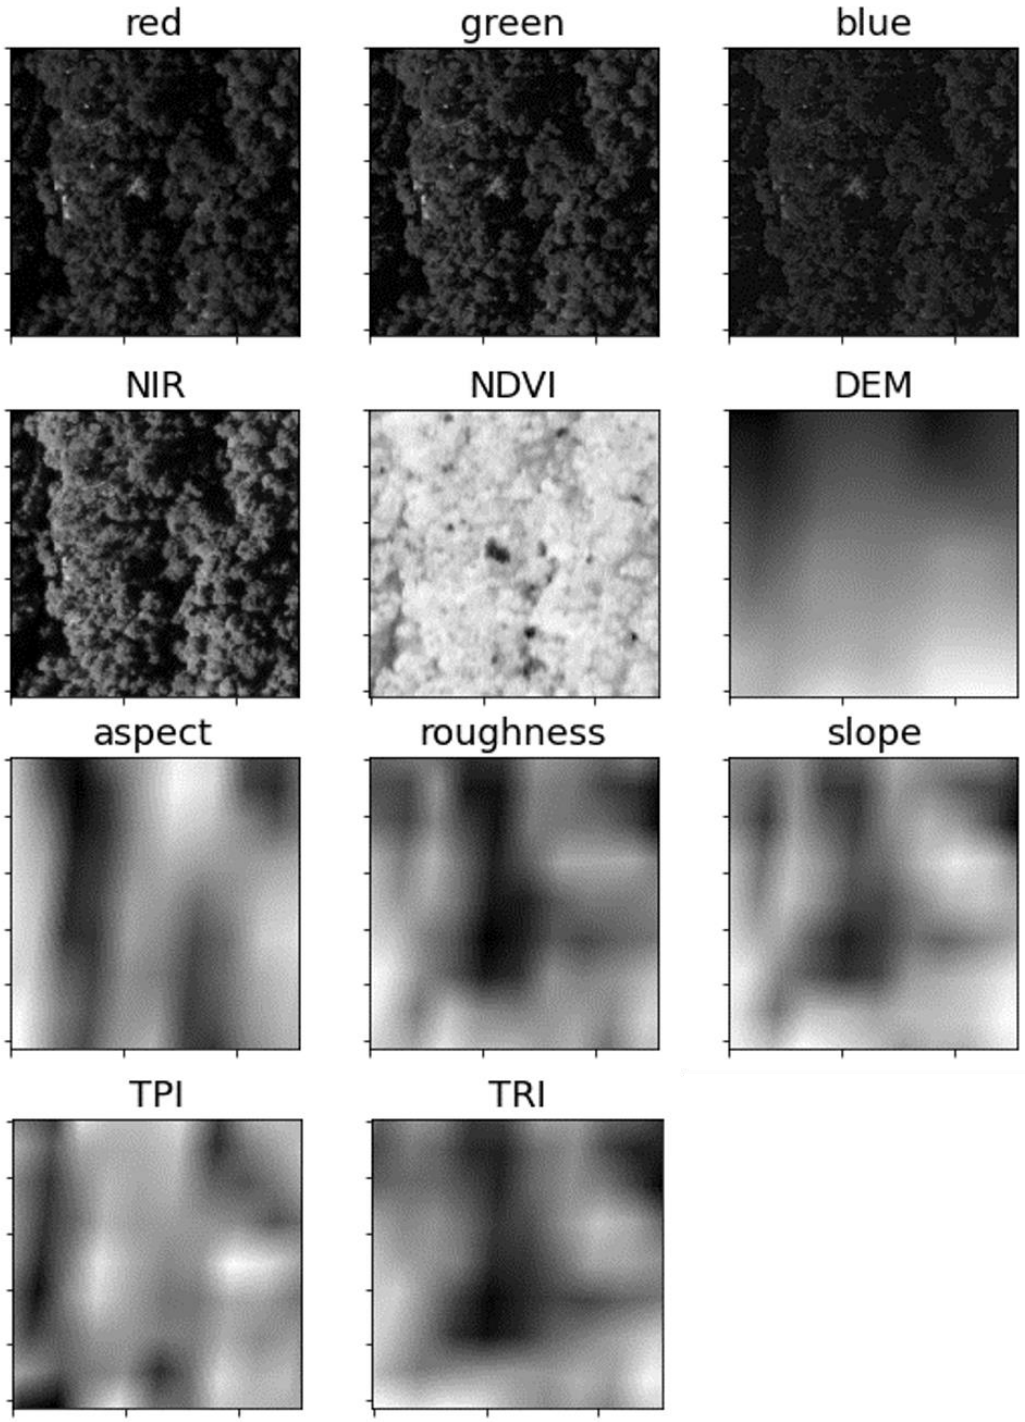

圖 6-15 本計畫使用之 11 項參數特徵案例

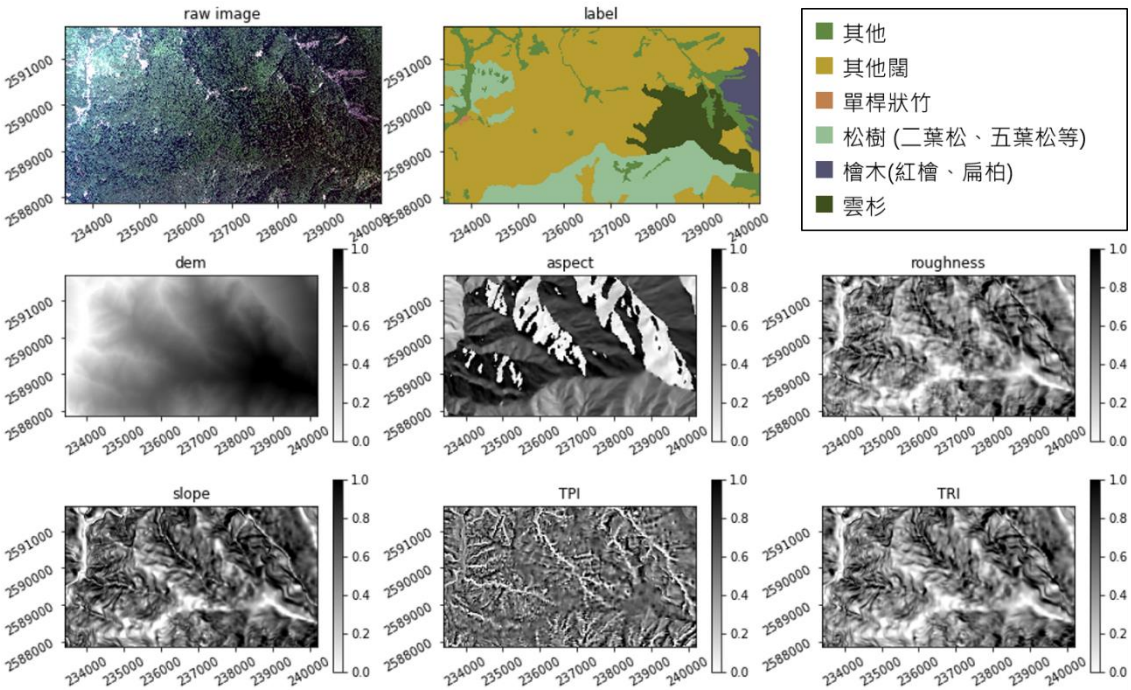

圖 6-16 各項特徵參數與標記圖框反投影於航攝影像之案例

三、森林物件特徵萃取經驗

本計畫將參考林務局已經完成的林班基本圖與森林調查簿，建立森林物件特徵。一般航攝影像分類萃取之影像因子特性繁多，包括色調、顏色、紋理、大小、形狀、組織、圖案、高度、陰影、立地、關聯物...等因子。這些特性某種程度反映森林林木生長之特性，例如樹冠的輪廓、邊緣、表面、數量、尺寸，冠層的通透、樹梢、深度、層次，或者是相鄰樹木之排列、葉層質地...等。因此，了解這些影像因子將有助於深度學習模型設計上，透過參數條件的設定以萃取正確有用的分類特徵。各項因子說明如下。

1. **色調與顏色(Tone/Color)：**目標物件之成像特性。通常吸收光線愈多者，影像色調則愈深，吸收光線少，而反射多者，則其色調必淡。如紅檜呈現紅褐色樹冠。如圖 6-17 所示，針葉林與其周圍闊葉林在近紅外光影像中的顯著差異。

2. **大小(Size)**：目標物件之幾何形態。照片上影像外表面積之大小，亦為識別重要因素之一。例如量取樹冠大小(寬度)，即易予區別。因此判釋時應注意照片比例尺，以免發生錯誤之判斷。
3. **形狀(Shape)**：目標物件之輪廓。形狀為判斷物體的重要依據如針葉樹之樹冠多呈圓錐形、灌叢通常樹冠呈半球型貼於地面。且因航照圖有拍攝角度的影響，所以在實際判釋影像時，須留意是否需要旋轉影像以利判讀，範例如圖 6-18。
4. **紋理(Texture)**：或稱組織，根據影像表面結構之粗細，可識別物體之類別組織為判釋林木最重要之依據，如密生幼林為細組織，過老林木為粗糙組織，針葉樹為較細組織，闊葉樹為粗狀組織。
5. **圖案(Pattern)**：目標物件於空間中之排列情形。目標物件群體之綜合表徵。所有照片上顯示之地物排列情形，均由人為或自然因素使然，人為地物之排列，其型態多有規則，在照片上容易辨別，如林業人員由林木排列情形可知是否為造林地，如人工林樹冠整齊畫一，範例如圖 6-19。
6. **陰影(Shadow)**：輔助辨認目標物件本體之特性，容易以其蔭影形狀區別。並可由其陰影之長度測出物體之高度。但陰影的缺點為遮掩了許多地物的影像，範例如圖 6-20。
7. **立地(Site)**：目標物件所處之環境狀態。立地環境在照片判釋上佔極重要之地位，因林木受立地因子影響而限制分佈，如針葉樹大多出現在較高海拔地區。
8. **關聯物(Related Object)**：目標物件所伴隨出現之其他物件。大多數物體附近有一些與它相關的地物同時存在，以協助辨認，如伴生植物等。

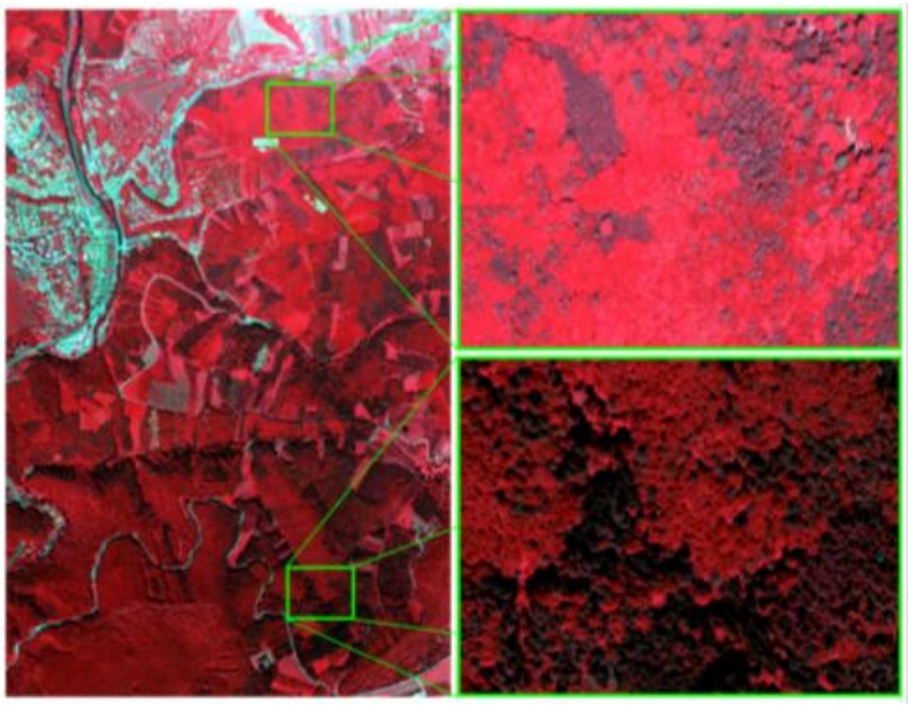

圖 6-17 樹木色調與顏色範例(Machala, 2014)

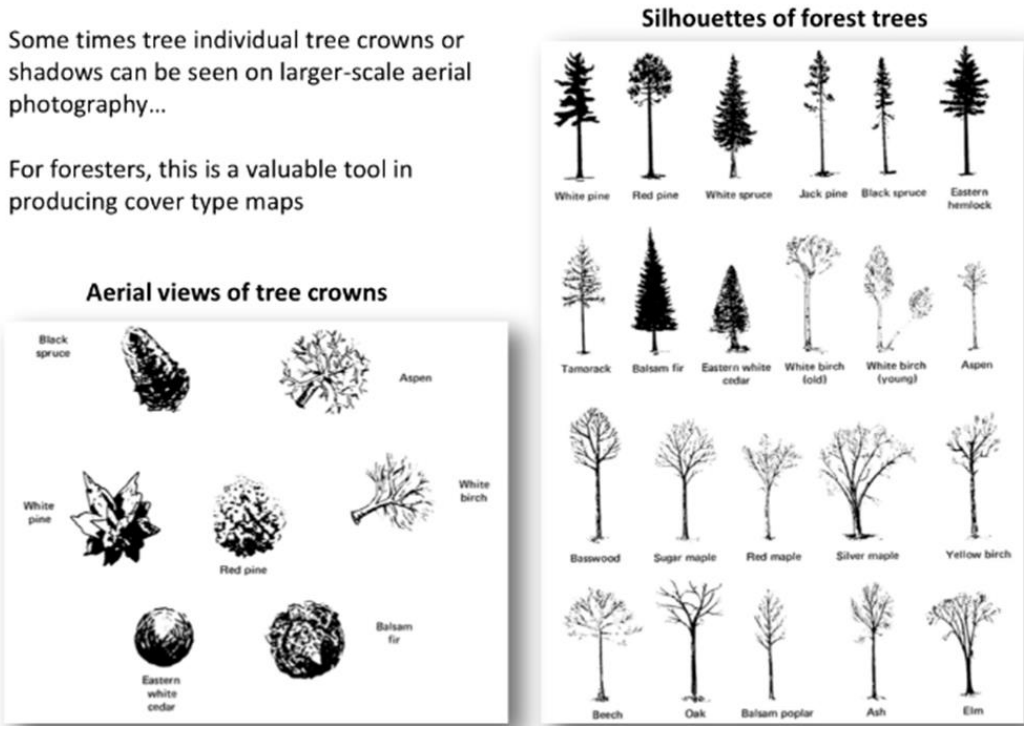

圖 6-18 樹冠形狀範例(Avery, 1978)

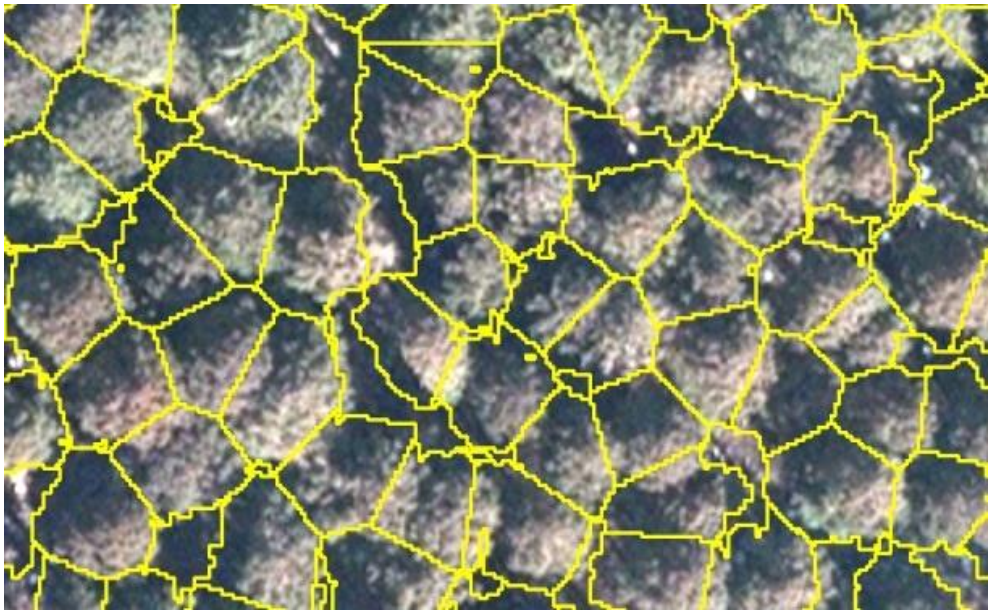

圖 6-19 樹木圖案範例

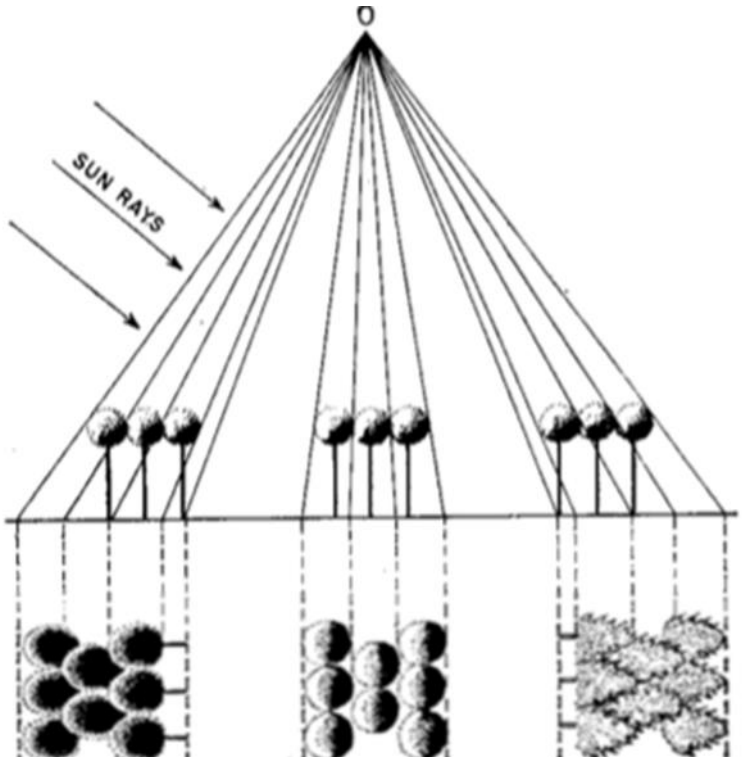

圖 6-20 樹木陰影範例

6-2 機器學習模型訓練、判釋與更新之流程

機器學習與深度學習模型實務運作上主要有兩個情境：訓練情境與判釋情境，未來在更新訓練資料或新增分類類別的需求下，還會增加更新模型的情境。

在訓練情境下，需要給定模型判斷所需之影像資料，本計畫優先使用農航所航拍任務取得之 DMC 航空照片。另外配合需要學習的正確答案，也就是第四次森林資源調查工作中更新的林型圖林地分類成果，經過前述的圖資套疊前處理後標記於航攝影像上。接續，訓練模型會透過權重進行配分，尋找最佳化的運算結果，直到模型配分不再進步，或者已經達到可接受的分數或成效。接著進入判釋情境，僅需透過已經訓練好的權重對圖像進行辨識。若要使用新資料重新訓練，則無需經過再行調整模型的超參數，使用現有的模型設定進行新資料的訓練即可。

綜合來說，上述情境可能會經歷的流程包含影像前處理與專家品管、訓練與測試資料集的切分、模型建構及超參數調整、模型預測與圖像後處理、模型評價，以及最後的模型部署。表 6-5 詳述了每種情境會經歷的環節，以下亦逐一說明各環節之操作流程。

表 6-5 操作情境對照表

	訓練流程	判釋流程	模型更新
影像前處理-影像遮蔽	O		O
影像前處理-影像切片	O	O	O
影像前處理-影像篩選	O		O
影像前處理-資料增強	O		O
訓練與測試資料集切分	O		O
模型建構與訓練	O		O
超參數調整與更新	O		
模型預測與圖像後處理	O	O	O
模型評價與驗證	O		O
深度學習模型部署	O		O

(資料來源：本計畫彙整)

一、影像前處理與訓練資料品管

影像前處理主要目的是，讓航空照片被轉換為一般深度學習可以接受的資料型態，並盡可能幫助模型取得較佳的學習成效。以下將分為影像遮蔽、影像切片、影像篩選與資料增強四個步驟進行介紹。

(一)影像遮蔽

由於一張影像並非所有部分都有進入標記範圍，同時也並非所有影像的區域皆包含標的物件，因此這些資料必須要在進行其他前處理步驟前先遮蔽掉。舉例來說，圖 6-21 中，右上半部的資料沒有標註，便可以透過圖層遮蔽掉，以避免模型錯誤學習。

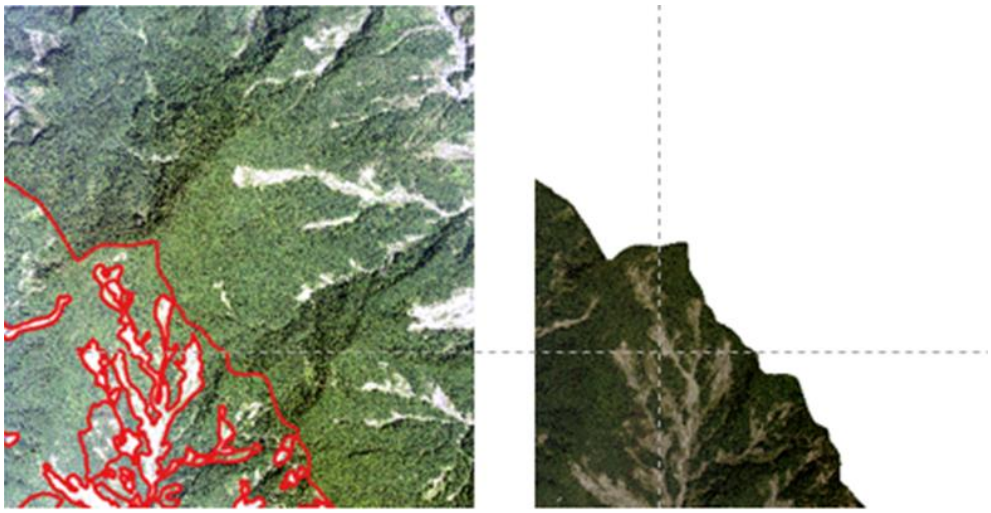

圖 6-21 影像遮蔽

(二)影像切片

由於航空照片與一般影像不同，其大小可超過一萬平方個像素，與一般相片約上百平方個像素，可說是非常大。此外，航空照片的取得成本也都較高，因此也相較一般影像來的稀少。一般 AI 模型皆是為了一般影像的設計，因此無論是「輸入大小的限制」或是「足夠的訓練資料量」的考量，都需先將遙測影像轉換為較少像素後，方能透過既有的 AI 模型訓練，並進行滾動式修正。

要達到這個目的最簡單的方法便是「影像切片」，一方面影像的大小可以變小，另一方面也可創造足夠量的訓練資料量。如圖 6-22 所示，便是使用 512×512 的窗格對將一張 11461×12261 的遙測影像進行切割，如此一來便能將一張航攝影像切割成至少 522 張影像，如果訓練成效依舊不佳的話，亦可以讓切割窗格相互重疊以創造出更多的訓練資料。

切割大小與張數多寡仍須看影像的解析度而定，由於本次所使用之影像空間解析度為 0.25 公尺，切割成 512×512 像素大小時，每張影像實際邊長為 128 公尺，足夠以人眼直接辨識，農航

所專業人員也能夠辨識出圖中樹種為何，因此本研究以 512×512 像素作為裁切樣本的單位。

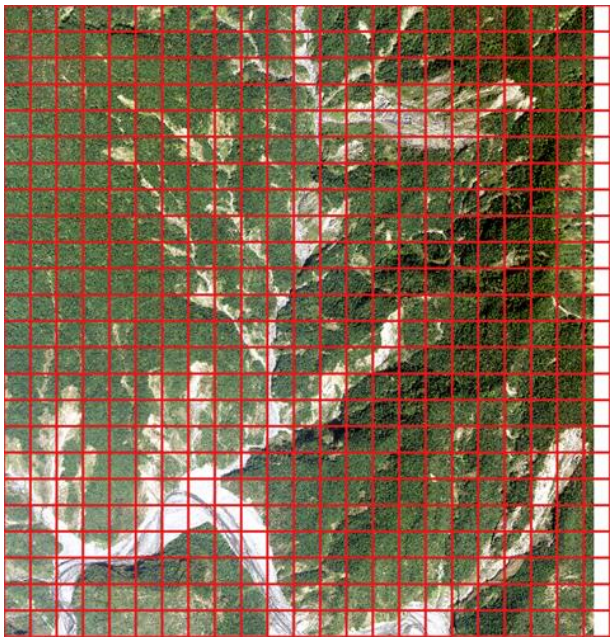

圖 6-22 影像切片示意圖

(三)影像篩選

該環節需進一步對已經切割的影像進行篩選，以盡可能避免多種分類同時出現在同一幅切割完的影像單元中，依循過往分類模型設計之經驗，本計畫目前優先使用 50%的門檻，作為單一類別篩選之原則。最終，考量訓練資料之品質將視情況變更門檻，或以遮罩的方式編修影像單元後再放入模型。

(四)資料增強

在資料科學領域中常透過資料增強(Data Augmentation)來增加訓練資料。由於航空照片在物件辨識上，大多時候無需考量方向性，也就是說即便樹木或森林旋轉了 180 度在影像上仍是一個正常的樹木或森林，且航高並非完全一致，因此可以透過照片翻轉旋轉放大縮小的手法來創造訓練資料。以圖 6-23 為例，

同時將輸入圖像與標記圖像透過旋轉與放大縮小，便可將訓練資料增加為原本的數倍。

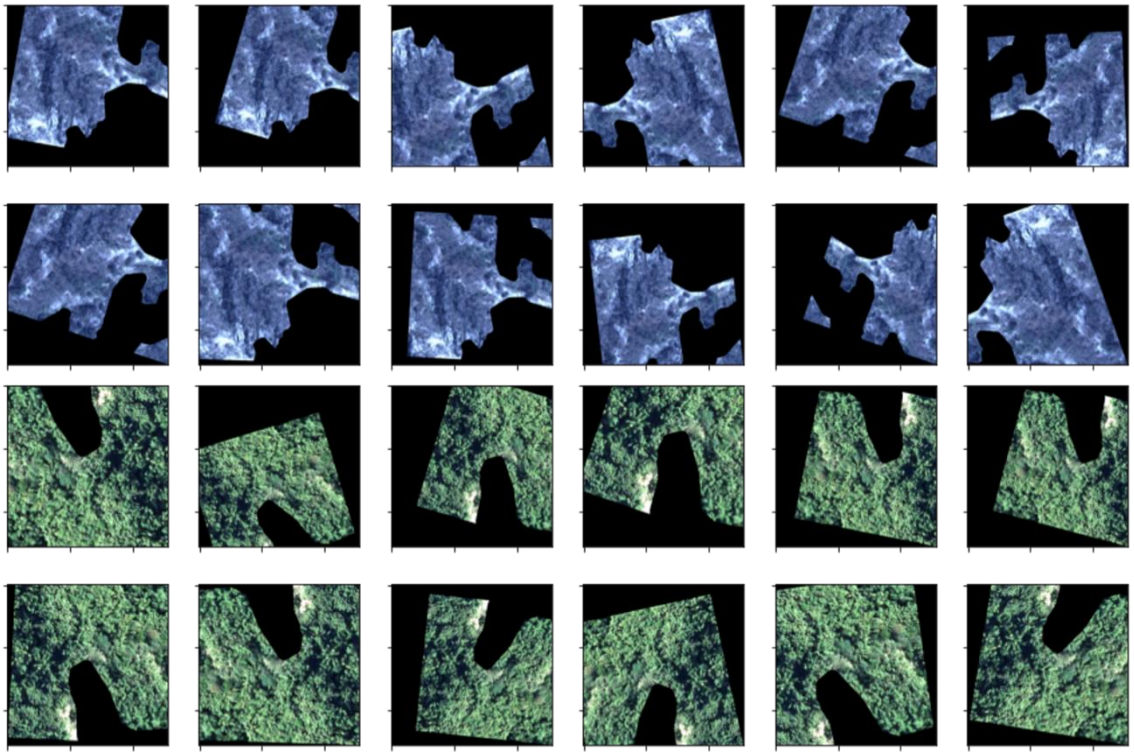

圖 6-23 資料增強示意圖

本計畫針對 11 項樹種對應之 718 幅航攝影像，進行資料裁切並建立訓練資料集，裁切的方式係採用 512×512 像素(pixels)大小視窗，在影像上移動切圖，每移動 256 pixels 切一幅。若該視窗內有包含一半以上之樹種，即保留該切圖，同時將非屬於該樹種之資訊以遮罩去除。各樹種資料統計如圖 6-24 所示，其中以松樹資料佔最大宗、鐵杉居次，資料均超過 50,000 筆；而相思樹、台灣赤楊、台灣杉，以及杉木資料相對缺少，不達 10,000 筆，顯示樹種比例不均的情況，隨機挑選裁切後的樣本資料呈現於圖 6-25。實際而言，訓練資料之品管在影像前處理工作中亦佔有相當重要的角色，本計畫同時配合執行團隊之一的宜蘭大學，建立航空照片品管工作，藉由森林資源專業背景確認訓

練用的航空照片之正確性，品管內容包含航攝影像品質確認、標記資料正確性與影像對位之合理性等，以確保後續訓練流程之順暢與符合實務需求。

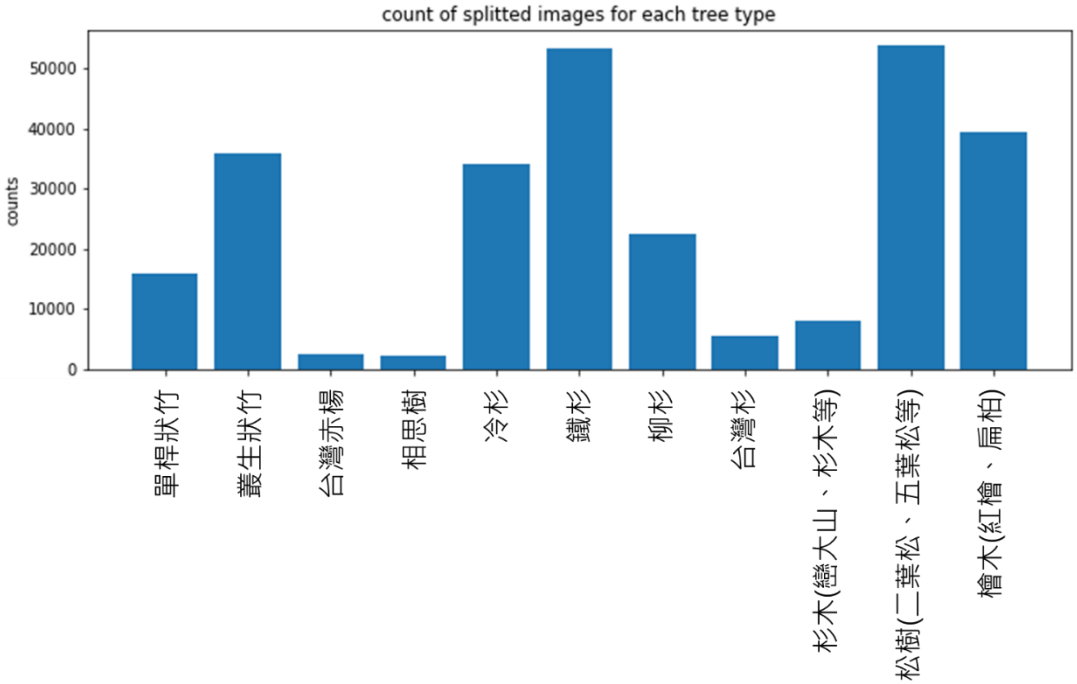

圖 6-24 各樹種切圖完成後之張數統計

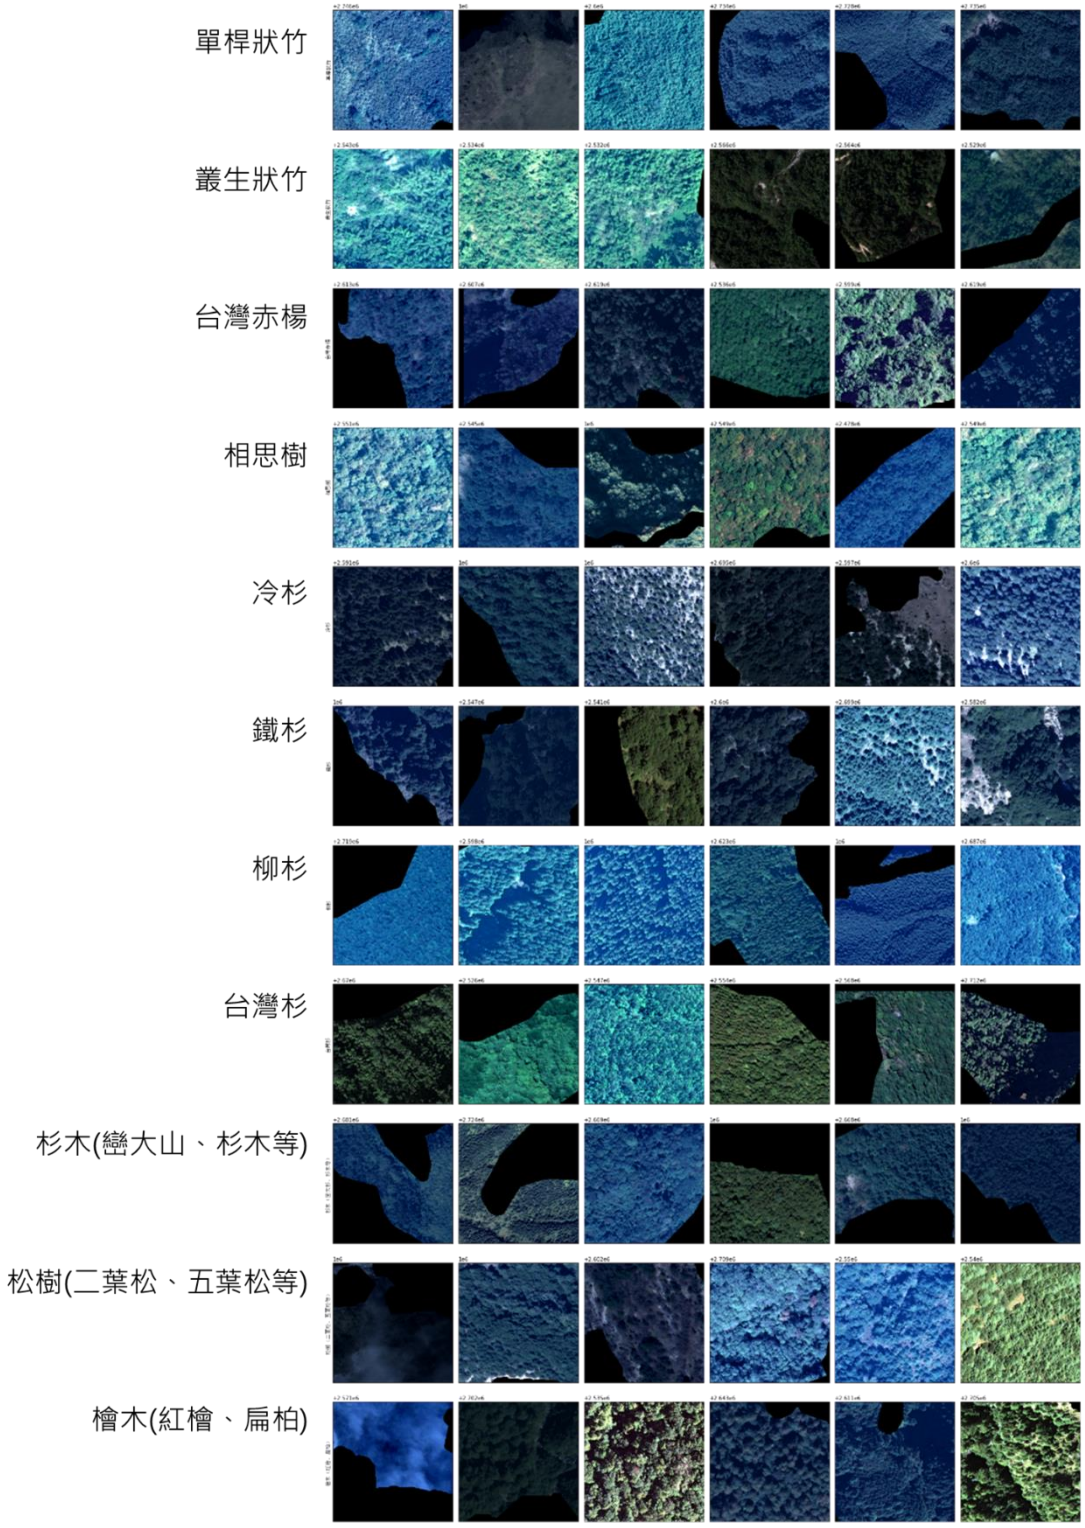

圖 6-25 11 類樹種影像裁切之訓練樣本案例

二、訓練與測試資料集切分

訓練與測試資料集切分為兩組，主要是希望可以確保模型不僅適用於模型看過的資料集，對於訓練中沒看過的資料集依舊可以推廣使用，如此方能確保模型不會過度擬合，並可以被使用在未來的航攝影像中。

本計畫切分時將考量到資料筆數比例與資料不平衡比例。資料筆數必須盡可能的確保最大量的訓練資料，以及足夠量的測試資料，根據吳恩達 Coursera 上 Deep Learning.ai 課程中 Improving Deep Neural Networks: Hyperparameter tuning, Regularization and Optimization 課程的 Train / Dev / Test sets 章節中提到，慣例上會採用三比七的比例切分測試資料與訓練資料。舉例來說，如圖 6-26 所示，下面經過篩選總共有 22 可用的航照影像，共挑出了 8 張影像做為測試資料(紅色框)，不放入模型進行訓練，最後若模型能在這些測試資料上有較佳的表現，代表模型具有可推廣性，也適用於未來其他未使用於訓練的航照影像。

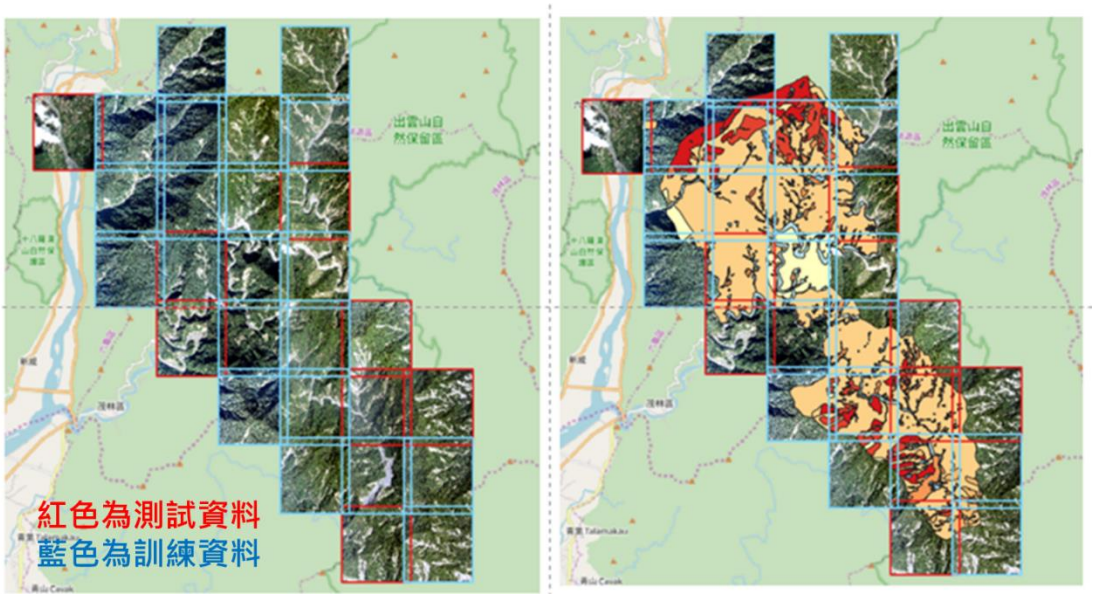

圖 6-26 資料集切分示意圖

三、模型建構與訓練

本計畫主要建構 CNN 與 DNN 混合模型。如圖 6-27 說明，首先由 CNN 模型作為萃取圖像特徵的工具，其深度取決於圖像的複雜度，由於本計畫擬將萃取色調與顏色、紋理、大小、形狀、組織、圖案...等細節特徵，因此 3~5 層左右的 CNN 便可萃取出重要的特徵向量。進入 DNN 階段，由於需將特徵向量依樹種進行分類，因此須注意輸出等同於樹種數量的向量，便可完成模型之建構，即 CNN 為萃取特徵向量為主，DNN 依據特徵向量進行樹種分類作業。

最初的模型設計上，本研究將 11 個因子都設為等權，但成效不佳；考量到因子主要為光譜資訊與地形資訊，又坡向的值為 0 到 360，和其他因子不大相同，故將學習因子分為 R、G、B、NIR、NDVI；DEM、坡度、粗糙度、TPI、TRI；坡向三類。而在隱藏層設計上，剛開始規劃為 5 個卷積層與 2 個池化層，但會導致模型過於複雜而過度擬合，在不斷測試後，最終改為 3 個卷積層與 4 個池化層(如圖 6-28 所示)，所得成果為最佳。

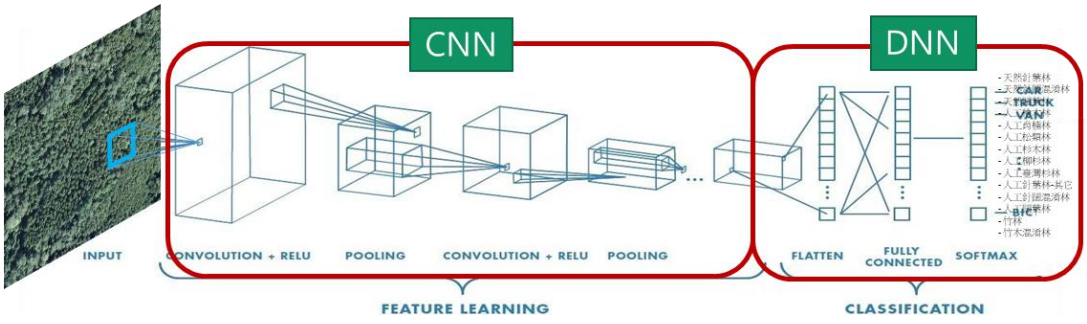

圖 6-27 模型建構與訓練說明

四、超參數調整與更新

超參數(Hyper Parameter)調整由於深度學習模型理論上已經學會如何自動化透過正確答案學習出適合的權重分配，所以基本上這些權重是不需要人工調整的。因此所謂的超參數調整的其實是判釋模型學習的方向或速度。比較重要的超參數包含「最佳化演算法」、「損失函數」以及「學習速率」，以及這三者使用演算法的一些因子，這其中可能包含千百種組合。

因此，本計畫預計透過網格搜索(Grid Search)的方式尋找最適合的超參數組合。一開始透過隨機篩選超參數進行模型訓練，然後在高維度的超參數空間中，逐步在每一個區域進行試驗，測試模型的表現狀況後找出較佳的超參數組合，進一步在該區域做更細緻的超參數搜索，如此一來超參數的調整也可以透過自動化來完成，以提升模型訓練的效能。

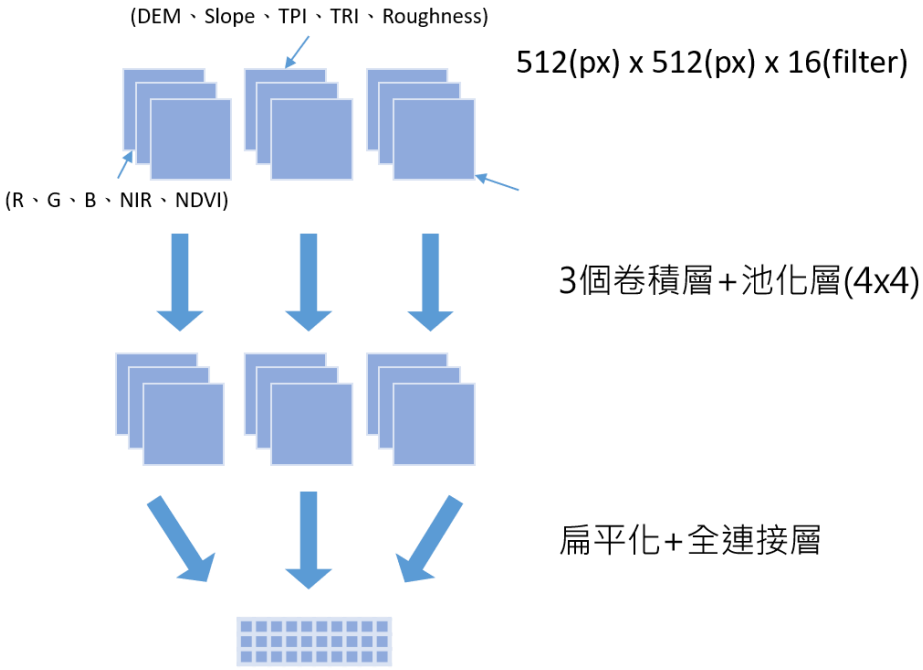

圖 6-28 模型設計架構示意圖

五、模型預測與圖像後處理

模型訓練完成隨即進入模型預測之步驟，透過已經訓練好的模型權重來進行完整像幅的航攝影像判釋，意即影像上的所有像素均會在最後獲得個別的類別機率，並且據此做出分類成果。實務上，影像必須經過設定好大小的像素移動裁切，然後再做判釋。每一次判釋的過程被裁切的影像都會因此獲得對應像素的類別機率，若因重覆裁切導致重覆判釋的像素，則會在最後對像素的各個類別機率加以平均，以選出機率最大的類別。

六、模型評價與精度評估

(一)模型評價方法

在模型評價的方面必須分成「局部評價」與「全域評價」來說明。在模型訓練過程中，「局部評價」是對每一張裁切後的影像分類準確度進行評價，此部分簡單的使用準確率便可進行評價，而準確率係指所有影像中模型判斷正確的比率。在模型訓練結束後，「全域評價」則是在每一張裁切的影像完成分類預測後，重新組合預測成果，然後再與人工標記的多邊形進行比對。這樣的衡量方法在圖像分割領域中被稱為檢測評價(Intersection over Union，IOU)函數。如圖 6-29 所示，IOU 顧名思義就是交集除以聯集，亦即標記區域與判釋區域的交集，除以標記區域與判釋區域的聯集，如此一來，便能夠準確計算標記區域與判釋區域的重疊率作為評價模型的分數。

為了進一步確認模型訓練成果之精度，導入一般常用誤差矩陣(Error Matrix)評估方法進行驗證，如表 6-6。主要包含使用者精度(User's Accuracy，UA)、生產者精度(Producer's Accuracy，PA)、整體精度(Overall Accuracy，OA)、平均精度(Average Accuracy)與 Kappa 指標。其中，使用者精度為在分類結果中實際為 A 樣本佔分類為 A 樣本的比值(式 6-2)；生產者精度分類為 A 樣本佔實際為 A 樣本的比值(式 6-3)；整體精度為分類

正確的樣本數佔總樣本數的比值(式 6-4)；Kappa 指標為表示分類成果與檢核資料相似程度的指數(式 6-5)，透過 P0(觀測一致性)與 Pc(期望一致性)計算而得，其範圍為 0 到 1，值愈大代表分類精度愈高。

$$\mathrm{UA}_i = \frac{X_{ii}}{X_{i1} + \cdots + X_{iN}}$$

式 6-2

$$\mathrm{PA}_i = \frac{X_{ii}}{X_{1i} + \cdots + X_{Ni}}$$

式 6-3

$$\mathrm{OA} = \frac{X_{11} + X_{22} + \cdots + X_{NN}}{\sum_{i=1}^{N} \sum_{j=1}^{N} X_{ij}}$$

式 6-4

$Kappa = \frac{P_0 - P_c}{1 - P_c}$ ，其中 $P_0 = OA$ ，

$$P_c = \frac{1}{\sum_{i=1}^{N} \sum_{j=1}^{N} X_{ij}} \sum_{k=1}^{N} \left(\frac{X_{kk}}{PA_k} \times \frac{X_{kk}}{UA_k}\right)$$

式 6-5

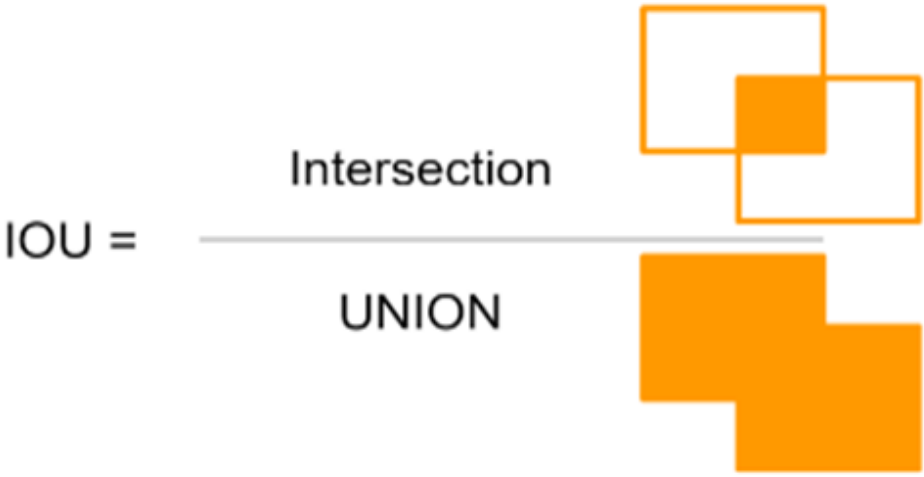

圖 6-29 交集除以聯集 (Intersection over Union)

表 6-6 誤差矩陣對照表

誤差矩陣		分類成果			
		類別 1	…	**類別 N**	**生產者精度：PA**
現地資料	**類別 1**	X_{11}	…	$X1_N$	PA_1
	⋮	⋮	⋱	⋮	⋮
	類別 N	X_{N1}	…	XN_N	PA_N
	使用者精度：UA	UA_1	…	UA_N	-
整體精度：OA			Kappa 指標：K		

(二)模型訓練成果

本計畫模型訓練過程之紀錄如圖 6-30 說明，橫坐標為回合數(Epoch)，縱座標為模型訓練計算之統計值，觀察數個回合內訓練資料集準確率(accuracy)與測試資料集準確率(val_accuracy)的變化情形，可看出在多次回合的訓練過程，與實際值之差異逐漸縮小，準確率逐漸提升，最後計算出在第 70 回合時達到樣本差異最小。最終成果產出如表 6-7 所示，呈現 11 類樹種之誤差矩陣，**整體準確率 65.3%，Kappa 值為 0.618。**

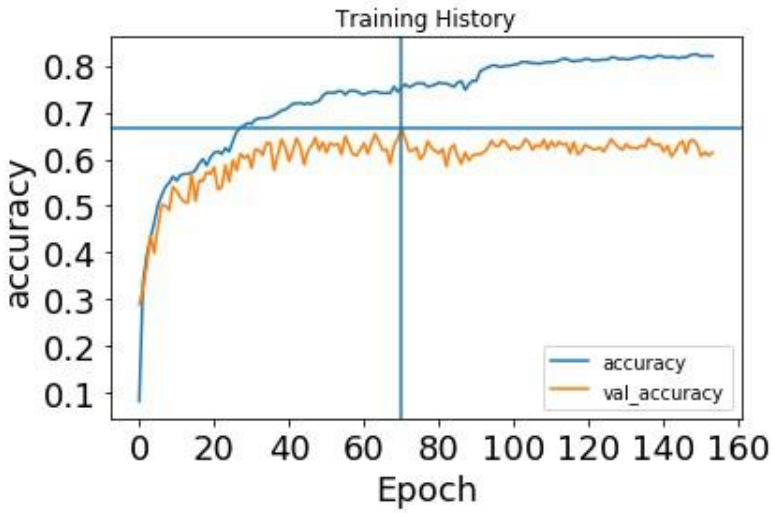

圖 6-30 各樹種訓練回合之統計情形

表 6-7 樹種判釋分類誤差矩陣 (表中數值為百分比)

	單桿狀竹	叢生狀竹	台灣赤楊	相思樹	冷杉	鐵杉	柳杉	台灣杉	杉木	松樹	檜木	總和
單桿狀竹	4.61	1.41	0.08	0.00	0.08	0.12	1.09	0.20	1.05	0.00	0.16	8.79
叢生狀竹	0.47	7.34	0.00	0.43	0.00	0.00	0.20	0.04	0.39	0.00	0.00	8.87
台灣赤楊	0.00	0.04	6.68	0.00	0.00	0.04	0.55	0.27	0.16	0.66	1.25	9.65
相思樹	0.20	1.64	0.00	7.11	0.00	0.00	0.08	0.00	0.00	0.00	0.00	9.02
冷杉	0.04	0.00	0.08	0.00	5.70	3.13	0.00	0.00	0.00	0.12	0.23	9.30
鐵杉	0.00	0.00	0.08	0.00	0.12	6.48	0.00	0.04	0.00	0.82	1.05	8.59
柳杉	0.12	0.12	0.20	0.04	0.00	0.00	5.70	1.45	0.47	0.04	1.52	9.65
台灣杉	0.04	0.00	0.27	0.00	0.00	0.12	0.82	6.09	0.27	0.20	1.13	8.95
杉木	0.31	1.13	0.04	0.16	0.00	0.00	1.52	0.74	5.43	0.00	0.27	9.61
松樹	0.04	0.00	0.43	0.00	0.08	1.45	0.16	0.08	0.12	3.75	1.76	7.85
檜木	0.00	0.00	0.55	0.00	0.08	1.17	0.31	0.63	0.00	0.59	6.41	9.73
總和	5.82	11.6	8.40	7.73	6.05	12.5	10.4	9.53	7.89	6.17	13.7	100.0

(三)訓練錯誤結果分析

至此完成 11 類樹種分類模型建構與訓練，並以測試資料集來驗證模型是否能正確分類出選擇的樹種，以下針對分類成果不理想之樹種進行訓練錯誤成果誤判分析。如圖 6-31 所示，以判斷正確統計圖而言松樹與單桿狀竹有較差的表現，而在各樹種錯誤分類統計圖中檜木最容易被分類錯誤，其次為鐵杉。

進一步針對 11 類樹種錯誤分類結果進行統計，如圖 6-32 至圖 6-34 所示，在竹類中，單桿狀竹容易與叢生狀竹混淆，柳杉和杉木也有較多的誤判，叢生狀竹也相對容易與單桿狀竹混淆，另外包含相思樹、杉木、柳杉也有較多的誤判；在闊葉樹種中，台灣赤楊最容易與檜木混淆，而相思樹則是以叢生狀竹為主；就針葉樹種而言，冷杉容易誤判為鐵杉，鐵杉容易誤判為檜木和松樹，柳杉則以檜木和台灣杉為主，台灣杉也同樣是檜木和柳杉，而杉木容易誤判為柳杉和叢生狀竹，松樹則是檜木和鐵杉，最容易誤判的檜木則是以鐵杉為主。針對上述誤判的結果摘選各類別數個案例呈現如圖 6-35 至圖 6-45，為了確保未來訓練成果的正確性，誤判的結果亦將透過貴所與專業顧問研判機制，藉由影像判釋技術人員實務作業了解誤判原因，或者歸因於訓練資料中標記圖資之錯誤定義，以有效輔助現行圖資產製作業，滾動修正與更新林型圖樹種圈繪結果。

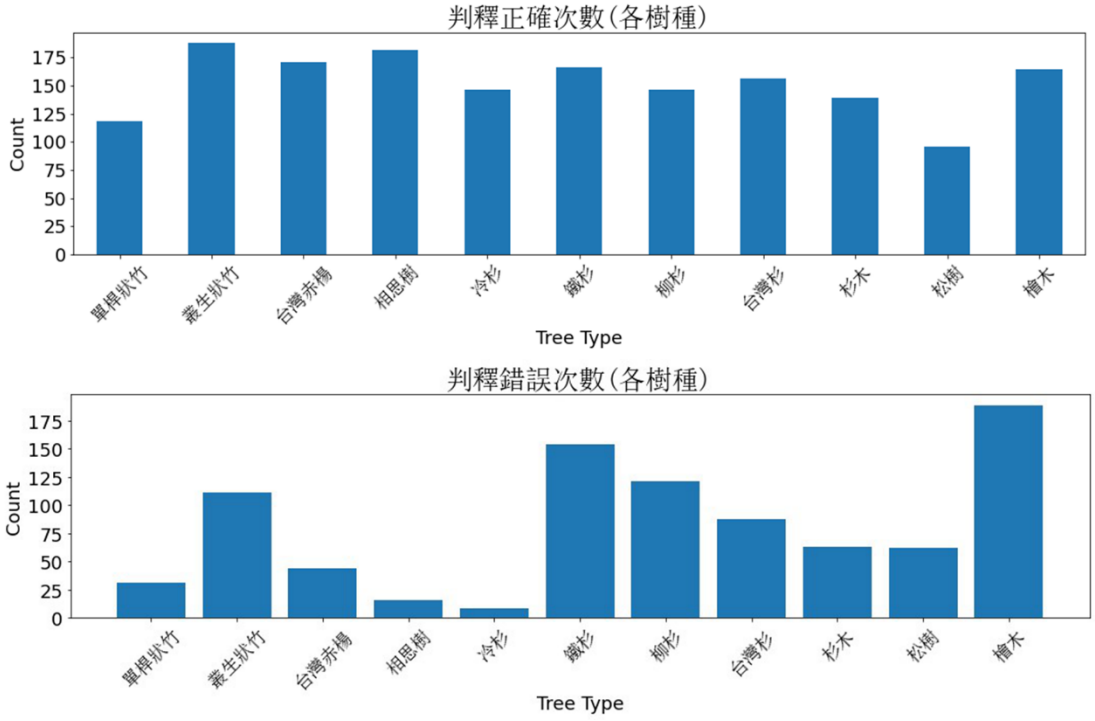

圖 6-31 判斷正確與錯誤分類統計

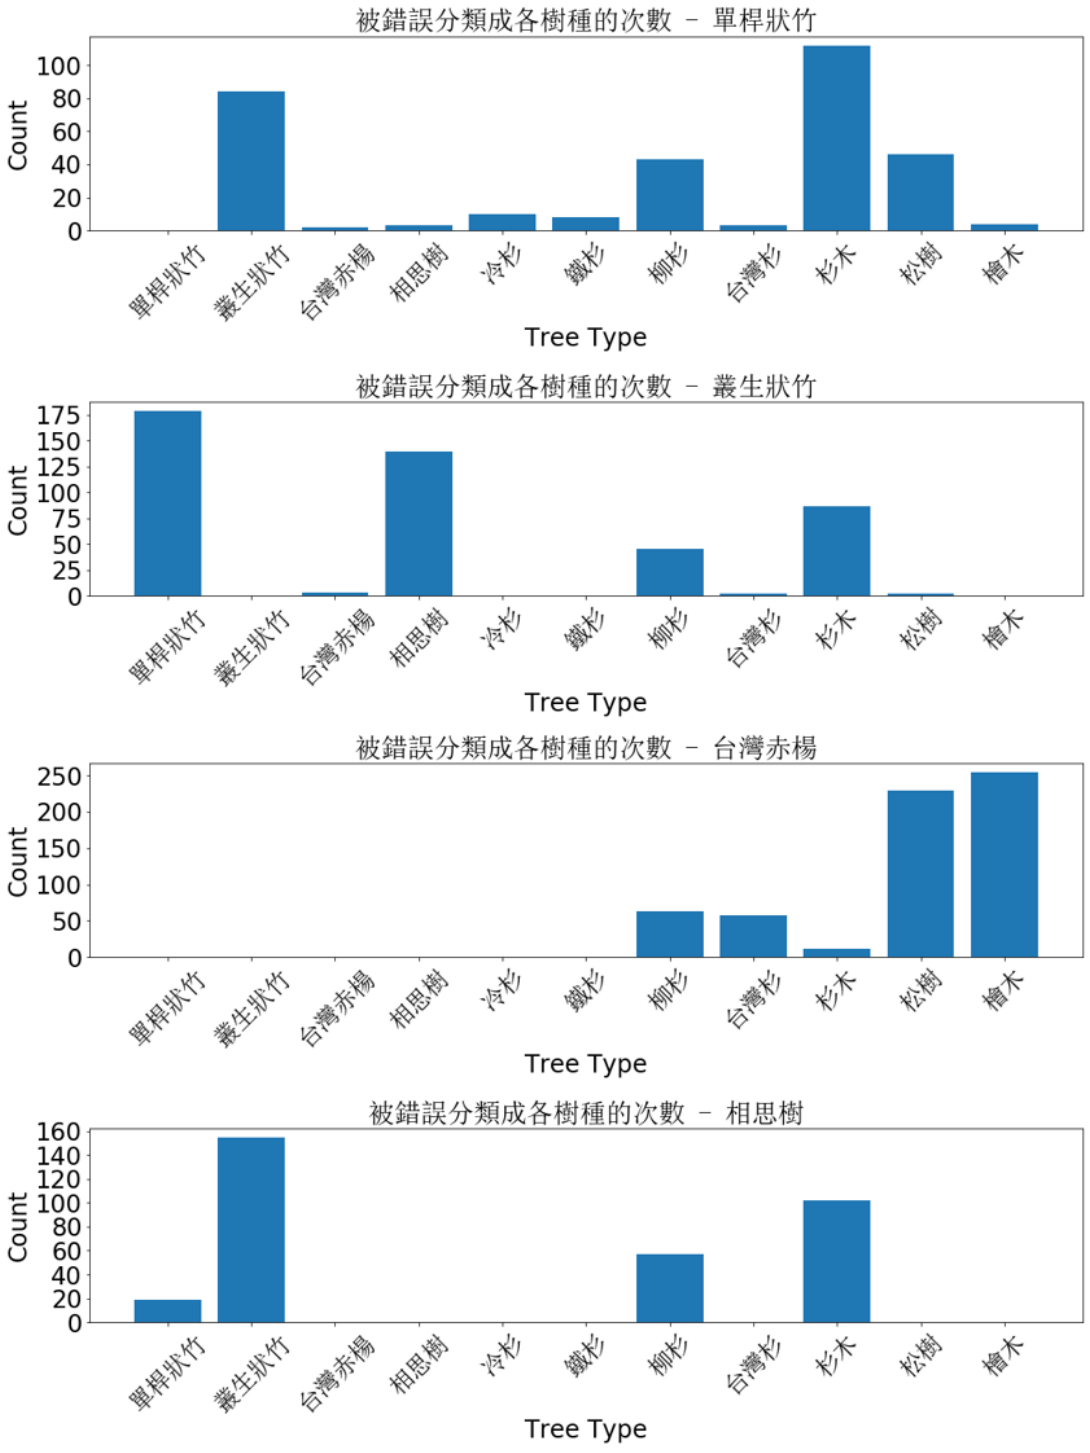

圖 6-32 各樹種錯誤分類次數統計(1/3)

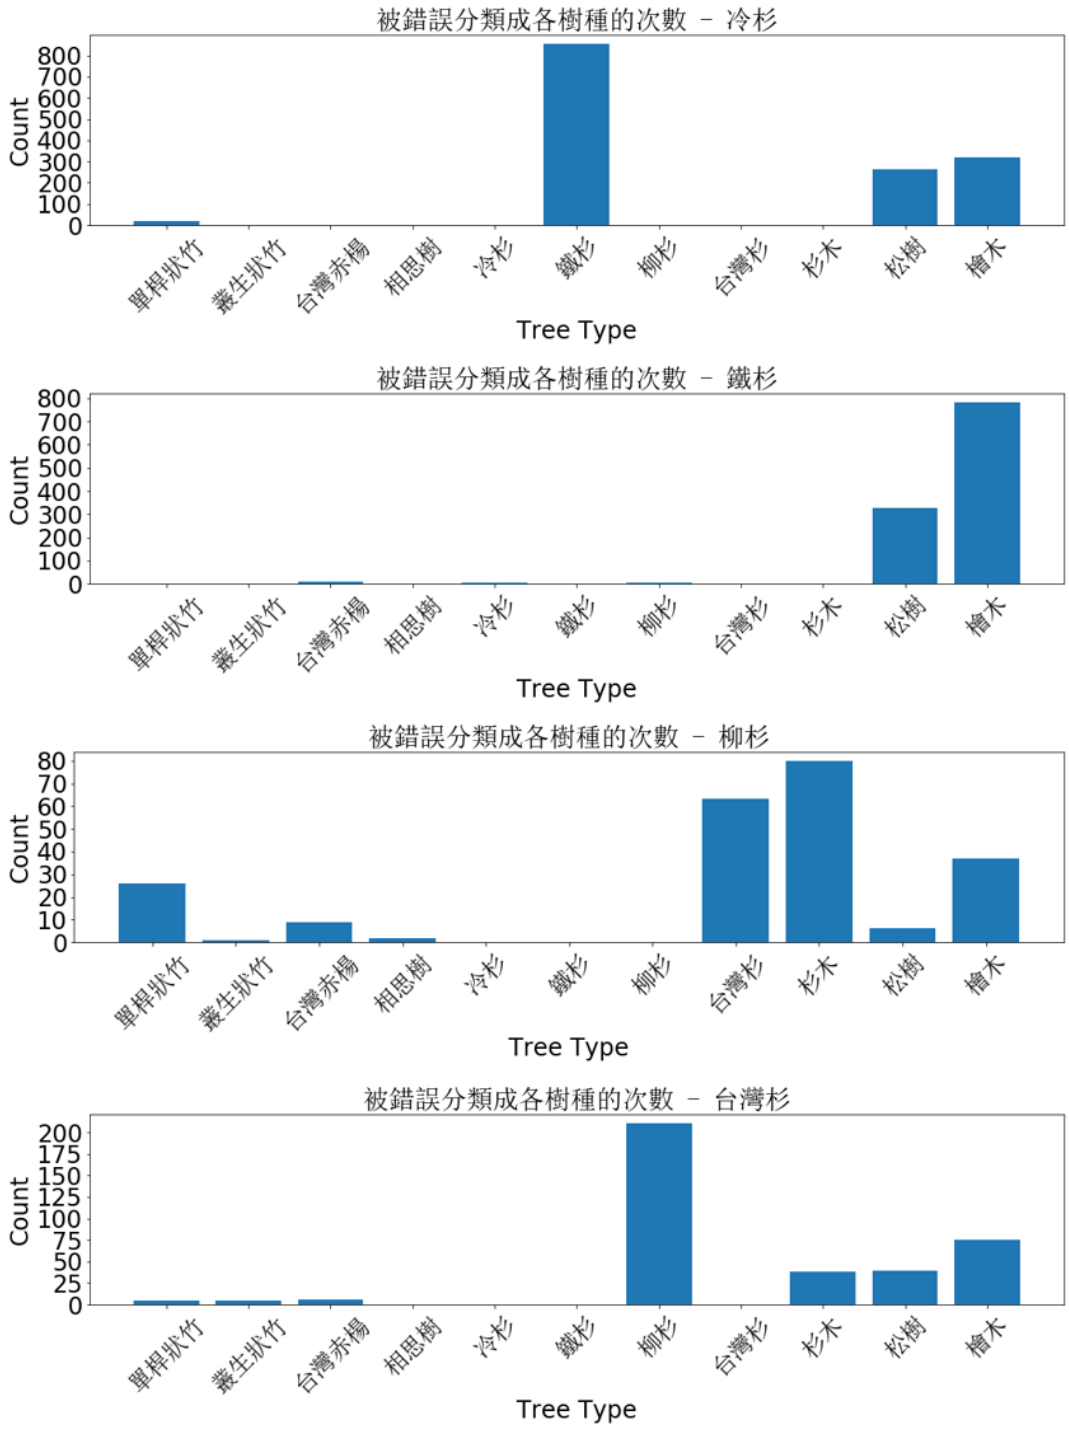

圖 6-33 各樹種錯誤分類次數統計(2/3)

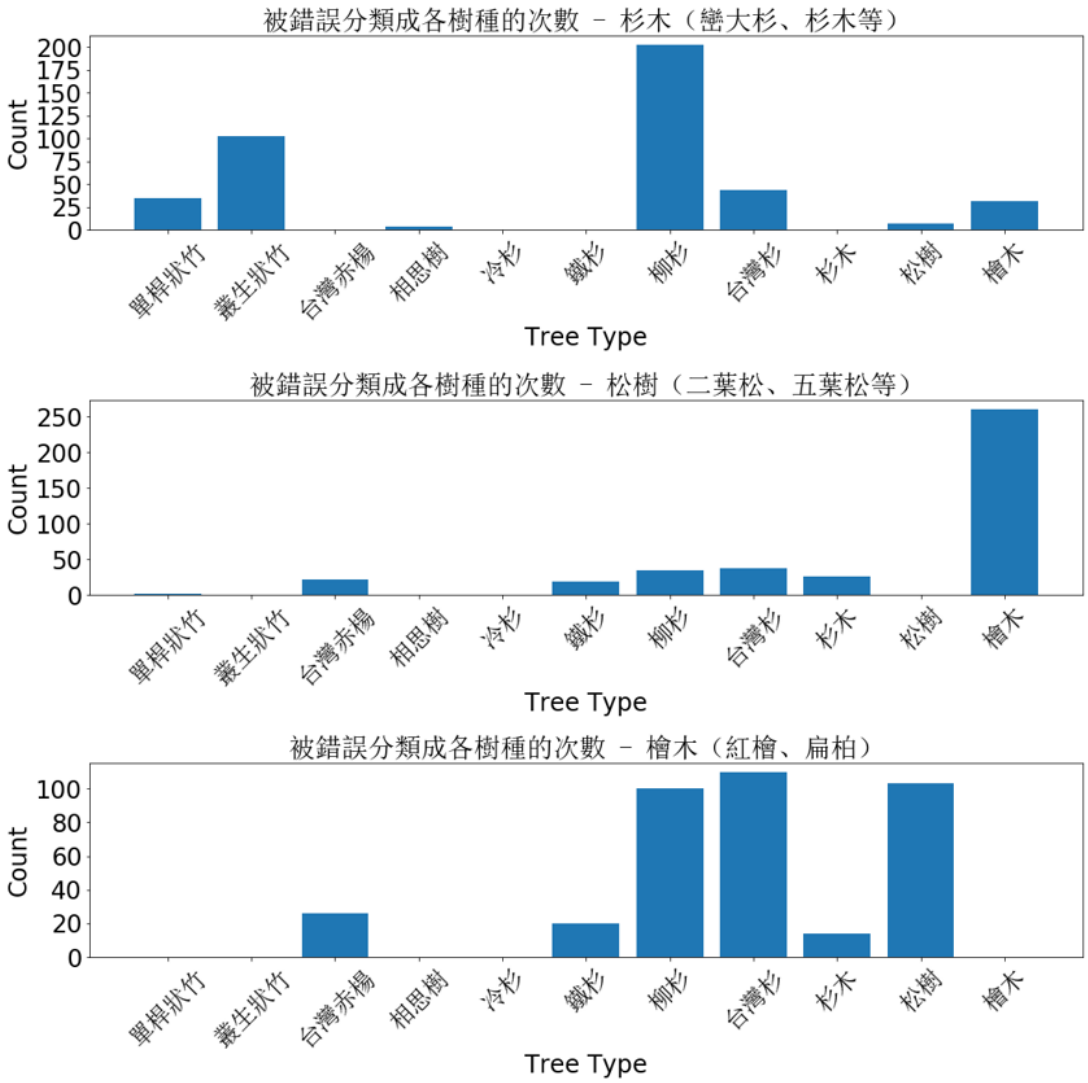

圖 6-34 各樹種錯誤分類次數統計(3/3)

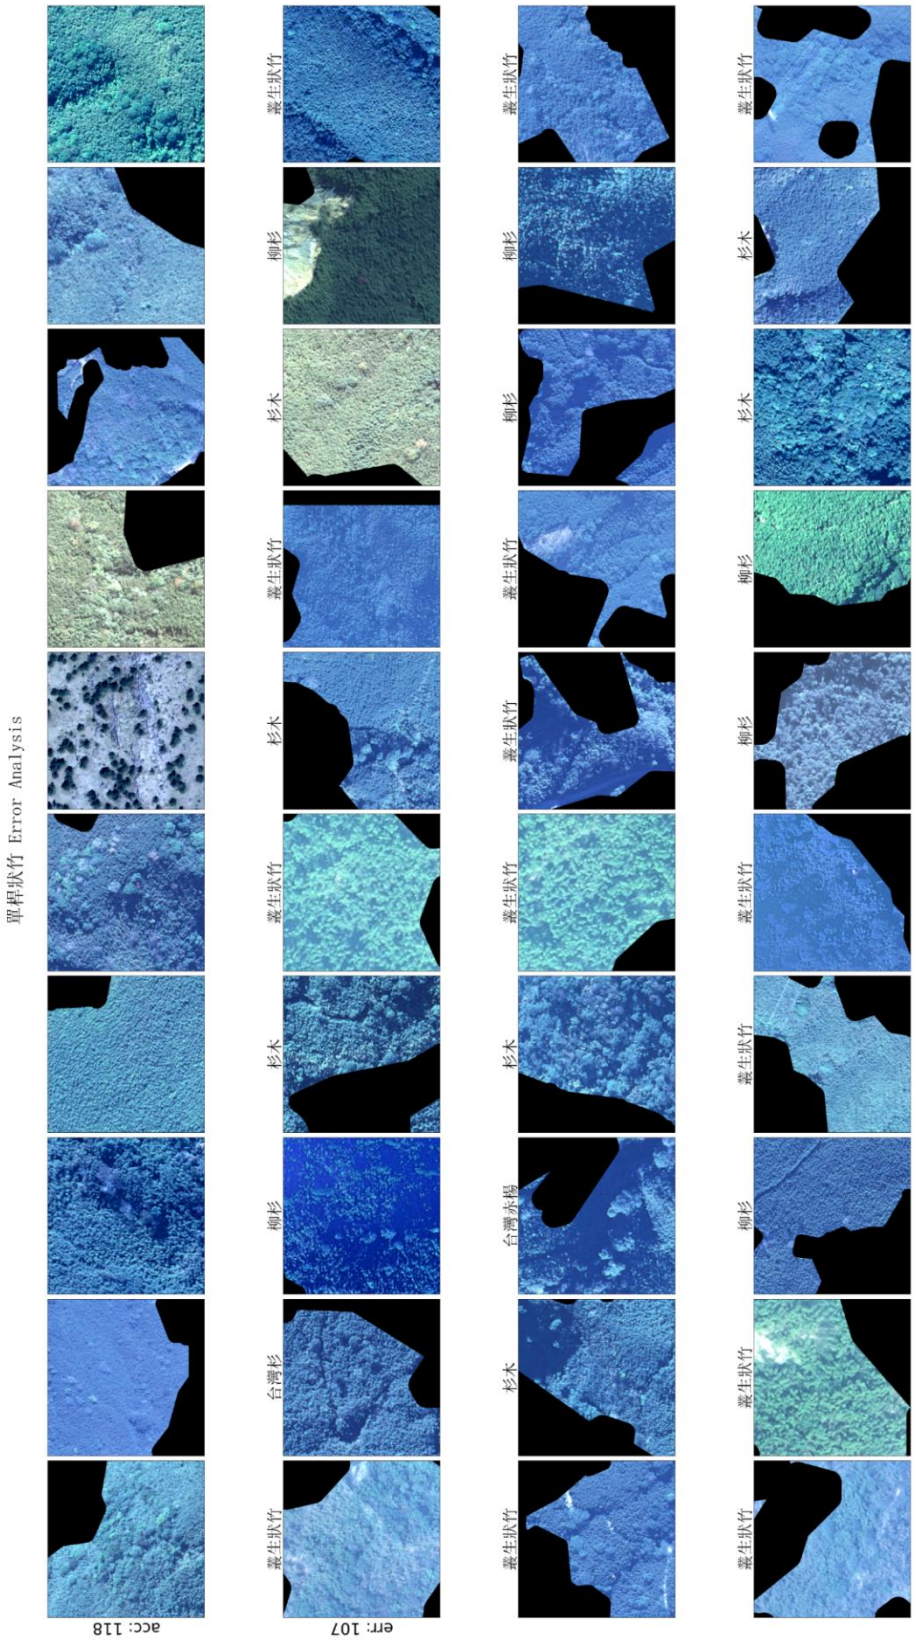

圖 6-35 單桿狀竹錯誤分類案例

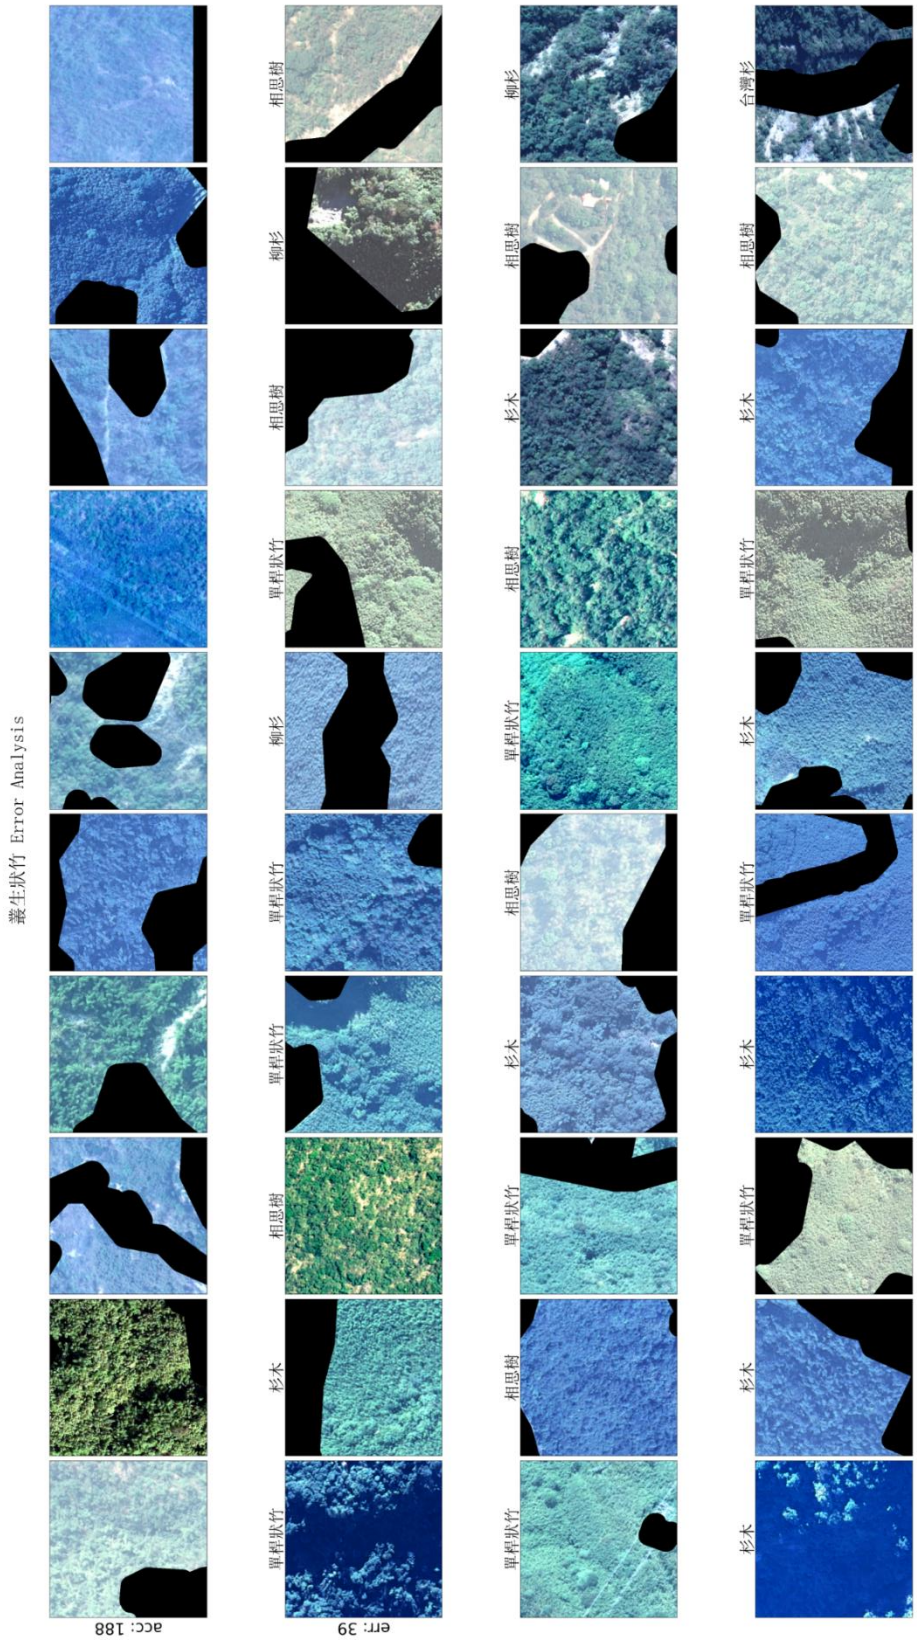

圖 6-36 叢生狀竹錯誤分類案例

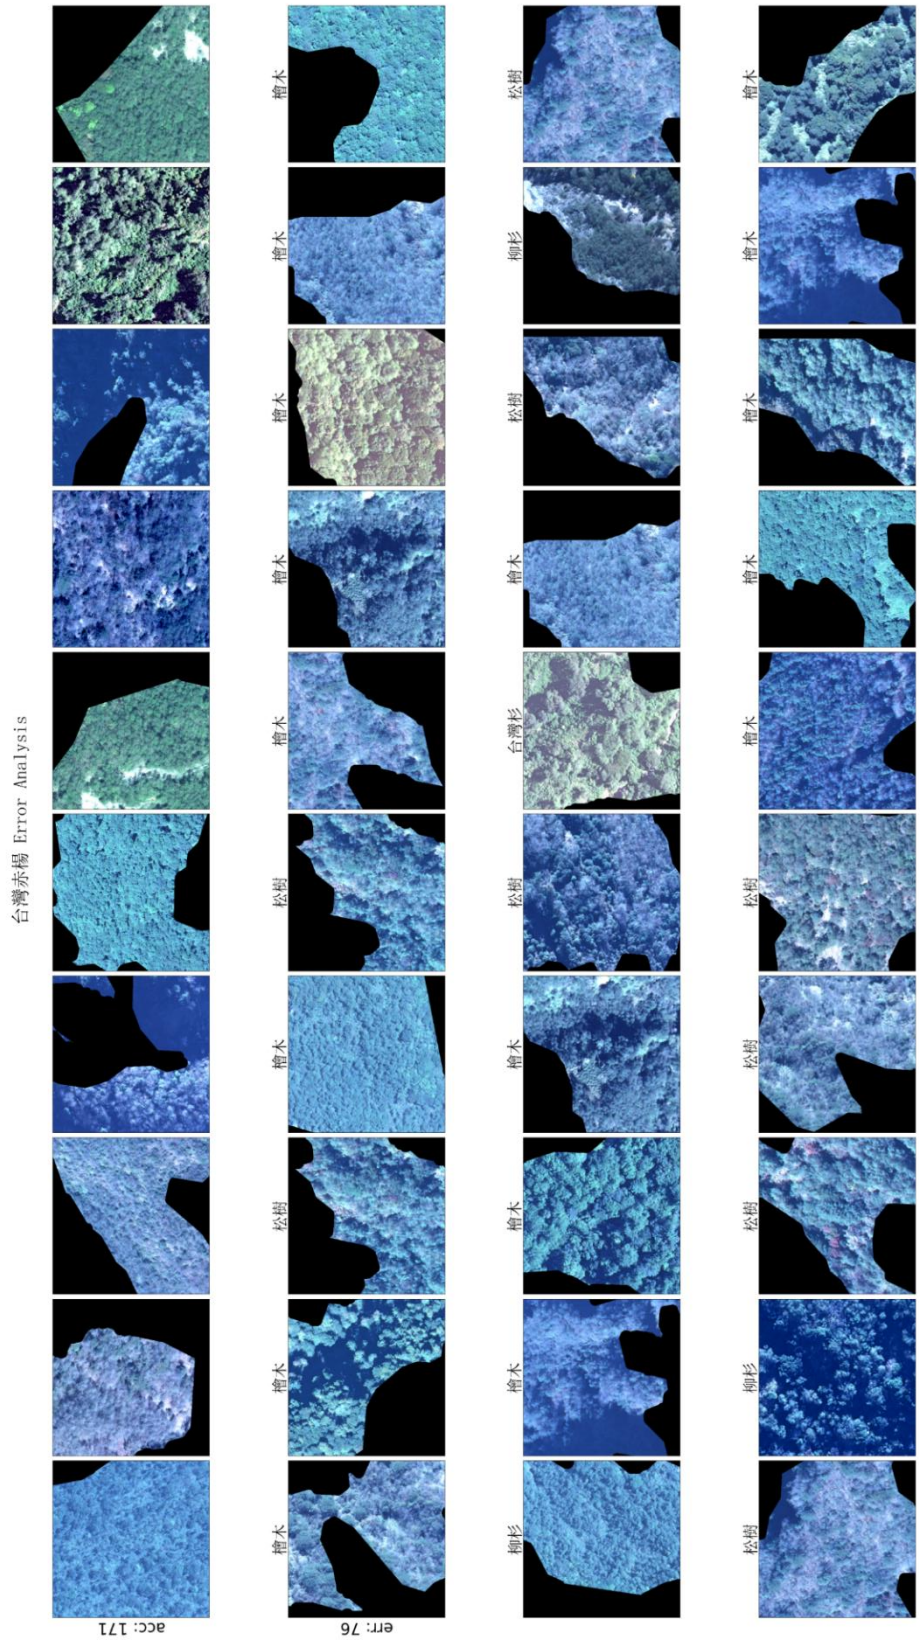

圖 6-37 台灣赤楊錯誤分類案例

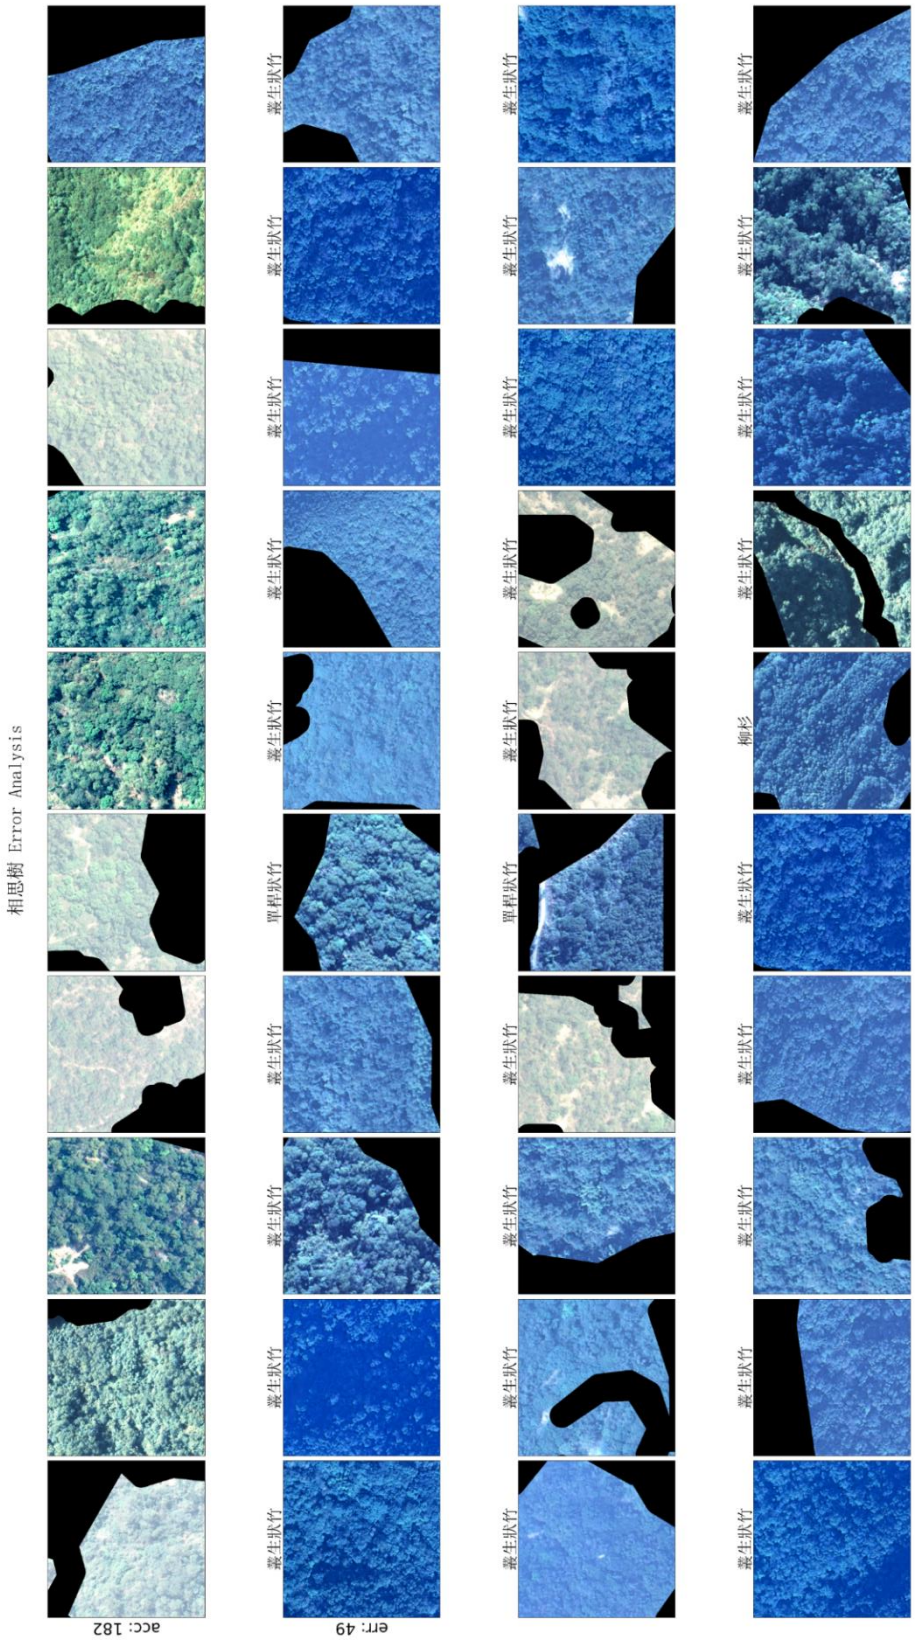

圖 6-38 相思樹錯誤分類案例

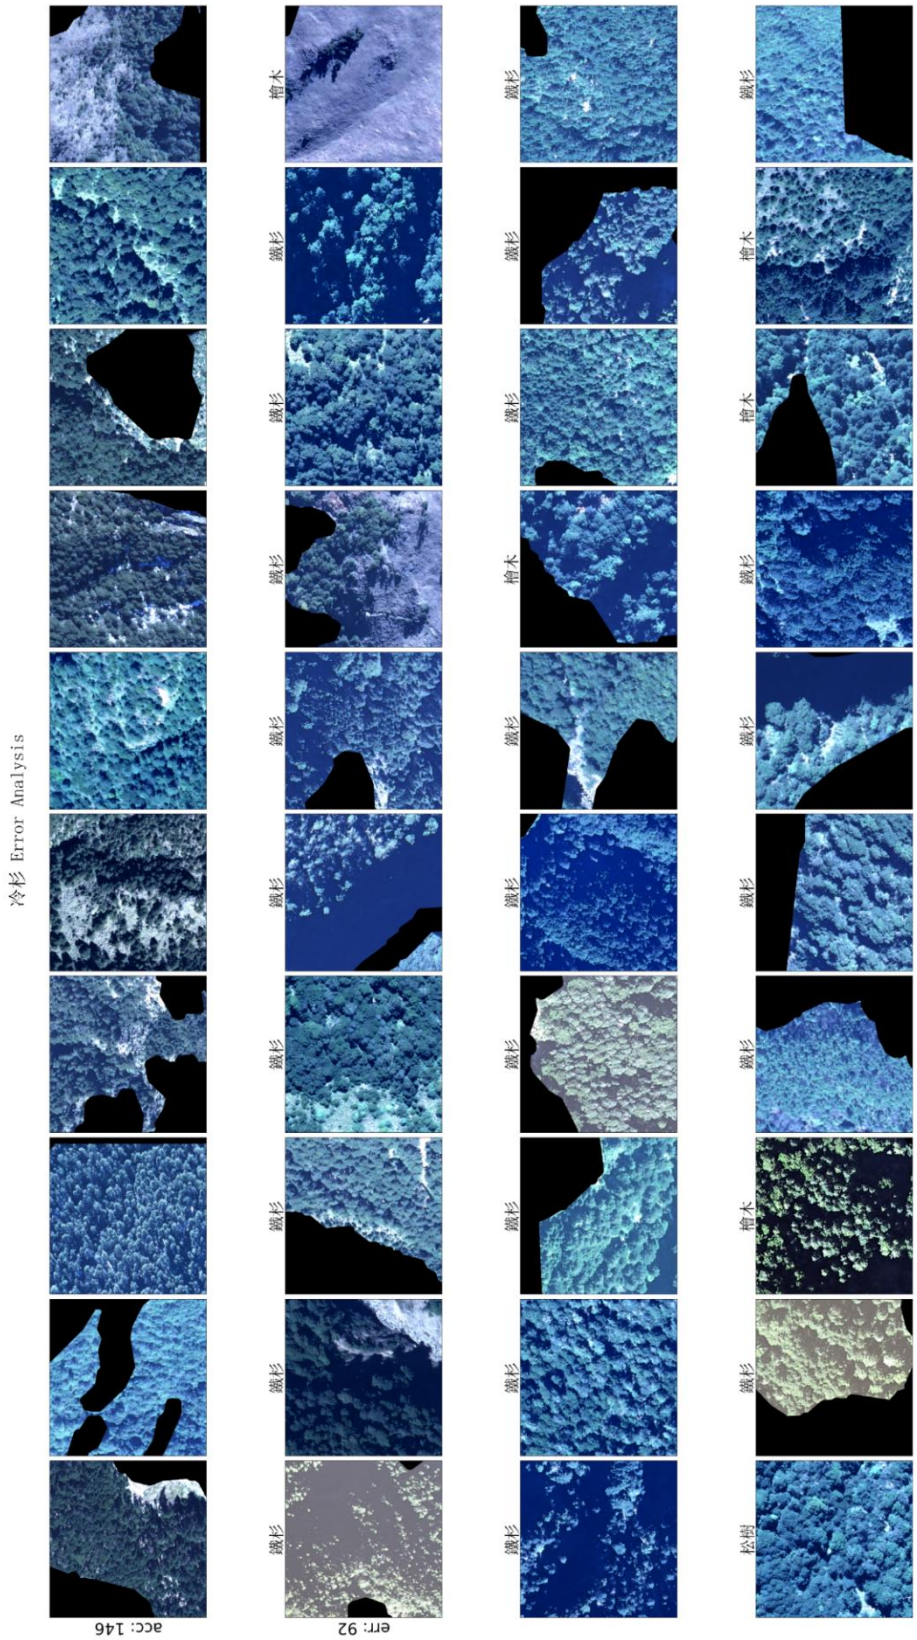

圖 6-39 冷杉錯誤分類案例

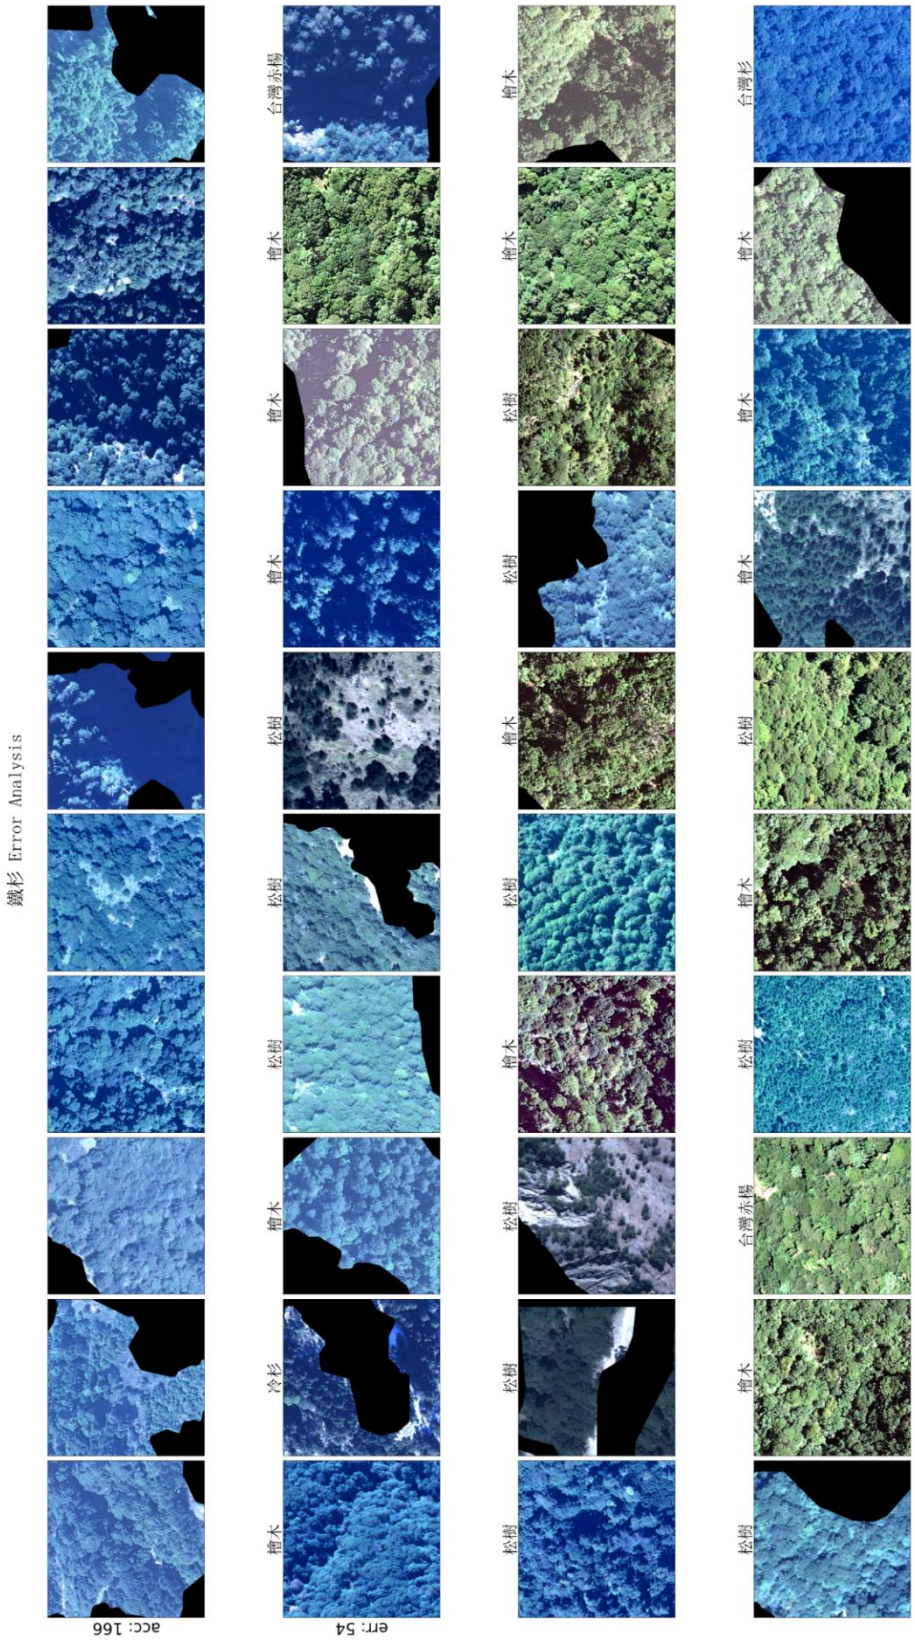

圖 6-40 鐵杉錯誤分類案例

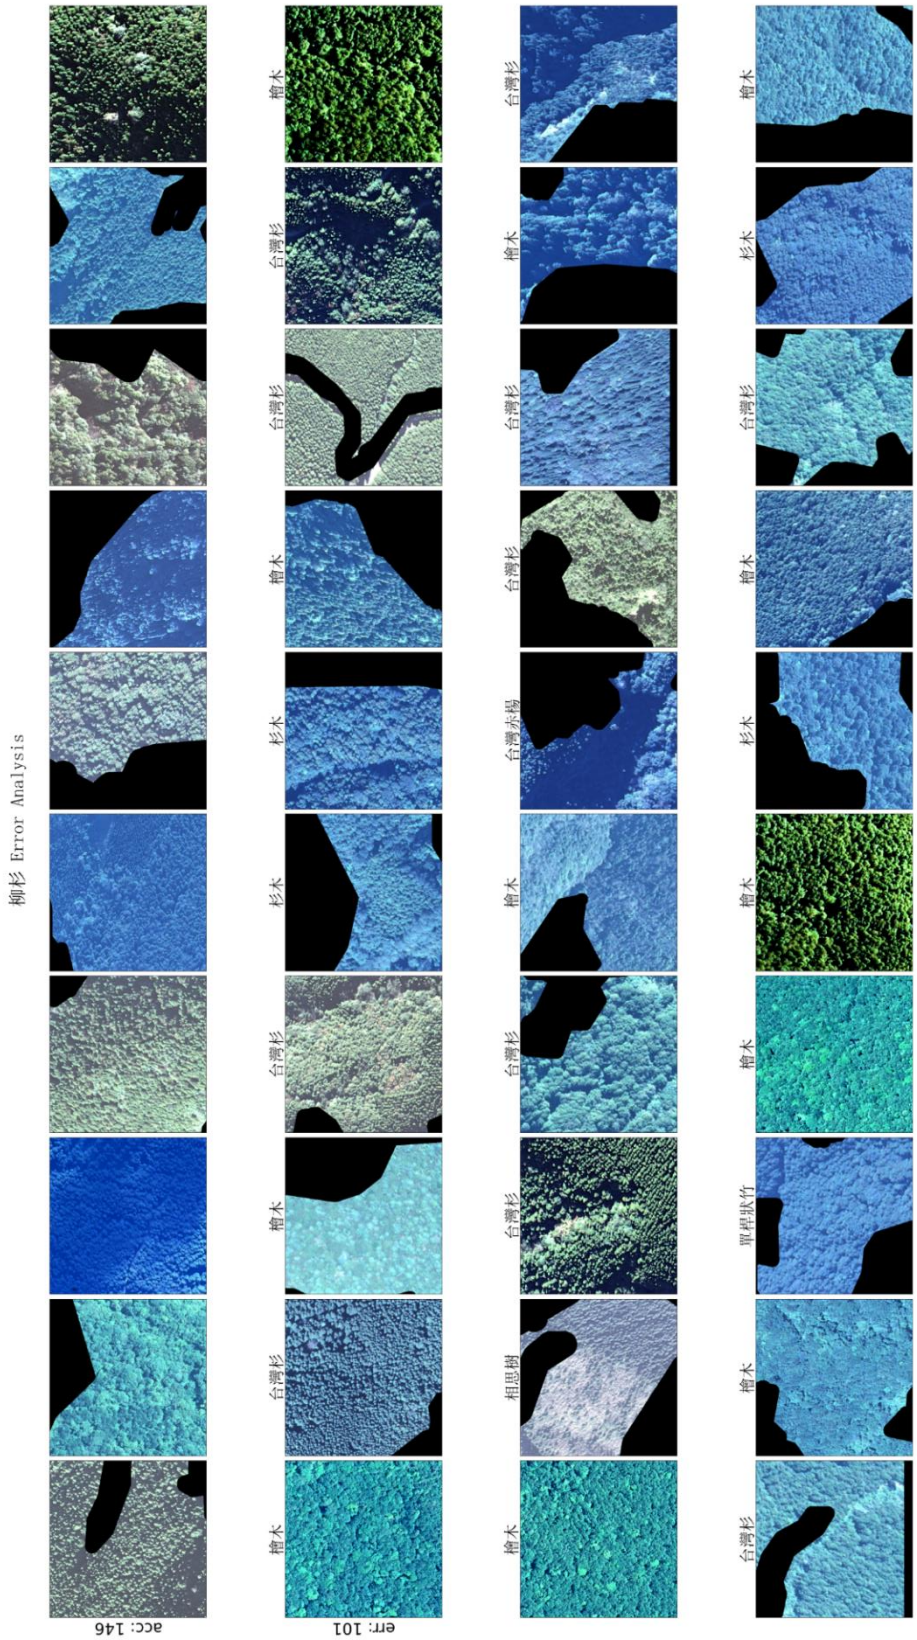

圖 6-41 柳杉錯誤分類案例

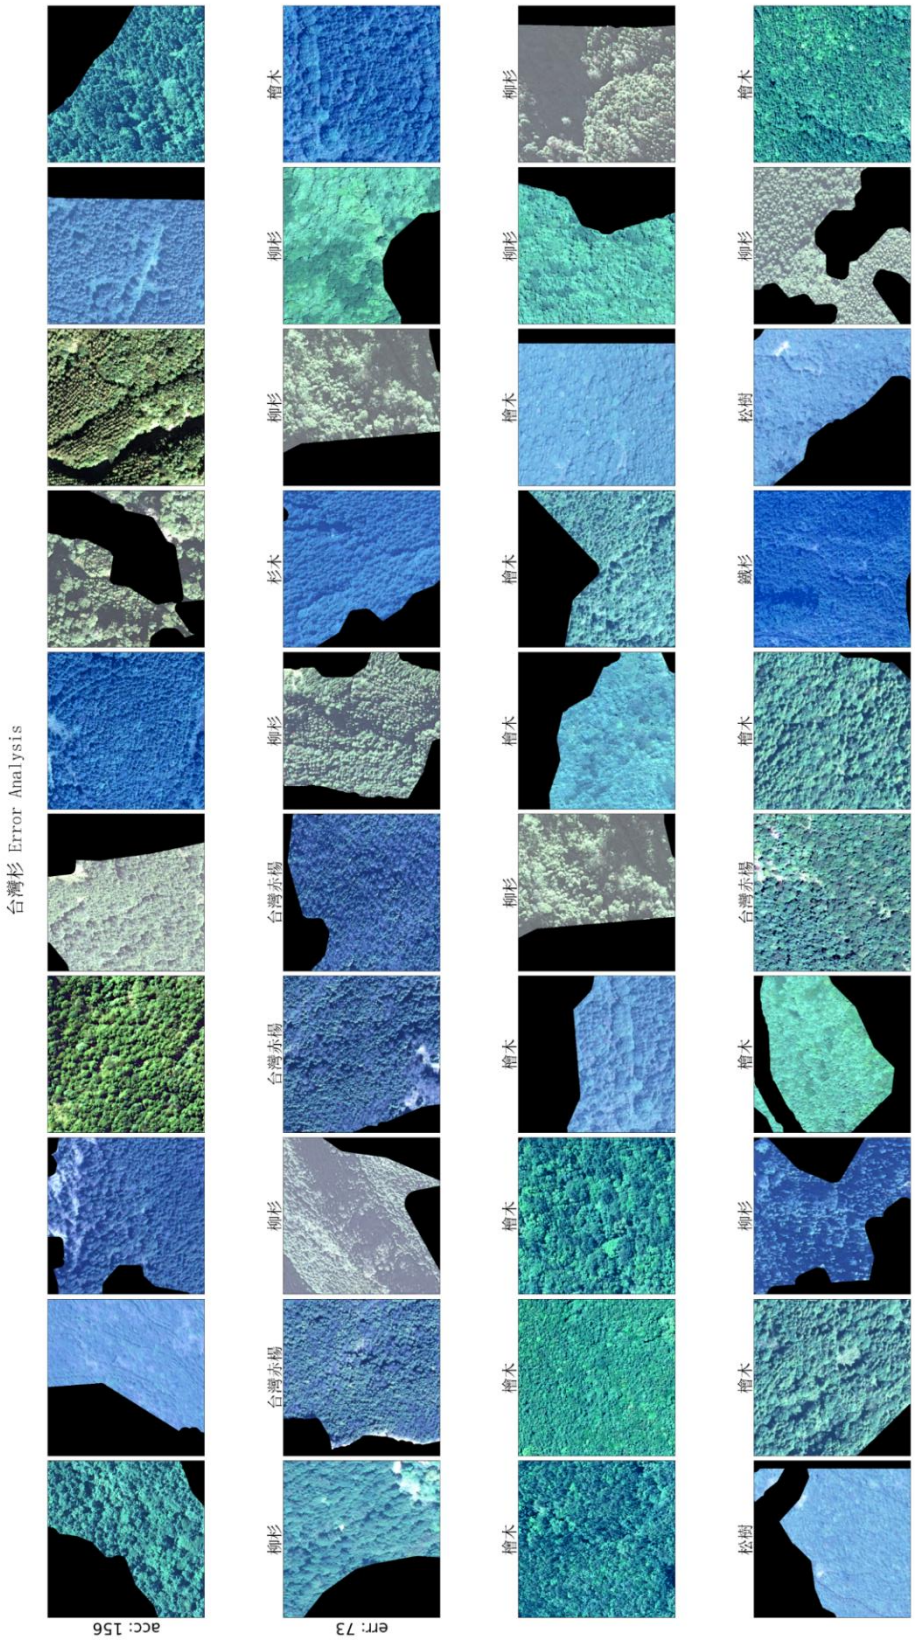

圖 6-42 台灣杉錯誤分類案例

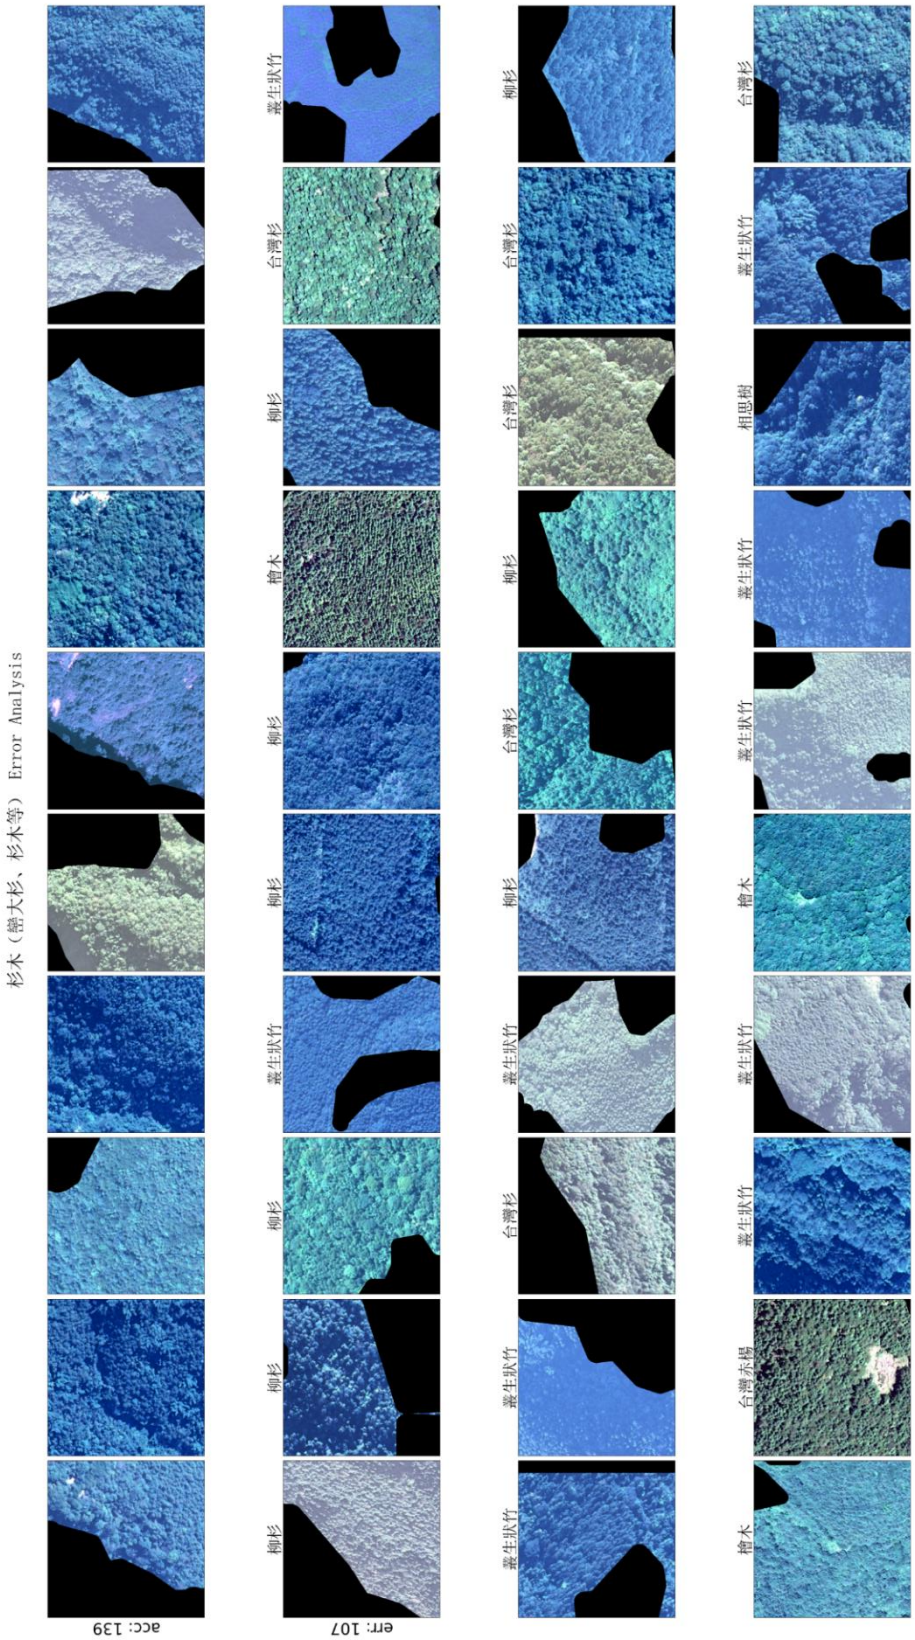

圖 6-43 杉木錯誤分類案例

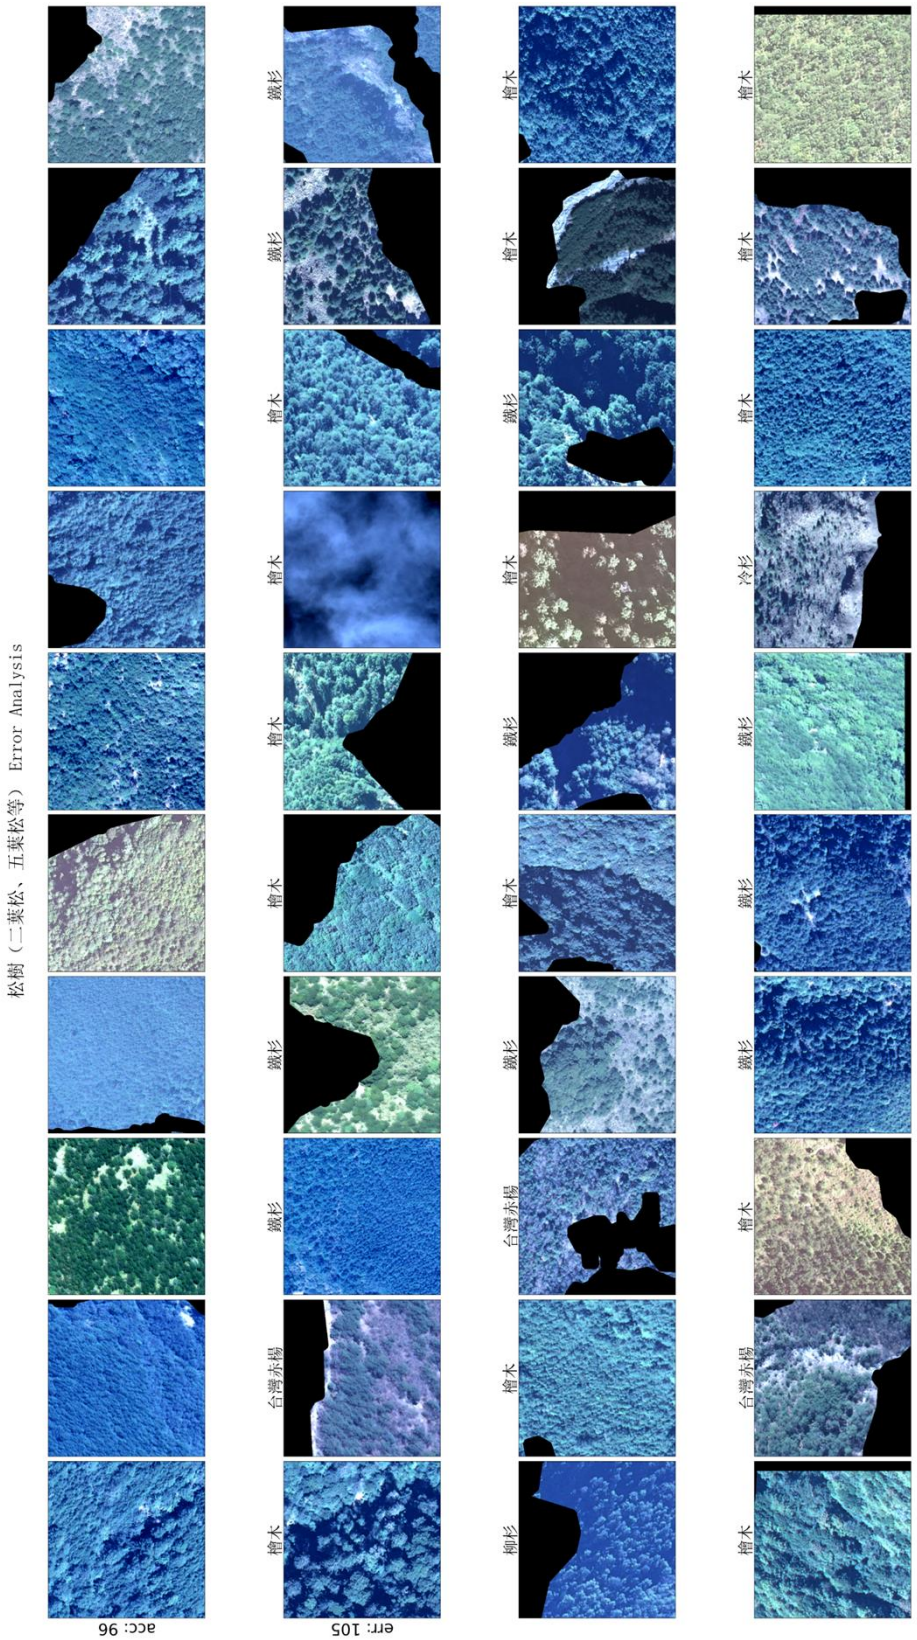

圖 6-44 松樹錯誤分類案例

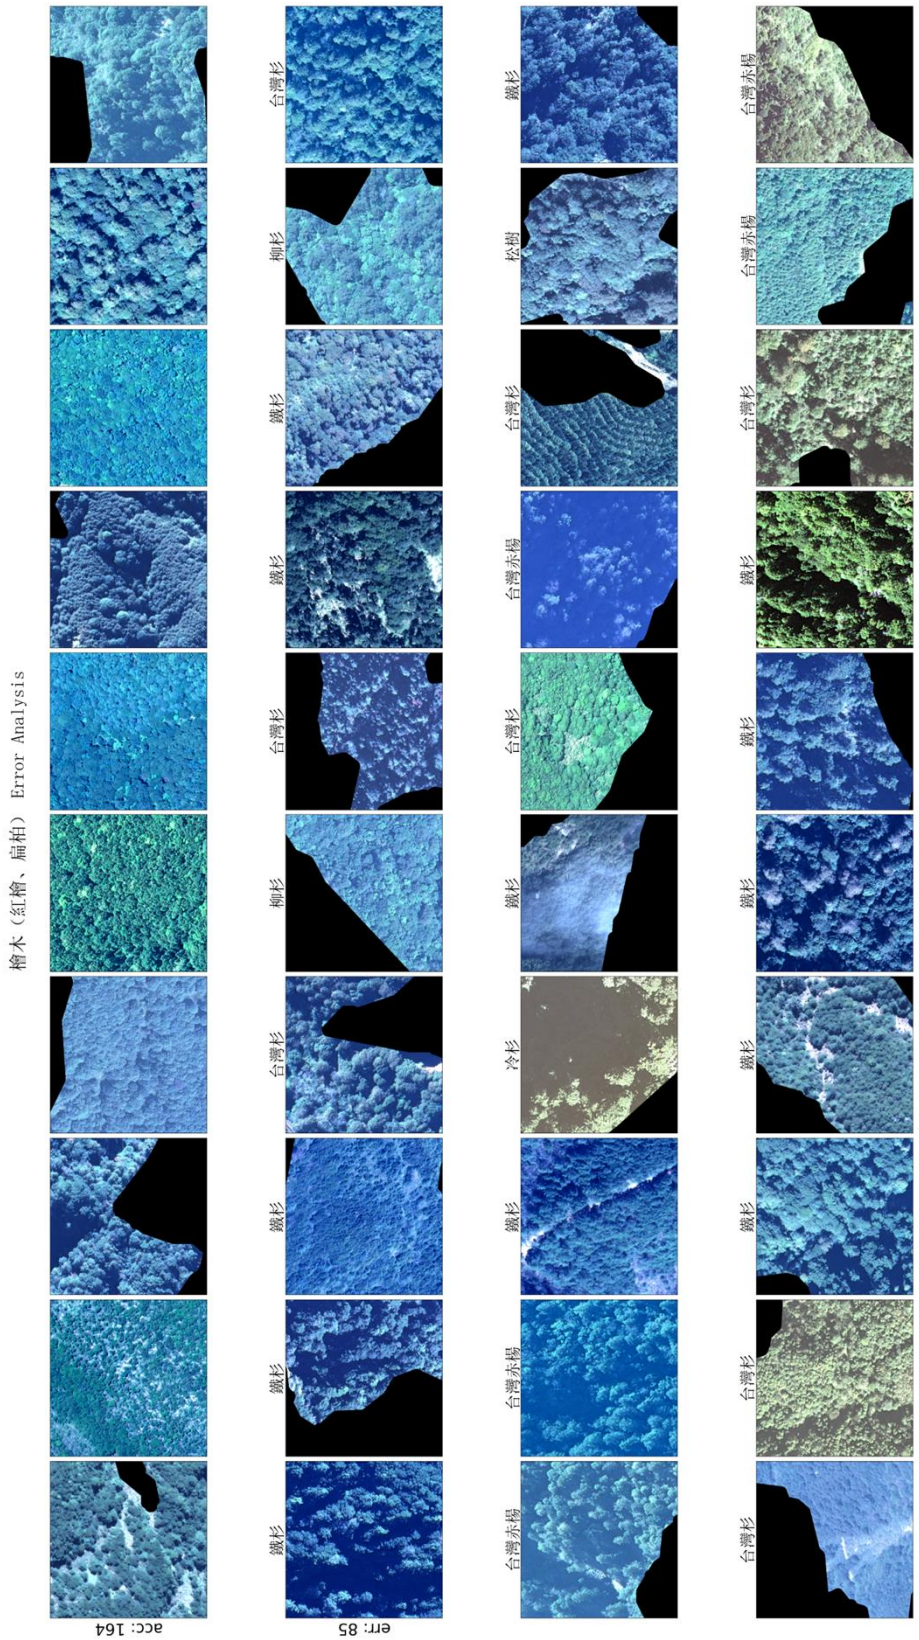

圖 6-45 檜木錯誤分類案例

(四)樹種特徵參數分析

為了深入了解選定的 11 項特徵參數對 11 類樹種分類的貢獻程度，繪製貢獻案例分析如圖 6-46 所示，呈現了各項特徵對於不同樹種判釋上的貢獻程度，縱軸代表的是 11 個樹種，橫軸代表的是 11 項不同特徵值以及原始訓練資料案例。在模型分析上，常使用 SHapley Additive exPlanations(SHAP) Value 來判斷每個特徵對分類結果造成的影響，SHAP 值的範圍為 1-到 1，顏色從藍色到紅色；越接近 1 或-1，代表該特徵影響判釋成果越大，此即為特徵的貢獻。舉例來說，當特徵 A 在甲類別上為藍色，代表特徵 A 對甲有正向貢獻，意即 A 越多，越有可能被判釋為甲類別；若特徵 A 在乙類別呈現紅色，代表特徵 A 對乙為負向貢獻，表示 A 越多，越不可能被判釋為乙類別。

觀察其結果發現，各個特徵對不同樹種有很明顯的差異貢獻，以單桿狀竹而言只有單一的坡向負貢獻來做判釋，而杉木也同樣只有單一的坡度負貢獻，對比冷杉卻多達八項特徵有做出貢獻，僅僅綠光、近紅外光以及粗糙度無顯著影響。除此之外，地形因子的導入確實大幅增加樹種分類的判讀性，特別是 DEM、TRI 對至少 5 種樹種作出貢獻。顯示地形環境乃至於環境物候，應直接影響著森林物種的生長。

九、自動化操作時效分析

本計畫以自動化作業為目標，於實作過程選擇開源程式碼進行，採用平行化運算完成批次操作分析與模型訓練之測試。進一步量化 718 張影像於各項流程之操作效率，如表 6-8，探討操作運轉時效，以作為未來貴所系統化精進之參考，並確保其研究成果在實務上能夠順利嵌入貴所既有的影像處理與樹種判釋的架構中。

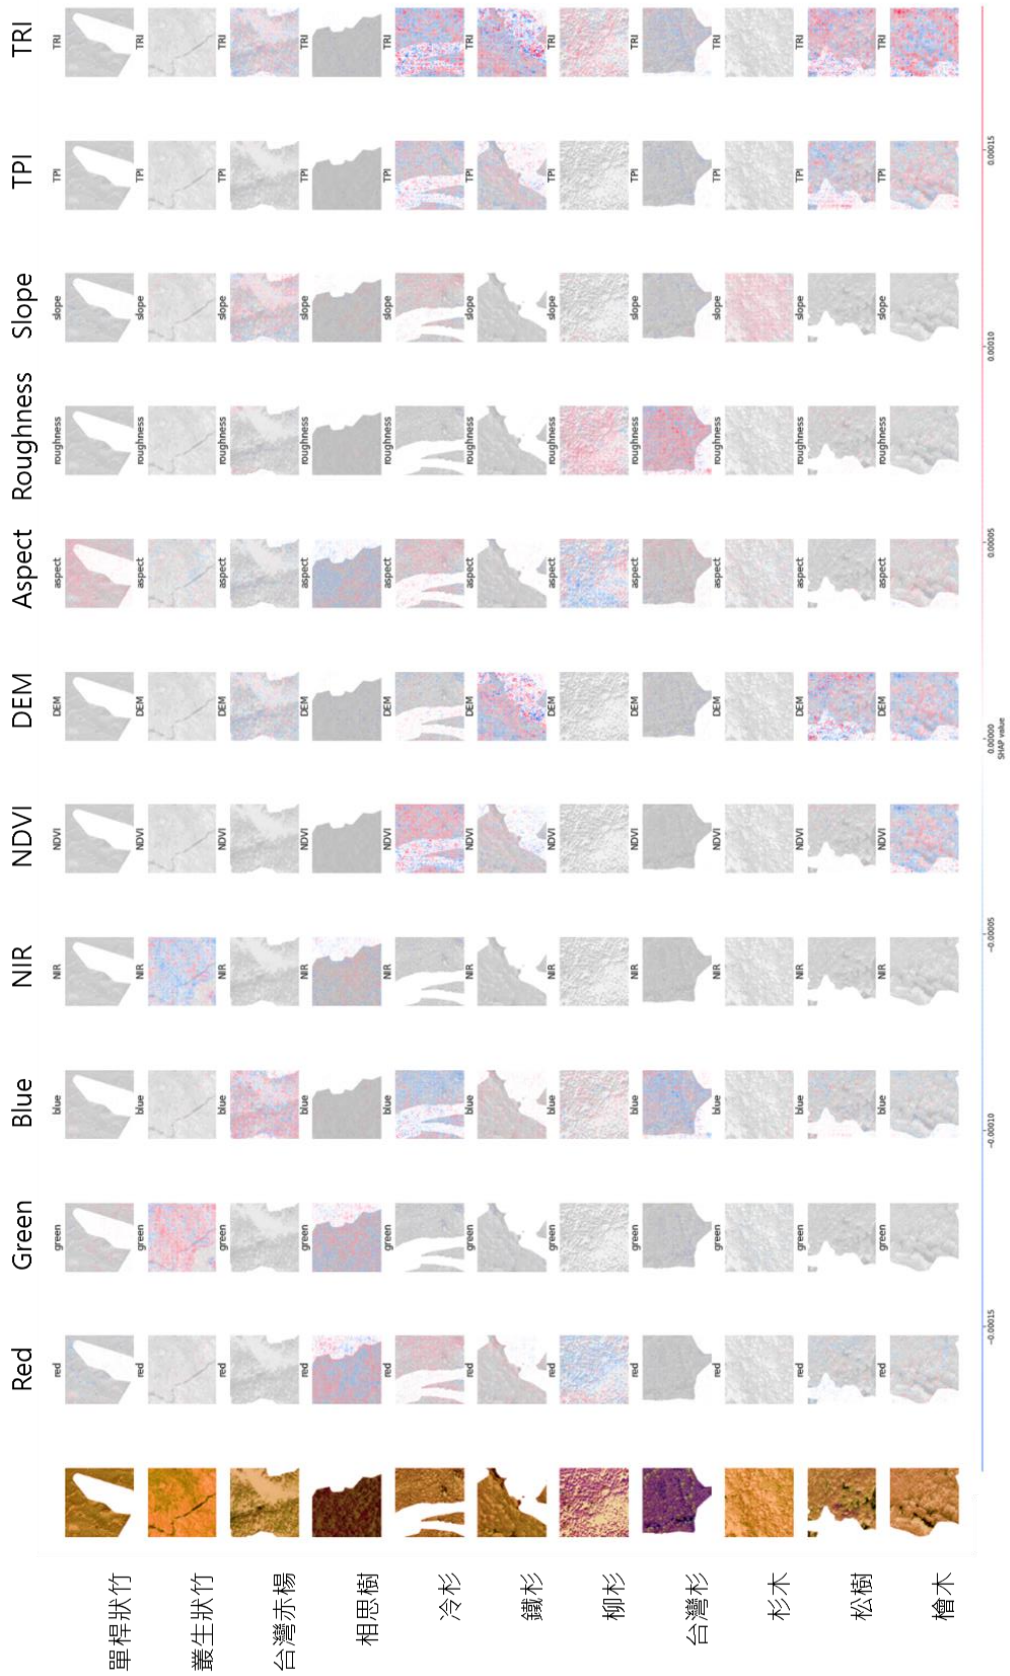

圖 6-46 訓練資料特徵貢獻案例

表 6-8 自動化流程操作時效紀錄

圖例	對應圖標	產圖時效說明
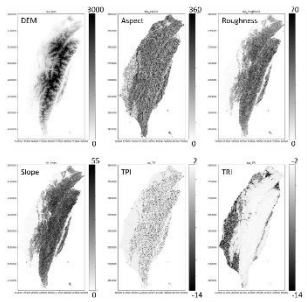	圖 3-14	以 20 公尺 DEM 產製全臺地形特徵參數，包含坡度、坡向、粗糙度、TPI、TRI，可在 10 分鐘內完成；若採用 5 公尺 DEM 產製，則耗時約 50 分鐘。
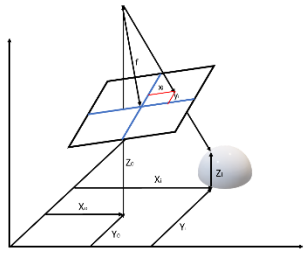	圖 6-4	計算反投影映射於每張航攝影像，將原本 10 分鐘的處理流程，平行化加速運算至數秒內完成。
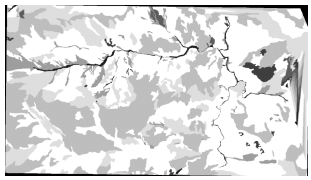	圖 6-11	林型圖圖框網格化映射於航攝影像且內差完成之計算，以 60 分鐘的處理流程，平行化加速至數十秒內完成。
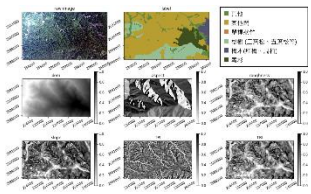	圖 6-16	以航攝影像為單位，產製各項參數特徵與林型圖標記資料，每幅影像大約在 2 分鐘內計算完成。

十、深度學習模型部署

模型部署為整個森林物件自動化萃取的重要關鍵，本計畫將考量未來預測資料量與使用頻率進行規劃，並將訓練好的模型嵌入農航所現有之影像處理架構中。一般模型部署上採用 http 的網站或 API 服務，不過考量到航攝影像之檔案大小，未來應採用 python 套件形式或是打包好的 exe 程式檔案，並依照農航所的作業系統進行設計，部署在農航所內部的伺服器進行運算，以加速資料分析之流程。

第柒章、教育訓練

7-1 教育訓練規劃

本計畫依契約已於 109 年 10 月 26 日(一) 09:20~16:00 完成教育訓練課程之辦理，報告與分享內容由本計畫團隊參與人員準備，包含「鍾智昕教授_機器學習應用於林業之相關實例與文獻回顧(60 分鐘)」、「鄭錦桐博士_本計畫現況成果與未來規劃(60 分鐘)」與「王選仲研發工程師_農航所之 AI 實務 - 以林型判釋為例(90 分鐘)」。教育訓練議程表如表 7-1，當日教育訓練相片與簽到紀錄如圖 7-1 至圖 7-3 所示，簡報內容則收錄於本計畫附錄。

表 7-1 教育訓練議程表

時間	時數	課程名稱	講師
09:20-09:30	10 分	報到入座	-
09:30-10:30	60 分	機器學習應用於林業之相關實例與文獻回顧	鍾智昕教授 (宜蘭大學)
10:30-10:40	10 分	休息時間/交流	-
10:40-11:40	60 分	本計畫現況成果與未來規劃	鄭錦桐博士 (興創知能)
11:40-12:00	10 分	綜合討論	-
12:00-14:00	午休時間		
14:00-15:30	90 分	農航所之 AI 實務 -- 以林型判釋為例	王選仲研發工程師 (興創知能)
15:30-16:00	30 分	綜合討論	-

圖 7-1 教育訓練照片記錄

行政院農業委員會林務局農林航空測量所

「機器學習於航攝影像森林覆蓋型萃取之研究(1/3)」案

教育訓練簽到單

時間：109 年 10 月 26 日（一）

課程地點：本所 201 會議室

講師：宜蘭大學鍾智昕教授、興創知能股份有限公司鄭錦桐博士、王選仲技術研發講師

單位/課室	職稱	姓名	午餐
			☐葷 ☐素
			☑葷 ☐素
宜蘭大學	助理教授	鍾智昕	☑葷 ☐素
興創	RD	吳笙絳	☑葷 ☐素
興創	工程師	王選仲	☑葷 ☐素
			☐葷 ☐素
			☐葷 ☐素
			☐葷 ☐素
			☐葷 ☐素

圖 7-2 教育訓練簽到表(1/2)

單位/課室	職稱	姓名	午餐
			□葷 □素
			□葷 □素
			□葷 □素
調查課	課長	鄧國禮	☑葷 □素
	技士	蔡[illegible]	☑葷 □素
	技士	郭宇文	☑葷 □素
	技士	張[illegible]	~~□葷 □素~~
	技士	黃宗仁	☑葷 □素
空測課	技士	蔡仲[illegible]	☑葷 □素
			□葷 □素
			□葷 □素
			□葷 □素
			□葷 □素

圖 7-3 教育訓練簽到表(2/2)

7-2 研討會投稿規劃

本計畫針對純林樹種建立廣域深度學習分類方法，實有其學術研究價值，過程中為了完成自動化作業，亦開發許多高效率影像處理工具，都是未來能夠發表曝光之議題。此外，本計畫團隊長期關

注國內外重要研討會及論文徵稿活動，並盤點相關國內外重要研討會如表 7-2 所示，雖然今年度因疫情影響許多會議活動因此取消，但相關資訊蒐集應持續進行，並與貴所共同研擬投稿內容。

表 7-2 國內外重要研討會列表

區域	會議名稱	日期	地點	簡述
國外	ISRS(International Symposium on Remote Sensing)	2020/04/20-22 (因疫情暫停)	韓國 釜山	國際年度舉辦的遙測學術交流活動
國內	TGA 地球物理年會	2020/11/17-18 (因疫情延後)	台灣 台北	國內年度舉辦的地球科學學術交流活動
國外	ISPRS(International Society for Photogrammetry and Remote Sensing)	2021/07 (因疫情延後)	法國 尼斯	全球四年舉辦一次的遙測學術交流活動
國內	SG 測量及空間資訊研討會	2020/08/27-28 (因疫情延後)	台灣 台北	國內年度舉辦的測量學學術交流活動
國外	ACRS(Asian Conference on Remote Sensing)	2020/11/09-13	中國 德清	亞洲區域年度舉辦的遙測學術交流活動

第捌章、結論建議與續期規劃

8-1 結論

本計畫基於深度學習方法，搭配貴所大量航攝影像，設計森林物件萃取模型，對特定樹種進行分類判釋，以自動化作業為目標建立萃取標準化流程。今年度針對 11 類樹種 718 幅航攝影像，以 11 項特徵參數建構深度學習模型，整體準確率達 65.3%，Kappa 值為 0.618，以下就各項工作說明主要之成果。

一、資料蒐集

透過 60 篇文獻回顧之理解，機器學習方法對於判釋樹種分類已漸趨成熟，但深度學習方法尚未普遍被使用。除此之外，大部分研究仍以特定案例為目標，較少考慮廣域實作可能遇到的自動化問題。為了優化既定作業，本計畫採用第四次森林資源調查林型圖之純林作為訓練目標，篩選 2007 年至 2014 年 718 幅航攝影像，並研析波段參數與地形參數以強化樹種分類之訓練成果。

二、航遙測影像分類技術之分析與功能評估

本計畫針對常見的遙測影像演算方法進行研析與比對，以確保實作設計過程能夠取其優點、捨棄缺點。就開發平台而言，現行 GIS 平台百家爭鳴，各種軟體功能強大，能夠容納許多演算法。然而，這些軟體普遍適用於專案形式的開發工作，而針對系統性的自動化作業，卻有許多操作上的不便利。因此本計畫採用 Python 以開源程式碼進行客製化開發，從根本解決操作效率之問題。

三、深度學習演算法之研究探討

本計畫基於樹種影像資料判讀之高度複雜性，歸納文獻回顧之使用方法，決定以深度學習中的卷積神經網路(CNN)進行模型之設計。使用常見 Tensorflow 與 Keras 深度學習開發套件，並且在 Python Jupyter 的編譯環境下，以實現自動化作業為目標進行開發。

四、森林物件萃取標準化流程雛型之建立

為了實現自動化作業，本計畫執行期間已透過攝影測量方法解決林型圖框標記資料反投影後圖框交叉錯位之問題。此外，亦根據文獻蒐整與實際測試，選定 5 項波段特徵與 6 項地形特徵進行樹種辨識之訓練。同時在資料前處理與模型訓練過程中，建構完整的自動化操作流程。最終於今年度完成 11 類樹種分類辨識之模型建構。

五、教育訓練

本計畫於計畫執行之尾聲辦理教育訓練，將計畫文獻蒐集成果與程式開發實作的過程，與執行機關相關業務同仁進行分享，除了協助貴所充分了解執行細節，亦從中汲取寶貴經驗協助成果品管，在延續計畫中設計出更符合貴所實務應用需求之軟體。

8-2 建議

本計畫建構純林樹種分類模型，雖已有顯著的辨識成果，但依然存在部分問題，包含林型圖框系統性偏移、特定樹種資料量不足...等。為確實提升模型精度，研擬相關建議以期做為貴所下一年度計畫改善與執行之方向。

一、森林分類流程實作

研究高解析度航攝及 UAV 影像以機器學習技術自動化萃取森林覆蓋型之演算模式與實作。建議以反投影系統性偏移之校正，以及增加樹種標記資料為主。考慮森林物種調查的頻率，本研究認為 DEM 資料雖更新頻率慢，但也能作為本次訓練參數之一，又考量到森林樹冠高程之不可忽略性，嘗試將 DEM 改以 DSM 進行反投影對位，並以強制對位方式提升圖框套疊精準度；此外，為補充訓練樣本數的不足，可增加不同時期的航攝影像、正射影像或無人機影像，讓訓練樣本數量提升至 3,000 筆之上。

二、運算資源效能測試

延續今年度的實作開發工作，應評估機器學習相關軟體與國內高速運算資源及測試，以自動化作業為目標，詳實紀錄各階段操作、運算時效，以滿足巨量高解析航攝影像、數值地形模型運算分析之負載。

三、處理效能提升方案

延續今年度的模型訓練工作，應研究機器學習演算法及流程效能提升方案。除了可透過增加不同季節拍攝之影像，增加物候對於林木生長之辨識特徵，亦可增加光學影像複合式的植被指標與背坡面的陰影特徵，來強化模型特徵之辨識。

四、森林分類流程建置

延續今年度的流程設計工作，應以機器學習技術自動萃取森林物件特徵演算法評估測試與調查流程建置。基於現階段樹種分類深度學習模型開發成果，規劃軟硬體需求與實作介面設計，以符合貴所自動化森林物件作業之目標。本年度先以純林為判釋目

標，測試以機器學習分類樹種之可行性，待第 2、3 年將加入混淆林型之分類，期許能夠有效輔助現行森林人工判釋之流程。

五、教育訓練與期刊投稿

延續今年度執行計畫，規劃投稿至少 1 篇論文至國內外期刊或研討會。同時，應持續辦理教育訓練，以其計畫成果能順利為貴所既定業務所用。

參考文獻

1. 行政院農業委員會林務局(2006)從京都議定書看台灣的森林資源調查。

2. 行政院農業委員會林務局(2011a)第四次森林資源調查報告。

3. 行政院農業委員會林務局(2011b)航照數位多光譜影像於林地經營管理上之應用。100 年度科技計畫研究報告。

4. 行政院農業委員會林務局(2013)高解析度多光譜影像於森林資源調查之應用。102 年度科技計畫研究報告。

5. 行政院農業委員會林務局(2014) 臺灣地區常見景觀樹種及農作物立體像對判釋之研究。103 年度科技計畫研究報告。

6. 行政院農業委員會林務局(2018)森林資源調查暨國有林事業區檢訂土地覆蓋型及航照樣點圖資更新作業手冊。

7. 行政院農業委員會林務局(2019)應用高光譜航遙測影像於土地覆蓋型調查之研究。109 年度林務局委託研究計畫。

8. 邱祈榮(2002)國有林檢訂調查制度之探討。91 年林務局委託研究計畫。

9. 馮豐隆(2005)森林測計學。中興大學森林學系。

10. Alonzo, M., Bookhagen, B., and Roberts, D. (2014) Urban tree species mapping using hyperspectral and lidar data fusion. Remote Sensing of Environment, 148, 70-83. https://doi.org/10.1016/j.rse.2014.03.018.

11. Anderson, C. B. (2018) Biodiversity monitoring, earth observations and the ecology of scale. Ecol. Lett. 21, 1572–1585.

12. Arief, H. A., G.-H. Strand, H. Tveite, and U. G. Indahl. (2018) Land cover segmentation of airborne LiDAR data using stochastic atrous network. Remote Sens. 10, 973. https://doi.org/10.3390/rs10060973

13. Avery T. E. 1996. Forester's Guide to Aerial Photo Interpretation. U.S. Department of Agriculture. Agricultural Handbook 308, Washington D.C., U.S.A.

14. Baena, S., Moat,, J., Whaley O., Boyd, D,S. (2017) Identifying species from the air: UAVs and the very high resolution challenge for plant conservation. PLoS ONE 12(11): e0188714. https://doi.org/10.1371/journal.pone.0188714.

15. Bay, H., Tuytelaars, T., Van Gool, L. (2006) SURF: Speeded Up Robust Features. Springer, Berlin, Heidelberg, pp 404–417.

16. Botella, C., Joly, A., Bonnet, P., Monestiez, P., Munoz F. (2017) A deep learning approach to Species Distribution Modelling. Multimedia Tools and Applications for Environmental & Biodiversity Informatics, Springer, pp.169-199.

17. Cavallini, Paolo (2007). Free GIS desktop and analyses: QuantumGIS, the easy way. The Global Geospatial Magazine. http://www.gisdevelopment.net/magazine/global/2007/august/62_1.htm

18. Chen, Y., Lu, D., Luo, G., and Huang, J. (2015) Detection of vegetation abundance change in the alpine tree line using multitemporal Landsat Thematic Mapper imagery. International Journal of Remote Sensing, 36, 4683-4701. https://doi.org/10.1080/01431161.2015.1088675.

19. Dabiri, Z., Lang, S. (2018) Spectral-Spatial Dimensionality Reduction of APEX Hyperspectral Imagery for Tree Species Classification; a Case Study of Salzach Riparian Mixed Forest. doi:10.20944/preprints201806.0188.v1

20. Dos Santos, A. A.; Marcato Junior, J., Araújo, M.S., Di Martini, D.R.,Tetila, E.C., Siqueira, H.L., Aoki, C., Eltner, A., Matsubara, E.T., Pistori, H., Feitosa, R.Q., Liesenberg, V., Gonçalves, W.N. (2019) Assessment of CNN-Based Methods for Individual Tree Detection on

Images Captured by RGB Cameras Attached to UAVs. Sensors, 19, 3595.

21. Fassnacht, F., Latifi, H., Sterenczak, K., Modzelewska, A., Lefsky, M., Waser, L., Straub, C., and Ghosh, A. (2016) Review of studies on tree species classification from remotely sensed data. Remote Sensing of Environment, 186, 64-87. https://doi.org/10.1016/j.rse.2016.08.013.

22. Feng, X. and Li, P. A. (2019) Tree Species Mapping Method from UAV Images over Urban Area Using Similarity in Tree-Crown Object Histograms. Remote Sens., 11, 1982; doi:10.3390/rs11171982

23. Feret, J.B., Asner, G. P. (2012) Tree Species Discrimination in Tropical Forests Using Airborne Imaging Spectroscopy. IEEE Transactions on Geoscience and Remote Sensing, 51(1):73 – 84.

24. Ferreira, M. P., Zortea, M., Zanotta, D. C., Shimabukuro, Y. E., Filho, C. R. de Sa. (2016) Mapping tree species in tropical seasonal semi-deciduous forests with hyperspectral and multispectral data. Remote Sensing of Environment 179, 66–78.

25. Franklin, (2018) Pixel- and object-based multispectral classification of forest tree species from small unmanned aerial vehicles. Journal of Unmanned Vehicle Systems. 6(4): 195-211.

26. Franklin, S. E., Ahmed, O. S., Williams, G. (2017) Northern Conifer Forest Species Classification Using Multispectral Data Acquired from an Unmanned Aerial Vehicle. Photogrammetric Engineering & Remote Sensing, 83(7), pp. 501–507.

27. Fricker, G. A.; Ventura, J. D., Wolf, J. A., North, M. P., Davis, F. W., Franklin, J. (2019) A Convolutional Neural Network Classifier Identifies Tree Species in Mixed-Conifer Forest from Hyperspectral Imagery. Remote Sensing, 11(19), p.2326

28. Garzon-Lopez, C. X., Bohlman, S. A., Olff, H., Jansen P. A., (2013) Mapping Tropical Forest Trees Using High-Resolution Aerial Digital

Photographs. BIOTROPICA 45(3): 308–316.https://doi.org/10.1111/btp.12009.

29. Ghazia, M. M., Yanikoglu, B., Aptoula, E. (2017) Plant identification using deep neural networks via optimization of transfer learning parameters. Neurocomputing 235, 228–235.

30. Ghimire, B., Rogan, J., Miller, J. (2010) Contextual landcover classification: Incorporating spatial dependence in land-cover classification models using random forests and the Getis statistic. Remote Sensing Letters, 1, 45–54. doi:10.1080/01431160903252327.

31. Ghosh, A., Fassnacht, F Goldenshluger, A., Zeevi, A. (2004) The Hough Transform Estimator. 32:. https://doi.org/10.1214/009053604000000760.

32. Ghosh, A., Fassnacht, F.E., Joshi, P.K., Koch, B. (2014) A framework for mapping tree species combining hyperspectral and LiDAR data: Role of selected classifiers and sensor across three spatial scales. International Journal of Applied Erath Observation and Geoinformation, 26, 49–63. doi:10.1016/j.jag.2013.05.017.

33. Hartling S., Sagan, V., Sidike, P., Maimaitijiang, M., Carron, J. (2019) Urban Tree Species Classification Using a WorldView-2/3 and LiDAR Data Fusion Approach and Deep Learning. Sensors 19, 1284; doi:10.3390/s19061284

34. Hershey, R. R., Befort, W. A. (1995) Aerial photo guide to new England forest cover types. United States Department of Agriculture. General Technical Report NE- 195.

35. Hesketh, M., Sánchez-Azofeifa, G. A. (2012) The effect of seasonal spectral variation on species classification in the Panamanian tropical forest. Remote Sensing of Environment 118:73–82.

36. Hill, R.A., Wilson, A.K., George, M., Hinsley, S.A., (2010) Mapping tree species in temperate deciduous woodland using time-series multi-spectral data. Applied Vegetation Science · February.

37. Huang, B., Lu, K., Audebert, N., Khalel, A., Tarabalka,Y., Malof, J. (2018) Large-scale semantic classification: outcome of the first year of Inria aerial image labeling benchmark. in IEEE International Geoscience and Remote Sensing Symposium – IGARSS 2018, Valencia, Spain. https://hal.inria.fr/hal-01767807

38. Immitzer, M., Atzberger, C., Koukal, T., (2012) Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data. Remote Sensing 4(9):2661-2693.

39. Kampen, M., Lederbauer, S, Mund, J.-P. and Immitzer M. (2019) UAV-Based Multispectral Data for Tree Species Classification and Tree Vitality Analysis. Dreiländertagung der DGPF, der OVG und der SGPF in Wien, Österreich – Publikationen der DGPF, Band 28, 2019

40. Karami, E., Shehata, M., Smith, A. (2017) Image Identification Using SIFT Algorithm: Performance Analysis against Different Image Deformations.

41. Karathanassi, V., Kolokousis, P., and Ioannidou, S. (2007) A comparison study on fusion methods using evaluation indicators. International Journal of Remote Sensing, 28, 2309-2341. https://doi.org/10.1080/01431160600606890.

42. Kim S., McGaughey R. J., Andersen H.-E., Schreuder G. (2009) Tree species differentiation using intensity data derived from leaf-on and leaf-off airborne laser scanner data. Remote Sensing of Environment. 113: 1575-1586.

43. Knauer, U., von Rekowski, C.S., Stecklina, M., Krokotsch, T., Pham Minh, T., Hauffe, V., Kilias, D., Ehrhardt, I., Sagischewski, H., Chmara, S., Seiffert, U. (2019) Tree Species Classification Based on

Hybrid Ensembles of a Convolutional Neural Network (CNN) and Random Forest Classifiers. Remote Sensing 11(23):2788

44. Korpela I., Mehtätalo L., Markelin L., Seppänen A., Kangas A. 2014. Tree species identification in aerial image data using directional reflectance signatures. Silva Fennica 48(3) article id 1087. 20 p.

45. Kou, W., Dong, J., Xiao, X., Hernandez, A., Qin, Y., Zhang, G., Chen, B., Lu, N., and Doughty, R. (2018) Expansion dynamics of deciduous rubber plantations in Xishuangbanna, China during 2000–2010. GIScience & Remote Sensing, 1-21. https://doi.org/10.1080/15481603.2018.1466441.

46. Krizhevsky, A., I. Sutskever, and G. E. Hinton. (2012) ImageNet classification with deep convolutional neural networks. Pp. 1097–1105 in F. Pereira, C. J. C. Burges, L. Bottou and K. Q. Weinberger, eds. Advances in neural information processing systems 25. Curran Associates, Inc., MIT Press, Cambridge, MA. http://papers.nips.cc/paper/ 4824-imagenet-classification-with-deep-convolutional-neura l-networks.pdf

47. Kulikova M. S., Mani M., Srivastava A., Descombes X., Zerubia J.(2007) Tree species classification using radiometry, texture and shape based features. 2007 15th European Signal Processing Conference.

48. Lecun,Y., Bottou, L., Bengio, Y., Haffner, P., (1998) Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278-2324.

49. Liao W.,Van Coillie F.,Gao L.,Li, L., Zhang, B., Chanussot, J. (2018) Deep Learning for Fusion of APEX Hyperspectral and Full-Waveform LiDAR Remote Sensing Data for Tree Species Mapping. IEEE Access, 6, 68716 – 68729.

50. Liu, N. and Kan, J.-M. (2016) Plant leaf identification based on the multi-feature fusion and deep belief networks method," Journal of Beijing Forestry University, vol. 38, no. 3, pp. 110–119.

51. Liu, Y., Zhong,Y., Fei, F., Zhu, Q., and Qin, Q. (2018) Scene classification based on a deep random-scale stretched convolutional neural network. Remote Sens. 10, 444.

52. Machala, M.; Zejdová, L. Forest mapping through object-based image analysis of multispectral and LiDAR aerial data. Eur. J. Remote Sens. 2014, 47, 117–131.

53. Michez A., Piégay H., Lisein J., Claessens H., Lejeune P. (2016) Classification of Riparian Forest Species and Health Condition Using Multi-Temporal and Hyperspatial Imagery From Unmanned Aerial System. Environ Monit Assess, 188(3):146. doi: 10.1007/s10661-015-4996-2. Epub 2016 Feb 5.

54. Michez, A., Piégay H., Lisein J., Claessens H., Lejeune P. (2016) Classification of Riparian Forest Species and Health Condition Using Multi-Temporal and Hyperspatial Imagery From Unmanned Aerial System. Environ Monit Assess. 188(3):146.

55. Morgan J. L., Gergel S. E., Coops N. C. (2010) Aerial Photography: A Rapidly Evolving Tool for Ecological Management. BioScience 60(1):47-59.

56. Nevalainen, O., Honkavaara, E., Tuominen, S., Viljanen, N., Hakala, T., Yu, X., Hyyppä, J., Saari, H., Pölönen, I., Imai, N.N., Tommaselli, A.M.G. (2017) Individual Tree Detection and Classification with UAV-Based Photogrammetric Point Clouds and Hyperspectral Imaging. Remote Sens., 9, 185.

57. Nezami, S., Khoramshahi, E., Nevalainen, O., Pölönen, I., Honkavaara, E. (2020) Tree Species Classification of Drone Hyperspectral and RGB Imagery with Deep Learning Convolutional Neural Networks. Remote Sens. 1070.

58. Nilsback, M.-E. and Zisserman, A., (2010) Delving deeper into the whorl of flower segmentation, Image and Vision Computing, vol. 28, no. 6, pp. 1049–1062

59. Omer, G., Mutanga, O., Abdel-Rahman, E.M., & Adam, E. (2015). Performance of support vector machines and artificial neural network for mapping endangered tree species using WorldView-2 data in Dukuduku forest, South Africa. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 8(10), 4825– 4840. doi:10.1109/JSTARS.2015.2461136

60. O'Mahony, N., Murphy, T., Panduru, K. (2017) Real-time monitoring of powder blend composition using near infrared spectroscopy. In: 2017 Eleventh International Conference on Sensing Technology (ICST). IEEE, pp 1–6.

61. Pal, M. (2005) Random forest classifier for remote sensing classification. International Journal of Remote Sensing, 26 (1), 217–222. doi:10.1080/01431160412331269698

62. Peerbhay, K., Mutanga, O., & Ismail, R. (2013) Commercial tree species discrimination using airborne AISA Eagle hyperspectral imagery and partial least squares discriminant analysis (PLS-DA) in KwaZulu Natal, South Africa. ISPRS Journal of Photogrammetry and Remote Sensing, 79, 19–28. doi:10.1016/j.isprsjprs.2013.01.013

63. Pereira C. S., Morais R. and Reis M. J. C. S. (2019) Deep Learning Techniques for Grape Plant Species Identification in Natural Images. Sensors 2019, 19, 4850; doi:10.3390/s19224850

64. Priedītis, G., Šmits, I., Daģis, S., Paura, L., Krūmiņš, J., & Dubrovskis, D. (2015). Assessment of hyperspectral data analysis methods to classify tree species. Research for Rural Development, 2, 7–13.

65. Pu R.L., Landry S. (2012) A comparative analysis of high spatial resolution IKONOS and WorldView-2 imagery for mapping urban tree species. Remote Sensing of Environment, 124, 516–533.

66. Puttonen E., Litkey P., Hyyppä, J. (2010) Tree Species Classification by Illuminated—Shaded Area Separation Remote Sens. 2, 19-35; doi:10.3390/rs2010019.

67. Raczko E. and Zagajewski B. (2017) Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images. EUROPEAN JOURNAL OF REMOTE SENSING, 2017 VOL. 50, NO. 1, 144–154. https://doi.org/10.1080/22797254.2017.1299557

68. Rafieyan O., Darvishsefat A. A., Babaii S., Mataji A. (2009) Object-based classification using UltraCam-D images for tree species discrimination (case study: Hyrcanian forest-Iran). The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXVIII-4/C7, Commission VI, WG IV/4, 6 pages

69. Ronneberger, O., P. Fischer, and T. Brox. (2015) U-Net: convolutional networks for biomedical image segmentation. CoRR, abs/1505.04597, http://arxiv.org/abs/1505.04597

70. Rosten, E., Drummond, T. (2006) Machine Learning for High-Speed Corner Detection. Springer, Berlin, Heidelberg, pp 430–443.

71. Saatchi S., Rignot E. (1997) Classification of boreal forest cover types using SAR images. Remote Sensing of Environment, 60, 270–281.

72. Sedliak, M., Sačkov, I., Kulla, L. (2017) Classification of tree species composition using a combination of multispectral imagery and airborne laser scanning data. Cent. Eur. For. J. 63, p1–9.

73. Settle J.J., Briggs S.A. (1987) Fast maximum-likelihood classification of remotely sensed imagery. International Journal of Remote Sensing, 8, 723–734.

74. Shang, X., and Chisholm, L. (2014) Classification of Australian native forest species using hyperspectral remote sensing and machine-learning classification algorithms. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 7, 2481-2489. https://doi.org/10.1109/JSTARS.2013.2282166.

75. Shen, G., Sakai, K., & Hoshino, Y. (2010) High spatial resolution hyperspectral mapping for forest ecosystem at tree species level. Agricultural Information Research,19(3), 71–78. doi:10.3173/air.19.71

76. Sheng, Y., Peng G, and Gregory S. B. (2003) True Orthoimage Production for Forested Areas from Large-Scale Aerial Photographs" Photogrammetric Engineering & Remote Sensing, , vol. 69, no. 3, pp. 259-266

77. Shi, Y., Wang, T., Skidmore,A. K., Heurich M. (2020) Improving LiDAR-based tree species mapping in Central European mixed forests using multi-temporal digital aerial colour-infrared photographs. International Journal of Applied Earth Observation and Geoinformation, 84, 101970.

78. Shojanoori R., Shafri H. Z.M., Mansor S., Ismail M. H. (2016) The Use of WorldView-2 Satellite Data in Urban Tree Species Mapping by Object-Based Image Analysis Technique. Sains Malaysiana 45(7): 1025–1034

79. Simon, E., Leandro, B., Kyoko, M., Todd, N., Kiyoto, T. (2006) IPCC Guidelines for National Greenhouse Gas Inventories. Institute for Global Environmental Strategies (IGES) for the IPCC, https://www.ipcc-nggip.iges.or.jp/public/2006gl/

80. Singh M., Evans D., Tan B. S., Nin C. S. (2015) Mapping and Characterizing Selected Canopy Tree Species at the Angkor World Heritage Site in Cambodia Using Aerial Data. PLOS ONE 11(4): e0154548. https://doi.org/10.1371/journal.pone.0154548.

81. Sothe, C., Dalponte, M., de Almeida, Schimalski M. B. (2019) Tree Species Classification in a Highly Diverse Subtropical Forest Integrating UAV-Based Photogrammetric Point Cloud and Hyperspectral Data. Remote Sensing 11(11):1338.

82. Stavrakoudis, D. G., Dragozi, E., Gitas, I.Z., Karydas, C.G. (2014) Decision Fusion Based on Hyperspectral and Multispectral Satellite Imagery for Accurate Forest Species Mapping. Remote Sens. 6, 6897-6928.

83. Sun, Y., Huang, J., Ao Z., Lao, D. (2019) Deep Learning Approaches for the Mapping of Tree Species Diversity in a Tropical Wetland Using Airborne LiDAR and High-Spatial-Resolution Remote Sensing Images. Forests 10(11):1047

84. Sun, Y., Liu, Y., Wang, G., and Zhang, H. (2017) Deep Learning for Plant Identification in Natural Environment. Computational Intelligence and Neuroscience, Vol. 2017, Article ID 7361042, 6 pages, https://doi.org/10.1155/2017/7361042

85. Sun, Y., Zhang, X., Xin, Q., and Huang, J. (2018) Developing amulti-filter convolutional neural network for semantic segmentation using high-resolution aerial imagery and LiDAR data. ISPRS J. Photogramm. Remote Sens. 143, 3–14. https://doi.org/10.1016/j.isprsjprs.2018.06.005

86. Tsai, F.C.D (1994) Geometric hashing with line features. Pattern Recognit 27:377–389. https://doi.org/10.1016/0031-3203(94)90115-5.

87. Verlič, A., Đurić, N., Kokalj, Ž., Marsetič A., Simončič P. and Oštir K. (2014) Tree Species Classification using WorldView-2 Satellite

Images and Laser Scanning Data in a natural Urban Forest. Šumarski list, 9–10, CXXXVIII, 477–488.

88. Virtanen, T., Mikkola, K., Nikula, A. (2016) Satellite image based vegetation classification of a large area using limited ground reference data: a case study in the Usa Basin, north-east European Russia. Polar Research 23(1), 51–66. https://doi.org/10.3402/polar.v23i1.6266.

89. Voulodimos, A., Doulamis, N., Doulamis, A., Protopapadakis, E. (2018) Deep Learning for Computer Vision: A Brief Review. Comput Intell Neurosci 2018:1–13. https://doi.org/10.1155/2018/7068349

90. Wagner F.H., Sanchez A., Aidar M.P.M., Rochelle A.L.C., Tarabalka Y., Fonseca M.G. (2020) Mapping Atlantic rainforest degradation and regeneration history with indicator species using convolutional network. PLoS ONE 15(2): e0229448. https://doi.org/10.1371/journal.pone.0229448.

91. Wagner, F. H., Sanchez, A., Tarabalka, Y., Lotte, R. G., Ferreira, M. P., Aidar, M. P. M., Gloor, E., Phillips, O. L., Aragão, L. E. O. C. (2019) Using the U-net convolutional network to map forest types and disturbance in the Atlantic rainforest with very high resolution images. Remote Sensing in Ecology and Conservation. 05 March 2019 https://doi.org/10.1002/rse2.111.

92. Warner, T. A., McGraw J. B. and Landenberger R. (2006) Segmentation and classification of high resolution imagery for mapping individual species in a closed canopy, deciduous forest. Science in China Series E: Technological Sciences volume 49, pages128–139

93. Waser L.T., Ginzler C., Kuechler M., Baltsavias, E., Hurni L. (2011) Semi-automatic classification of tree species in different forest ecosystems by spectral and geometric variables derived from Airborne Digital Sensor (ADS40) and RC30 data. Remote Sensing of Environment 115(1):76-85.

94. Weil, G.; Lensky, I.M.; Resheff, Y.S.; Levin, N. (2017) Optimizing the Timing of Unmanned Aerial Vehicle Image Acquisition for Applied Mapping of Woody Vegetation Species Using Feature Selection. Remote Sens. 9, 1130.

95. Weinstein B. G.,Marconi S., Bohlman S. A.,Zare A.,White E. P. (2020) Cross-site learning in deep learning RGB tree crown detection. Ecological Informatics. 56, March 2020, 101061

96. Wright J., Lillesand T.M., Kiefer R.W. (1980) Remote sensing and image interpretation. The Geographical Journal, 146, 448–449.

97. Xie, Z., Chen, Y., Lu, D., Li, G., and Chen, E. (2019) Classification of land cover, forest, and tree species classes with ZiYuan-3 multispectral and stereo Data. Remote Sensing, 11, 164. https://doi.org/10.3390/rs11020164

98. Yu, X.; Hyyppä, J.; Litkey, P.; Kaartinen, H.; Vastaranta, M.; Holopainen, M. (2017) Single-Sensor Solution to Tree Species Classification Using Multispectral Airborne Laser Scanning. Remote Sens. 9, 108.

99. Zadeh, L. A. (1965) Fuzzy Sets, INFOR~ATIO~AND CONTROL, 8, 338–353.

100. Zhang, C., and Xie, Z. (2013) Object-based vegetation mapping in the Kissimmee river Watershed using HyMap data and machine learning techniques. Wetlands, 33, 233-244. https://doi.org/10.1007/s13157-012-0373-x

附錄一 相關名詞及其說明

名詞	名詞說明
航空照片	由航攝飛機攜帶精密空中照相機自空中向下垂直或傾斜攝影，將地面上地物、地貌作永久真實記錄。
相片基本圖	以垂直航攝像片為底圖，在像片上加繪等高線及必要之地物註記等，製成像片地形圖，並以此作為國家基本圖者，稱為像片基本圖。
正射影像	經過幾何糾正的航攝像片。農航所提供的正射影像為藉由空中 GPS 儀器搭載 IMU，經解算獲取相機拍攝瞬間位置及姿態，搭配 DTM 糾正成正射投影，加註說明製成正射影像。
常態化差值植生指標	Normalized Difference Vegetation Index，NDVI。透過影像的紅光波段與近紅外光波段計算而得，以評估目標地區綠色植被的生長狀況。
數值地形模型	Digital Terrain Model，DTM。用數值座標表示的地形模型，即用三度空間坐標值來表示地表位置和高程的一種模式。
數值高程模型	Digital Elevation Model，DEM。紀錄地形的高程資訊。
數值表面模型	Digital Surface Model，DSM。除了紀錄地形高程資訊，也保留了地表以上的物件高程資訊。
坡度	Slope。坡度為單位距離的高度差，可定義為兩點之高程與水平距離之比值，以角度表示。
坡向	Aspect。坡向反映斜坡的方向，定義為曲面上某點的切平面法線的正方向與正北方之夾角。
地形位置指數	Topographic Position Index，TPI。表示 DEM 相鄰網格之間的高程差。
地形堅固指數	Topographic Ruggedness Index，TRI。表示 DEM 相鄰網格之間的高程差平均。
粗糙度	Roughness，粗糙度為地形的變異程度，主要利用數值統計的方法來表示地表平坦、地形高差變化的參數。
人工智慧	Artificial Intelligence，AI。電腦科學中的一個領域，致力於應用電腦及其他相關科技來完成類似人類智慧可以做得到的工作。
機器學習	Machine Learning。人工智慧中，使電腦能根據已往累積的經驗，經歸納與綜合來改進自身的性能，建立學習模式，使電腦具有智能及學習能力的學科。
監督式分類	先行建立每項判釋類別的訓練樣本，包含許多從已知判釋類別影像獲取的資料，以利分類判斷，準確率較高。
非監督式分類	不需要訓練樣本資料，由電腦自行依特徵向量判斷，常用於較不熟悉或快速取得大量判釋成果。

名詞	名詞說明
紋理分析法	針對紋理特徵之萃取並分析，較適合運用於疏密粗細有清楚區分之紋理特徵。
模糊分析法	在是非之間存在灰色地帶，不確定事物的歸屬可用概率方式加以表示，以顯示其模糊與不確定性。
卷積神經網路	Convolutional Neural Network，CNN。透過卷積數學運算方法，對圖像進行特徵擷取的動作，更正確的解決分類問題。
深度神經網路	Deep Neural Netorks，DNN。透過每層神經元階層及架構的多次線性或非線性運算及訓練，找出最佳化、最有效的深度學習模型。
U-Net	一種 CNN 法，將整張圖片放入模型做圖像分割。
超參數	Hyper Parameter。機器學習中控制模型生長條件的參數。
林型	森林受生態條件的影響，其生長條件相似、性質相同的林木，聚生為一個集團所表現的森林形態。
樹種	樹的種類。
紋理	Texture。物體表面固有的一種特性，根據影像表面結構之粗細，可識別物體之類別。
圖案	Pattern。目標物件於空間中之排列情形。
立地	Site。目標物件所處之環境狀態。
局部評價	對每張裁切後影像分類準確度進行評價。
全域評價	重新組合預測成果，與人工標記的多邊形進行比對，又稱檢測評價(IOU)。
使用者精度	User’s Accuracy，UA。在分類結果中實際為 A 樣本佔分類為 A 樣本的比值。
生產者精度	Producer’s Accuracy，PA。分類為 A 樣本佔實際為 A 樣本的比值。
整體精度	Overall Accuracy，OA。分類正確的樣本數佔總樣本數的比值。
Kappa 指標	Kappa 指標為表示分類成果與檢核資料相似程度的指數，範圍為 0 到 1，值愈大代表分類精度愈高
物候	物候，全名為『生物氣候』，主要是指週期性的生物律動發生的時間，諸如候鳥遷徙的季節，植物抽芽、開花、結果的時間，以及昆蟲活動變化的季節性等，而物候學(phenology)即是對週期性的生物律動進行研究的一門學問。
檢訂調查	在林業經營上，如何對森林基本資料及森林資源作有效的掌握，乃經營決策的基本需求。因此在國有林經營計畫編定前，即開始實施所謂的檢訂調查，以收集編定計畫時所需之資訊。在森林生態系經營的理念下，檢訂調查特別強調「適應性經營」之理念，透過調查了解土況與林況，已達蓄積量評估之依據。

名詞	名詞說明
林分	林分為森林之一部份，有許多樹木聚生在一定面積之林地上，其樹種或樹齡之構成等皆成均齊狀態，足能與森林中之其他鄰接地區之森林區別者謂之。
林型	森林受生態條件的影響，其生長條件相似、性質相同的林木，聚生為一個集團所表現的森林形態。
林班	林班(Forest Compartment)在林業經營上解釋是，為了長久管理方便所定義的林區單元，係由事業區中依地形地勢進行分割，通常使用阿拉伯數連續表示。
模型訓練	通常一開始會隨機決定一組資料，帶入先前準備好的標記資料得到結果，並比較此結果與預期結果之間的差值，持續調整並縮小差值。最後得到差值最小的演算法，此過程即為模型訓練。
森林蓄積	森林受生態條件的影響，其生長條件相似、性質相同的林木，聚生為一個集團所表現的森林形態。
永久樣區	所謂永久樣區(Permanent Sampling Plot，PSP)係指一個取樣單位在設置及記錄之後，可持續於下一次的調查工作中，在相同位置進行重覆測量，以了解不同時間狀態之變化。林務局於全台設置永久樣區，進行長期監測以觀測林分生長，森林組成、結構、蓄積等動態變化和對不同林分處理反應之狀況。
系統樣區	與永久樣區有相同之設置目的，透過系統樣區的地面樣區及航照樣點的調查，分別獲得全國尺度及林分尺度的蓄積數據。有別於永久樣區的選定，系統樣區以更為客觀的選取方式，平均散佈於全台森林範圍。
光譜類別	指分類結果都屬於光譜資訊。
資訊類別	指分類結果帶有使用者想知道的資訊，如地物分類等。
優勢方位	對於某種紋理或特徵，容易發生在特定方位上。
四叉樹	是一種樹狀資料結構，在每一個節點上會有四個子區塊。四元樹常應用於二維空間資料的分析與分類。
超參數	機器學習模型訓練時，人為調整的參數，如迭代次數、隱藏層數

附錄二 各階段審查意見與回覆情形

一、期初審查意見與回覆情形

意見說明	回覆情形
管委員立豪	
林務局轄管事業區應為 37 個，請修正相關敘述內容。	感謝委員指教，因後續訓練資料的選定係以第四次全國性森林資源調查林型圖為依據，故已將相關內容修正刪除。
在使用第四次森林資源調查之成果，可能會有判釋的年度會與使用影像不同之情形，所以要如何精準的挑選到測試區域，要特別注意。	感謝委員提醒，第四次全國性森林資源調查的林型圖在製圖的過程，均有記載當時進行判釋所使用的影像編號，應可避免誤用不同時期影像之情況。
鄭委員祈全	
有關農航所曾經亦有委託其他團隊利用 DMC 航攝影像進行森林覆蓋型萃取之相關研究案，相關之報告應納入文獻蒐集章節，避免類似問題再度發生。	感謝委員建議，現已蒐集國內其他團隊利用 DMC 影像所進行的研究報告資料，經過彙整後會再納入本計畫之研究參考文獻。
有關簡報第 38 頁之準確性 Accuracy、精確率 Precision、召回率 Recall 等是否為影像辨識等相關領域的定義？而在遙測上之定義有所不同，建議要能以遙測定義為一致的名稱。	感謝委員建議，已於 3-4-2 模型評價與精度評估章節中更新，統一使用遙測慣用的精度評估詞彙與定義。
計畫目標準確率是訂在 85%是針對樹種分類準確率嗎？應以森林覆蓋型資訊萃取為主。	感謝委員建議，本案將參考 IPCC 第二階層之分類以及「森林資源調查暨國有林事業區檢訂土地覆蓋型及航照樣點圖資更新作業手冊」之重要樹種類別為訓練標的，準確率 85%係主辦課建議之目標，本案將以此為基本門檻，並戮力提升分類準確率。
簡報 30 頁林分、林型、樹種之階層圖及工作計畫書第 18 頁表 3-4 內容有誤，請研究團隊應以第四次森林資源調查報告內容來修正。	感謝委員指教，目前已統一採用第四次全國性森林資源調查之林型分類進行模型分類之定義，修正如表 3-7。
工作計畫書提到機器學習相關演算法利用光譜、紋理、地形等眾多因子來做判別考量來提升準確率，應亦要考量到相關之處理時間成本。	感謝委員提醒，本案規劃演算法發展已考量處理時間成本。處理時間成本可分為「訓練」與「判釋」時間，「訓練」僅需專案期間或是新的標記

意見說明	回覆情形
	資料進來時執行，「判釋」則會在任何需要進行森林覆蓋行判釋之影像進到所內資料庫時執行，因此時間考量上應以「判釋」時間為主。 判釋時間又可以分成「模型讀取」、「影像讀取」、「前處理」、「模型判釋」與「後處理」時間，「模型讀取」僅會執行一次，一旦將模型權重讀取到記憶體中，便不需要再次執行；「影像讀取」、「前處理」、「模型判釋」與「後處理」則需要在每張影像上執行，「影像讀取」指得是將影像資料從硬碟搬到記憶體上，「前處理」則是指影像切割與正規化的過程，「模型判釋」是指影像與模型權重進行運算判釋(其中光譜與紋理將會在此處進行運算)的過程，「後處理」是指將切割後影像的判釋結果組合成原圖大小的過程。 經過實測，在「模型讀取」上，一個62Mb 的十層 CNN(UNet)模型讀取時間為 21.2 秒；在「影像讀取」上，讀取 12,261*11,461*4 的影像約需花費為 7.88 秒；「前處理」部分，將 12261*11461*4 進行正規化，並切割成 512 張 412*512*4 的影像，所需的時間為 13.9 秒；「模型判釋」耗費 13.7 秒；「後處理」耗費 9.86 秒，亦即每張照片所需耗費時間為 45.34 秒。本專案預計採用相同大小或更小的 CNN 模型，因此執行時間可與之接近或可能更少。
僅以大甲溪、旗山、大雪山事業區等 3 個試驗區之成果擴及萃取全台森林覆蓋型會有其困難性。	感謝委員指教，因後續訓練樣區的選定係以第四次全國性森林資源調查林型圖為依據，無試驗區選定之必要，故已將相關內容修正刪除。
工作計畫書第 54 頁表 3-13 資料來源有誤，以及第 71 頁等多處內文錯誤，請修正。	感謝委員指教，原表 3-13 已更新，相關內文錯誤亦已修正。

意見說明	回覆情形
在航攝影像如遭遇到陰影等問題時該如何處理？工作計畫書應納入。	感謝委員提醒，本案考量未來所內產製之影像亦會有陰影，欲獲得森林覆蓋型不可避免地仍須對陰影進行判釋，因此本案仍會將陰影放入模型進行訓練。此外，由於現在感光元件的進步，每個網格儲存的像元數增加為16 個 bit，對陰影處進行判釋不無可能，陰影區之細微變化亦可能對模型訓練有所助益。綜上，本年度將直接把影像放進模型進行訓練，視訓練結果並參考相關文獻，建議未來是否對影像陰影區需有進一步前處理。
邱委員式鴻	
研究係以 DMC 原始航攝影像萃取森林覆蓋型，其中地形因子該如何加到 CNN 演算法中進行判釋？另使用全台 DEM 網格大小會有所影響，這需多加考量。	感謝委員提醒，若考慮地形因子將會把 DEM 與影像投影到同一網格上，並加入原始影像中變成一個新的波段(band)，以進行 CNN 判釋。然而在實務上航空照片對位與地形因子萃取工作甚為複雜，在本年度計畫暫不納入模型設計，擬持續透過文獻蒐集了解相關操作方法，做為下一期計畫之執行目標。
人工智慧、機器學習等相關名詞於工作計畫書中出現，建議統一修正為機器學習。	感謝委員建議，已將相關名詞統一為機器學習。
從農航所之需求係由航攝影像萃取出森林覆蓋型之資訊，進行測試出重要樹種。而在工作計畫書提及利用相關演算法萃取 14 類樹種？另分類演算法有 CNN、FCN、Mask R-CNN 及 U-Net 等 4 種方法，是要以像元還是物件分？請團隊再說明之。	感謝委員提醒，(1)目前已與所內達成共識，本案將參考 IPCC 第二階層之分類以及「森林資源調查暨國有林事業區檢訂土地覆蓋型及航照樣點圖資更新作業手冊」之重要樹種類別為訓練標的。(2)本案演算法分類流程補充說明，首先對原始影像透過移動窗格進切割，接著採用 CNN 影像分類模型對每一個切割後的影像進行分類，並將該切割後影像所有像元視為同一分類結果。然後把每一像元的分類結果寫回原始影像中像元的位置，如此一來，原始影像中的每個像元便會有多個判釋結果。最終將原始影像每個網格中的多個移動窗格的判釋結果進行平均，以獲得每個像元的分類結

意見說明	回覆情形
	果。相關內容亦補充詳述於 3-4-2 節。
與本研究計畫有關機器學習之應用國內外期刊、實作報告等相關文獻蒐集不足，要多加補充；其餘關於森林永續經營、生物多樣性監測等文獻較與本研究計畫無關。	感謝委員建議，本計畫將持續補充國內外相關文獻資料，並著重於機器學習之應用，未來亦改以表格方式進行統整，具體呈現技術發展之成果，除了作為模型實做分類測試之依據，亦提供業主作為後續計畫執行之參考。
現地資料蒐集有全國性森林資源調查、永久樣區調查及國有林事業區檢訂調查等 3 種資料，是都要當作訓練資料？抑或選擇其中 1 種為主？	感謝委員提醒，本計畫已與所內達成共識，現階段僅採用第四次全國性森林資源調查的林型圖做為訓練資料，達成 8 項樹種分類之目標。
工作計畫書、簡報中提到的軟體應要多加說明其關連性。	感謝委員提醒，現行既有軟體種類眾多，為能同時滿足不同類型的用戶，均著重於操作介面與模組套用的彈性。但面對本計畫之龐大的訓練資料需求下，實難直接進行整併與應用。因此本計畫規劃以實際開發程式語言建構模組的方式完成分類之需求。既有軟體功能之評估將作為，模型架構與模組設計之參考，亦可以表格具體彙整提供業主作為後續計畫執行之參考。
工作計畫書圖 3-19 不能來代表森林物件萃取標準化之流程雛形，應改以簡報中第 34 頁。	感謝委員指教，針對流程雛形之規劃以更新於圖 3-19。
機器學習所訓練的成果是否能反餽回相關參數進行修正？開發的平台全自動進行森林覆蓋型萃取有其難度，應考量半自動加入人工修正錯誤。	感謝委員建議，本計畫後續辦理平台規劃時，將考量納入人工編修功能，以協助加快標註的的效率，同時亦將標註人員修正之結果反饋以提升的準確率。
謝委員嘉聲	
相關機器學習的演算法最大的主軸就是在訓練樣本的選取，要如何建立正確的樣本是重要的關鍵，應在工作計畫書中詳加說明之。	感謝委員提醒，本計畫將對在影像前處理的流程中，對選取樣本進行抽樣與專家品管，相關內容亦於 3-4-2 節補充說明之。
工作計畫書中所列出 CNN、FCN、Mask R-CNN 及 U-Net 等多種演算法之探討，應要多著墨於哪一種演算法最適合用於臺灣地區森林覆蓋型資訊萃取。	感謝委員提醒，本計畫優先規劃採用 CNN 影像分類模型進行森林覆蓋型資訊萃取，相關評估之細節亦於 3-3-1 補充說明之。

意見說明	回覆情形
機器學習與傳統人工作法兩者之異同應要多加說明，兩種做法應如何結合利用亦可加以闡述。	感謝委員提醒，人工判釋時除考量到影像上的特徵如紋理形狀或是顏色外，亦會考量其他領域知識如生物學與地理學知識。本年度模型訓練將著重於影像特徵利用，未來將再考量納入高程作為特徵值，放入模型進行訓練。
蔡委員展榮	
第 78 至 85 頁一共陳列 77 篇參考文獻，其中只有 9 篇在工作計畫書內文所引用，其他未被引用，若是其相關的內容來不及撰寫於此計畫書中補充撰寫引用內容；不然則應從參考文獻清單中刪除未被引用文獻資料。	感謝委員建議，會全盤整理參考文獻，並補充相關引用。
工作計畫書第 9 頁引用文獻「Lu and Weng, 2007」、「Nilsback and Zisserman (2010)」、「Liu and Kan (2016)」，第 20 頁「森林測計學，馮豐隆」、第 23 頁「國有林檢訂調查制度之探討」都不在參考文獻清單中，請補充之。	感謝委員建議，針對計畫書補正相關引用文獻。
建議增加附錄來說明此工作計畫書採用的相關名詞之意義並括弧標示其英文全名，包括：物候、檢訂、林分、林型、林班、模性訓練、森林蓄積、逢機取樣(一般稱隨機取樣)、永久樣區、系統樣區、光譜類別、資訊類別、優適方位、四差樹(一般稱四分樹)、超像素、超參數等。	感謝委員建議，相關名詞與其意義將於期中報告檢附於附錄參考之。
第 31 頁「非監督式分類(Knowledge Based)及監督式分類(Sampled Based)」兩術語的中英文與一般常見者不同，請確認並修正。	感謝委員指教，已統一本文術語將其修正為「非監督式(Unsupervised)分類」與「監督式(Supervised)分類」
本案係以 DMC 原始航攝影像為研究目標，該影像檔案大小及資料量龐大，應考量到如何降低相關計算的複雜度（即：如何降低完成計算所需的加減乘除運算之次數）和計算時間。	感謝委員提醒，本案已考量原始影像計算複雜度及執行效能，最終亦將針對程式碼進行效能優化後再行提交成果。
研究團隊考量一般人工智慧的情況而決定採用以小窗影像來進行機器學習萃取森林覆蓋型，恐會有瞎子摸象之	感謝委員建議，此建議係屬進階之處理方法，為兼顧計畫期程及可行性，本年度將以尋找出最適的固定窗格大

意見說明	回覆情形
窘境而導致容易辨識錯誤之缺點，建議宜斟酌如何兼顧大窗影像的辨識資訊（例如考量採用多解析力影像辨識技術）。	小為目標，並以測試資料集的判釋表現作為最適窗格大小的判斷標準。未來將評估委員建議之方法，以進一步優化整體模型。
工作計畫書各章節的圖表集中放在章節末，距離圖表對應的敘述文字甚遠，不利對照閱讀。因此，強烈建議相關的圖表宜放在其對應的敘述分析文字的附近，俾方便比對閱讀。	感謝委員建議，已修正圖表與正文對應之位置，提升閱讀之便利。
相關報告不建議採用這樣的中英文混用的撰寫方式（如第 32 頁「……搭配特定興趣的 object domain 可對特定類別……」）。	感謝委員提醒，已修正相關論述以中文為主，必要處補充英文名詞以利閱讀。
建議研究團隊應先對相關判釋作業資深人員進行訪談，瞭解其作業方式及判釋森林覆蓋型之經驗，以俾後續導入機器學習演算法。	感謝委員建議，已與林務局吳技正請益，並取得「森林資源調查暨國有林事業區檢訂土地覆蓋型及航照樣點圖資更新作業手冊」，將考量其作業方式作為機器學習演算法發展參考。
第 59 頁「訓練與測試資料集切分為兩組……，一般來說，慣例上會採用二比八的比例進行切分」，其中所謂二比八的比例之依據為何？應於報告中再加以說明。	感謝委員提醒，根據吳恩達 Coursera 上 Deep Learning.ai 課程中 Improving Deep Neural Networks: Hyperparameter tuning, Regularization and Optimization 課程的 Train / Dev / Test sets 章節中提到的做法是三比七。相關內容亦於 3-4-2 節補充修改之。
第 73 頁表 4-1 團隊人員「相關經歷與專長」，建議宜另表標示「歷年承辦案件」相關資料並於附錄附上人員學經歷表。	感謝委員提醒，已增補附錄一「計畫主要人員學經歷」。
其餘工作計畫書相關謬誤之處，另提供給研究團隊修正之。	感謝委員指教。
吳委員淑華	
第 10 頁有關測試區域篩選原則過於籠統及缺乏具體事實、量化等指標，以 4 項原則來選擇大甲溪、旗山及大雪山等 3 個事業區之理由較為薄弱；且台灣北、中、南區所呈現森林樣態迥異，原選擇之測試區域多集中在中部，應將測試區域考量於台灣各區。	感謝委員指教，因後續訓練樣區的選定係以第四次全國性森林資源調查林型圖為依據，無試驗區選定之必要，故已將相關內容修正刪除。
第 12 頁 3-1-3 現地資料蒐集以「全國性森林資源調查」、「永久樣區調	感謝委員指教，本次計畫希望使用機器學習方法，對航空攝影像進行林型

意見說明	回覆情形
查」及「國有林事業區檢訂調查」3項資料為主，該如何查證這些資料的正確性。	判釋，現地之資料為遙測科學之重要立基，可同時對這幾種資料進行比對與檢討，瞭解資料可能存在的不確定性。
第12至15頁撰寫有關全國性森林資源調查之內容，卻忽略掉最主要的第四次森林資源調查中人工作業方式、如何區分不同林型的準則等，應要多加說明如何以人工方式繪製森林覆蓋型資訊，進而如何將相關作業轉換成機器學習演算法。	感謝委員指教，林型由人工判釋，需經過一定時間的專業訓練，而訓練的過程應具有標準的訓練樣本，可提供做為機器學習的輸入樣本，另外人員判讀的經驗，其判釋的特徵型態(如紋理、形狀或顏色)亦可作為選擇機器學習時的重要變數。此外，人工判釋時除考量到影像上的特徵外，亦會考量其他領域知識如生物學與地理學知識。本年度模型訓練將著重於影像特徵利用，未來將再考量納入高程作為特徵值，放入模型進行訓練。相關內容亦於3-1-1、3-4-1節補充說明之。
工作計畫書之表3-4及簡報第30頁的內容請依IPCC、第四次森林資源調查報告修正；且依據IPCC中林地level2的分類並非研究團隊所指之14種森林分類，也請一併修正。	感謝委員指教，目前已統一採用第四次全國性森林資源調查之林型分類進行模型分類之定義，修正如表3-7。
林務局森林企劃組吳技正俊奇	
本計畫為跨領域的研究，研究團隊興創知能係以資工背景為主要，對於林業領域相關名詞較不熟悉，應多與宜蘭大學鍾教授請益，亦可與農航所業務課確認。	感謝委員提醒，將加強主辦課及團隊內部交流。
第四次森林資源調查作業結束後，係以地面樣區的複查、林型圖的持續更新編修為2個主軸，應以這2種資料分析為主；並著重於現在的作法，亦可提供作業手冊給研究團隊參考。	感謝委員建議，目前已取得第四次森林資源調查作業之林型圖以及作業手冊，將納入作業手冊之作業方式及重要樹種類別作為演算法發展參考。
研究團隊建議以SAGA自動化地球科學分析系統，而農委員及林務局已有ArcGIS大量授權版本，調查作業亦架構於ArcGIS之下開發作業平台，建議機器學習能以農航所人員使用較為熟悉的ArcGIS考量；抑或分析成果可支援ArcGIS使用。	感謝委員建議，ArcGIS確實具有大量便利使用之工具，且為所內人員所熟悉之軟體，然其未開放彈性擴充外部模組之特性，無法藉由本案開發可透過ArcGIS使用之工具。本案規劃有教育訓練課程，將於該課程使所內同仁熟悉本案開發成果之使用方式。

意見說明	回覆情形
有 30 幾種樹種可由航攝影像上人眼辨識出來，建議摒除天然林與人工林之差異部分，從 30 幾種樹種挑選重要樹種來進行辨識。	感謝委員建議，已經與所內達成共識，本案將參考 IPCC 第二階層之分類以及「森林資源調查暨國有林事業區檢訂土地覆蓋型及航照樣點圖資更新作業手冊」之重要樹種類別(共 30 種)為訓練標的，不另行區分人工林與天然林。
葉課長堃生	
工作計畫書之圖 3-1 與內文所敘述之選定測試區域不一致，這請依據選定測試區域來調整圖 3-1 內容。	感謝課長指教，因後續訓練樣區的選定係以第四次全國性森林資源調查林型圖為依據，無試驗區選定之必要，故已將相關內容修正刪除。
2. 工作計畫書第 61 頁「機器學習模型部署」，研究團隊應需先瞭解農航所目前使用的軟硬體及網路等架構。	感謝課長提醒，將持續與所內交流掌握其既有系統架構。
工作計畫書有多處出現民國年跟西元年等類似情形，請統一格式。	感謝課長指教，已統一時間格式為西元年，如此亦有利於航照編碼對應。

二、期初修正審查意見與回覆情形

意見說明	回覆情形
蔡委員展榮	
依據吳副所長在 109/04/29 日的期初審查會上的說明，確認本案採用農航所的每年 DMC 航拍取得的常態性航攝影像來進行機器學習萃取森林覆蓋型。修正版第 126 頁回覆表示”已與林務局吳技正請益，並取得「森林資源調查暨國有林事業區檢訂土地覆蓋型及航照樣點圖資更新作業手冊」，將考量其作業方式作為機器學習演算法發展參考。”如何仿效真人的 DMC 影像判釋森林覆蓋型之思考知覺過程來進行機器學習，宜 1.找出、規劃、敘明並計算真人判釋資料/資訊/指標、2.萃取 DMC 航拍影像的低/中/高階特徵、3.建立判釋邏輯，另外，4.為了提高判釋精度，是否宜考慮除了原始 DMC 航攝影像外，一併使用正射影像，甚至於使用影像密匹配(逐像元匹配)建置的三維影像模型來進行機器學習萃取森林覆蓋型，建議貴	感謝委員指教，已加入補充說明文字，請詳見工作計畫書修正版 P.55。

意見說明	回覆情形
公司宜補充說明，俾以提高本案研究成功(真的可用、實用)之機率。	
修正版 p.125 的提問 6 的一項目的是提醒貴公司: 真人判釋也會用到多解析力影像判釋(multi-resolution image recognition/classification)。貴公司的回覆未能提及這一點(和其它實際實用的技術)之工作規劃，甚是可惜。	感謝委員建議，兼顧大窗影像的辨識方法確實是個重要議題，然並非一定要在輸入影像上採用不同解析度的影像才能達到此目的。在本報告提出的移動窗格切割方法，只要確保移動窗格大小夠大，亦能將兼顧大窗影像之紋理特徵，同時本報告使用之影像分類模型 CNN 模型，亦會在主要的卷積層(convolution layer)之間透過池化層(pooling layer)，改變解析度以取得更廣域的影像紋理特徵。無論在任何物件的分類上，模型起初都會採集比較細節的紋理，在逐步透過池化層降低解析度後，便可採集到較廣域的紋理特徵。因此，CNN 模型以可以部分解決委員所擔心的問題。 為兼顧計畫期程及可行性，本年度將以尋找出最適的固定窗格大小為目標，並以測試資料集的判釋表現作為最適窗格大小的判斷標準，因此本年度計畫並沒有嘗試使用此方法的規劃。在本期有初步測試成果後，未來會考慮嘗試輸入不同解析度的影像進行訓練，以達到多解析力影像判釋的效果。在影像前處理階段，透過不同大小的移動窗格進行切割，同時為確保輸入影像之實際網格數量相同，會將像素點較小的相片，透過內插或採樣的方式，將影像網格量提升到與最大的移動窗格相同，如此便可同時放到模型裡面訓練，訓練成果便可更大程度的保障，各種解析力的影像特徵都能夠被模型學習到。
文獻格式仍然是未統一，有的文獻(例如 3 和 4)作者“先名後姓”，有的(例如 5 和 6)卻是”先姓後名”，建議格式要一致。	感謝委員提醒，已瀏覽「參考文獻」一章內之文獻清單，統一文獻格式。

意見說明	回覆情形
仍有不少引用的文獻未在文獻清單中，請確實訂正。	經檢視，委員提及之文獻為「附錄一 計畫主要人員學經歷」各主要人員曾經發表之論文清單，非屬於「參考文獻」內之文獻清單。
仍有不少文獻清單裡的文獻未被引用，請確實訂正。	經檢視，委員提及之文獻為「附錄一 計畫主要人員學經歷」各主要人員曾經發表之論文清單，非屬於「參考文獻」內之文獻清單。
吳副所長	
P.16 表 3-2 底下附註之資料來源 (資料來源：圖資作業更新手冊)，需再註明機構名稱說明出處，同文件中其他部分需一並檢視。	感謝委員提醒，重新瀏覽文件並註明各參考文獻之出處名稱。
P.19 第七行，「相關設立流程如圖 3-4」說明出處，該文字建議加入引用出處之設立流程。	感謝委員提醒，補述該設立流程圖之出處說明，請詳見工作計畫修正版 P.19。
P.71 文字「本計畫團隊預計將研究成果於行政院農業委員會林業試驗所台灣林業科學季刊發表外....」調整為「本計畫團隊預計將研究成果於行政院農業委員會林業試驗所台灣林業科學季刊、並改寫為科普文章於臺灣林業發表外 .... 」。	配合辦理，調整為描述，請詳見工作計畫修正版 P.71。

三、期中審查意見與回覆情形

意見說明	回覆情形
謝委員嘉聲	
第 6 頁圖 2-1 工作架構中關於影像前處理之訓練與測繪資料集切分，應再加上說明何謂「切分」。	感謝委員建議，已配合修正圖 2-1，訓練流程的影像前處理係包含建立訓練與測試資料集，本計畫採用訓練資料集訓練模型，並利用測試資料集驗證模型之正確性。
第 14、15 頁關於文獻蒐集部分，從大量的文獻資料中能否觀察出(1)分類跟物種上有什麼樣的趨勢；(2)表 3-1 列出各種因子之重要性及指標，哪些因子是特別重要。	感謝委員建議，期中階段彙整文獻蒐集之總表，針對各文獻有使用到之因子已列入總表內，後續針對已彙整之文獻進行分析，掌握各種因子之重要性及具指標之因子。
第 31 頁圖 3-3 應再標註期中報告所使用之 620 幅原始影像分布情形。	感謝委員提醒，以圖 3-3 說明所使用之 620 幅原始影像分布。

意見說明	回覆情形
第 42 頁所要分類的類別目標是 Level2 或 Level3？請將簡報說明之內容補充於報告中。	感謝委員提醒，本計畫考量前處理工作與實作可行性，經承辦單位確認本期將針對特定樹種進行訓練標的之測試，亦即以 Level3 為類別目標。
第 46-47 頁下一期計畫執行目標是加入 DEM，惟第 48 頁圖 3-10、3-11 皆是 DSM、DTM 的說明，請釐清三者之定義及後續所使用的資料為何，且文字與圖要有一致的對應。	感謝委員提醒，已確認圖 3-12 為 DSM 與 DTM 之差異；圖 3-13 為全臺 DEM 模型資料，本計畫採用之資料為 DEM，並同步調整報告書文字。
第 61 頁所提到的 Metadata 所指稱係詮釋資料，而非 ArcGIS 的屬性資料， 請釐清本案所用之資料類型並修正敘述。	感謝委員提醒，已修正為詮釋資料 (Metadata)。
第 64 頁針對深度學習部分使用 CNN 所遭遇兩個問題，惟後續應如何處理應多加以闡述之。	感謝委員建議，已釐清該段介紹 CNN 演算法之說明，提及所遭遇之兩個問題為傳統遙測影像判釋面臨之問題，CNN 基於該問題之背景下誕生，能有效進行分類辨識的學習。
第 67 頁何謂 CNN 模型表現不佳？此應再加上文字敘述。	感謝委員建議，CNN 模型表現不佳即為準確率或 Kappa 值較低，由於期中階段後擬透過提升樣本數、加入地形因子及加入指數作為其他波段等方式提升模型訓練成效。因此，本期暫不規劃採用 U-Net 模型，已修正期中報告書修正版內文。
第 97 頁圖 3-23、圖 3-24 請加上引用文獻。	感謝委員提醒，已調整圖片並加入該文獻引用。
第 82 頁「影像切片」係使用 512pixel×512pixel，為什麼要選擇這大小？ 且這大小是否適合 Level3 樹種分類？請補充說明之。	感謝委員建議，基本上 CNN 進行紋理特徵萃取的細緻程度與「影像切片」的像素(pixel)較無關，CNN 是由多層 3x3 像素的卷積層(Convolution Layer)疊加起來，因此無論「影像切片」的像素大小，皆能萃取到該影像解析度下最細緻的紋理。此外，本計畫亦藉由所內專業判釋人員人工確認可辨識之最小切片尺寸，藉此同時兼顧最廣域特徵與最細緻之紋理。
第 92 頁圖 3-34 林型圖圖資與反投影後產生交集所顯示為兩種反投影的類型，反投影後的位置竟相差 500 至 800 公尺？是否為圖資有使用錯誤	感謝委員提醒，圖 3-34 僅為表達反投影前後之差異，該坐標不為實際位置，已修正圖 3-35，避免誤解產生。有關反投影後之資料可靠性，擬由專

意見說明	回覆情形
所致？第 94 頁類別消除反投影交叉後之資料的可靠性是否要檢討？請補充說明。	家學進行航空照片品管工作時亦協助檢視反投影交叉後之資料正確性。
訓練樣區之混淆表應加以說明敘述，並將樣本數、訓練回合、訓練取樣等過程加入報告內容。	感謝委員建議，已配合辦理修正，現階段樣本數為六類樹種各取 1000 筆分割後影像；訓練取樣則以亂數隨機尋找六類各 300 筆資料當成測試樣本，其他當成訓練樣本。另外，訓練回合大約在第 24 回合時達到測試樣本的損失最少，統計結果如圖 3-50。
邱委員式鴻	
本年度之計畫目標是林型萃取還是樹種辨識？若先以各單一樹種辨識再進而組成各種林型資訊，需針對各樹種進行辨識，請團隊與承辦單位後續思考其執行可行性。	感謝委員建議，由於過去所內已有相關研究計畫透過衛星影像判釋林型圖資之第二層分類之成果，為避免重複工作，本年度計畫經多次與承辦單位會議討論後，決議優先針對特定樹種進行訓練標的之訓練，並斟酌後續擴充樹種判釋之類型。
有關無人機影像的蒐集情形及樣區規劃內容部分，請補充於報告中。	感謝委員提醒，本期之目標優先處理農林航空測量所提供之 DMC 影像資料為主，目前已蒐集新竹、南投、宜蘭及花蓮等地區之無人機影像資料，後續再嘗試使用無人機影像進行相關之測試。地面樣區資料目前為第四次森林資源調查範圍為主。
第肆章人力配置及第伍章業主配合事項不需放於期中報告書。	感謝委員提醒，已配合辦理移除第肆章人力配置，及第伍章業主配合事項。
表 2-1 預定進度表、表 2-2 實際進度表應合併成 1 個表格。	感謝委員建議，由於原先之表 2-2 實際進度表已經包含預定進度規劃，因此，保留實際進度表說明作業進度。
報告中多處提到「根據文獻回顧……」卻未標註文獻，請修正補充。	感謝委員提醒，已配合辦理補充相關文獻。
表 3-1 文獻蒐集總表之各文獻分類因子同一欄位所列之因子卻不同？請再檢視該表格呈現方式並修正之。	感謝委員建議，實際上該總表所列之分類因子為各文獻有用到之因子，後續於期末報告書修正彙整，包含分類跟物種上之趨勢及各因子之重要性及指標，使呈現方式更加清楚。
第 27 頁描述正射影像內容有重複撰寫，請審視後修正。	感謝委員提醒，經檢視第 27 頁為正射影像類之描述，供應之產品尚包含正

意見說明	回覆情形
	射影像圖(紙圖)與正射影像檔(光碟片)，非為重複內容。
有關訓練樣區係以第四次森林資源調查林型圖成果為主，為何不考慮第34頁所提到之永久樣區調查？請說明之。	感謝委員建議，由於第四次森林資源調查林型圖圖資，係現階段記錄樹種分布範圍資料最全面的圖資，包含完整的地理空間資訊，是本計畫航攝影像對位之關鍵資訊。而就現有的永久樣區資料雖有詳細樹木資訊，卻缺乏明確的位置範圍，故本計畫暫不考慮納入使用。
第43頁請再加上文獻，俾利閱讀及查詢其內容。	感謝委員提醒，已配合辦理修正加入文獻文字。
第49頁紋理分析法及模糊分類法應為監督式分類、非監督式分類其中項目之一，為何獨立分述請再加強說明之。	感謝委員建議，由於紋理分析法及模糊分類法為近期電腦自動分類之新技術，故獨立分述加強說明。
第86頁「CNN模型作為萃取圖像特徵的工具……」，請針對此作法再補充內容。	感謝委員建議，已配合辦理補充圖3-32說明CNN與DNN混合模型之運作方式。
第91頁表3-18攝影站之物空間坐標，其參數「X_0,Y_0」漏寫Z_0，請加入。	感謝委員提醒，已配合辦理修正。
第108頁「3-6物件萃取雲端服務系統規劃建議」標題與下方文字敘述較無關連性。	感謝委員建議，由於本計畫建立機器學習航攝影像森林覆蓋型萃取之模型，後續以提供系統介面操作為目標，因此該節內容主要說明若後續提供此系統之規劃建議，以利模型建置後可透過介面使用。
鄭委員祈全	
請參考農航所於108年「應用高光譜航遙測影像於土地覆蓋型調查之研究」相關成果，並納入文獻內。	感謝委員建議，已著實詳讀參考，並補充相關說明與文獻資訊。
第102頁初步判釋成果說明之整體分類準確度51.28%、Kappa值0.2564，後續應針對個別樹種去提升其準確度。	感謝委員建議，計畫團隊已與承辦單位擬訂期末進度，規劃增加模型精準度之方法有三。1.加入DEM高程及其各項地形因子如坡度、坡向、粗糙度等；2.加入不同波段產製的標準化指標如NDVI、SWIR等；3.加入不同視角之訓練資料，將以電腦視覺常用的資料增強方式，旋轉影像視角，應用於所有樹種之中。

意見說明	回覆情形
為何僅以 DMC 原始影像進行樹種分類而未使用正射影像？另 DEM 資料也可考量改用 5 公尺解析度進行分析	感謝委員建議，本計畫優先採用 DMC 原始影像之目的，在於希望能充分利用其航攝影像資料，直接進行樹種判釋，一來可簡化判釋程序適用所有 DMC 影像，二來亦避免正射過程導致樹種特徵遺失之問題。為提升判釋精準度，尚不排除增加正射影像進入模型，另外也考量採用 5 公尺解析度之 DEM 進行輔助。
春夏秋冬四季或乾濕兩季森林在航攝影像會有不同的光譜資訊，在航攝影像的挑選上亦請考量此資訊。	感謝委員建議，本次影像挑選仍以第四次森林資源調查所使用的影像為主，以確保當時判釋人員所見到的影像與模型學習到的影像是一制的。關於季節等特性，將再與所內研議如何將相關資訊納入作為下一年度計畫執行之參考。
吳委員淑華	
目前僅針對 6 種樹種進行機器學習訓練，惟臺灣生物多樣性豐富，要對於未學習到的樹種全部訓練實有其難度，而後續再進而推至 Level2 林型資訊萃取應該如何處理？	感謝委員建議，後續將研議以遷移學習(Transfer Learning)的方法，將此次模型學習到的淺層權重，放入 Level2 林型判釋的模型當中進行學習。
有關後續待辦事項提到研議增加坡度、坡向、粗糙度等地形因子，請團隊考量所取用之相關圖資，就行政部門而言應是可用、可及、多量的資料，俾利往後在實務上能順利執行。	感謝委員提醒，本計畫已開發自動化工具為原則，後續取用地文圖資時必將考量實務需求納入適當的地形因子。
期中報告書有關本次期中除論述相關基礎原理外，如何導入本計畫相關內容較無更進一步說明，這部分請多加闡述之；倘若與之前工作計畫書有重複的部分則可減少其篇幅。	感謝委員建議，本計畫期中階段主要著重於資料前處理之過程，將原始影像建立訓練及測試資料集之過程，採用前述基礎原理提及之演算法進行模型訓練，提供期中階段之初步成果。就後續導入之規劃，現階段參考 3-4-2 節說明，期末階段將深入補充說明具體應用規劃。
本次選擇的影像相關資訊（年份、季節等）呈現較為不足，請補充於期中報告書。	感謝委員提醒，依照影像拍攝之年份及月份加入統計圖說明，請見圖 3-4、圖 3-5。
管委員立豪	
相關名詞及其定義未放於期中報告書附錄內，這部分請補充。	感謝委員提醒，已配合辦理補充於期中報告書修正版附錄一。

意見說明	回覆情形
有關簡報第 52 頁整體精度、生產者精度、使用者精度相關內容及定義，請補充於期中報告書第 88 頁。	感謝委員建議，請詳見期中報告書修正版 3-4-2 節六、模型評價與精度評估。
蔡委員展榮（書面意見）	
航攝影像森林物件自動判釋精度高(例如判釋精度 0.95)就可實用嗎？若否，表示除追求自動判釋精度高之外，還缺少什麼呢？建議參閱歷年來國內相關單位(例如林務局、農航所、農糧署)的航遙測影像自動判釋應用工作案之實際經驗，來找出答案，並供本案 3 年期計畫的規劃研究重 點使用，俾期本案能對農航所暨林務局常態業務具有實用價值的貢獻。	感謝委員建議，本計畫後續將持續參考相關管理單位之遙測自動判釋計畫執行經驗。除了善用既有的航遙測影像資源，亦以未來能用、可擴充之原則進行程式語言工具開發，有效提升所內常態業務處理之影像分析效率。
第 82 頁「需先將遙測影像轉換為較小像素後，方能使用既有的 AI 模型」，其中是「較小像素」？還是「較少像素」？	感謝委員提醒，錯字部分已配合修正。
110 年度預定目標(後續擴充)第 1 項「研究高解析度…UAV 影像以機器學習技術自動化萃取森林覆蓋型之演算模式與實作」:是否已經考慮過 UAV 的像幅小(單張影像的地面覆蓋面積小)、飛航安全、UAV 影像幾何特性、作業成本、對本案的實用性？	感謝委員提醒，針對 UAV 之實用性會再研擬評估是否納入本案進行自動化模型萃取演算模式及實作，並於期末與承辦單位討論後續年度擬辦理之可行性。目前 UAV 影像掌握情形請詳見期中報告書修正版第 3-1-2 節三、正射影像類。
第 132 頁意見 4 和 5 的回覆內容完全相同: 如果意見 4 回覆「各主要人員曾經發表之論文清單，非屬於參考文獻」正確，則表示各主要人員曾 經發表之論文不列入參考文獻，而意見 5 的相同回覆卻表示各主要人員曾經發表之論文列入參考文獻，兩者自相矛盾，請確實回覆和訂正。	感謝委員提醒，針對參考文獻內已有檢視各引用情形，另期中報告書修正版人力配置一節已依委員建議移除，同時確保參考文獻之引用可有效對照於內文中。
第 76 頁「在未來延續計畫中亦不排除增加正射影像或其他影像資料之使用」:貴公司是否了解正射影像(ortho image)和真正射影像(true ortho image)兩者區別呢？未來將採用何者？	感謝委員指教，傳統的正射影像(ortho image)係指將航遙測影像之地表高程差，透過 DTM 正射糾正(ortho rectification)投影到正確的平面位置，然而針對複雜地表地貌資訊，容易在重投影的過程中失真傾斜。而所謂的真正射影像(true ortho image)，則有別

意見說明	回覆情形
	於傳統作法額外考量所有地表物體在影像的幾何變形與遮蔽，透過 DSM 進行校正，真實呈現所有地表覆蓋物在空間中的「真實位置」。現階段，本計畫仍以 DMC 航空照片進行模型訓練與測試，未來則係以導入真正射影像為目標，解決投影帶來的高程偏差，提供更佳正確可用的訓練資料。
期中報告書仍有文獻撰寫格式不一致情形，請確實修正並統一格式。	感謝委員指教，已再次重新檢視、修正參考文獻內之撰寫格式。
第 88 頁圖 3-30 圖標題文字 Intersection of Union」:請訂正為「Intersection over Union」。考量全文宜統一使用中文(或英文)來撰寫，不宜中英文混用，建議修改為交集除以聯集或交集除以聯集(Intersection over Union)。	感謝委員建議，圖 3-33 已配合修正為交集除以聯集 (Intersection over Union)。
全文宜統一使用中文(或英文)來撰寫，請盡量勿中英文混用，例如第 13 頁「使用 deep belief network architecture 作為影像辨識分類器」。	感謝委員建議，已配合修正相關內文，避免中英文混用之情形。
第 84 頁「本計畫將配合執行團隊之一的宜蘭大學，建立航空照片品管工作」部分，請補充說明本案如何建立航空照片品管工作。	感謝委員建議，本計畫將研議以下兩方面進行。1. 透過專家學者之經驗篩選第四次森林資源調查之多邊形，須包含每一樹種選出較具代表性的多邊形，作為模型訓練之用。2. 進入前處理工作後，針對每一樹種，以切割後的影像為基礎，由專家協助篩選較具代表性的影像，以達訓練樣本之品管工作。
建議本案辛苦蒐集來的參考文獻(電子檔)宜提供給農航所同仁查閱及學習使用。	感謝委員肯定，將配合辦理於期末交付成果報告時，一併提供於所內本計畫相關參考文獻。
第 131 頁意見 2 回覆「將像素點較小的相片，透過內插或採樣的方式，將影像網格量提升到與最大的移動窗格相同」，例如將 128x128 內插為 512x512 影像窗的像元數量，則相鄰的像元數位值(digital numbers)高相關，要注意它對自動化影像識別成果有何影響。	感謝委員提醒，在本期有初步測試成果後，未來會考慮嘗試輸入不同解析度的影像進行訓練，包含原始解析度影像，以達到多解析力影像綜合判釋之效果。

意見說明	回覆情形
第 107 頁表 3-23「SG 測量及空間資訊研討會」原訂 2020/08/27-28 舉行，也因 COVID-19 疫情影響順延至明年，請一併更正。	感謝委員提醒，已補充修正之。
以下為期中報告書內容有提到之參考文獻卻未列於清單者，請補列入：(1) 行政院農業委員會林務局第四次全國森林資源調查計畫書；(2)從京都議定書看台灣的森林資源調查；(3)IPCC 2006 Guidelines；(4)Gary Sherman 於 2002；(5)Zadeh，1965。	感謝委員提醒，已配合補入上述五項參考文獻。
全文請統一用詞：(1)統一使用「座標」或「坐標」；(2) 統一使用「最近鄰居法(Nearest Neighbors)」或「最鄰近法(Nearest Neighbors)」；(3)「存儲」訂正為「儲存」；(4)「ArcIMS」訂正為「ArcWMS」。	感謝委員提醒，已配合統一用詞與錯誤修正。
第 95 頁「DEM 未涵蓋之範圍」：本案使用的資料區中，何處是 DEM 未涵蓋之範圍？	感謝委員提醒，DEM 未涵蓋之範圍係指高程小於 0 之海域範圍。
第 101 頁圖 3-45 及第 102 頁圖 3-46 文字模糊，請修正。	感謝委員提醒，已重新出圖抽換。
其餘期中報告書相關文字誤植或謬誤之處，另提供給研究團隊修正之。	感謝委員提醒，已配合修改文字誤植與謬誤之細節。
葉課長堃生	
在考慮目前之調查資料係多個單位判讀之成果存有人為判釋準確度差異之情形下，請團隊思考後續之執行架構，是否有機會以人機互動輔助機器學習方式來確認或反饋機器判讀成果，藉以提升森林覆蓋型萃取之成功率？	感謝課長建議，透過人機互動輔助機器學習，的確可有效反饋機器判讀之成果，建議納入後續年度規劃執行，以利提升模型判釋之正確率。
提醒團隊有關本案期末階段除需完成期末應完成項目外，亦請於期末報告書中就本年度計畫執行成果及相關會議討論內容，提出下年度研究方向的修正建議供本所參考。	感謝課長提醒，本計畫除交付期末成果報告外，亦將針對相關會議討論內容收斂彙整，提供所內規劃下年度研究方向與計畫執行建議。
黃技士宗仁	

意見說明	回覆情形
有關教育訓練暫定於 10 月 2 日(五)辦理，查該日為中秋連假，請團隊另行安排其他時間。	感謝承辦提醒，經確認教育訓練日期將暫調整為 10 月 9 日(星期五)辦理。
缺少 sel 之 DMC 原始影像請團隊於會後再提供清單，再由承辦單位協助查明。	感謝承辦提醒，現已將缺少 sel 之 DMC 原始影像提供，再請承辦單位協助查明。
林務局森林企劃組吳技正俊奇（書面意見）	
第 32、33 頁有部分將事業區檢訂調查誤植為檢「定」調查，請修正。	感謝局內同仁指教，已配合修正誤植之處。
第 32 頁末行「並與永久樣區調查進行整併」文字建議刪除，事業區檢訂與永久樣區調查之目的不同，如何整併？	感謝局內同仁指教，已配合刪除該行文字。
第 34 頁對於永久樣區調查之描述有諸多錯誤情形，第二段森林永久樣區調查重點為林木或林型的定期生長量，並未包含所羅列的地景、地理、野生動植物與社經文化等；另永久樣區係與全國森林資源調查之系統樣區進行整合並定期辦理複查，並非與事業區檢訂整併。	感謝局內同仁指教，已配合修正永久樣區調查之相關描述。
第 37 頁第 2 段「並整併國有林檢訂調查與永久樣區調查一同實施」文字請刪除，係第四次全國森林資源調查結束後，於建立資料更新機制時整併其他調查工作。	感謝局內同仁指教，已配合刪除該段文字。

四、期末審查意見與回覆情形

意見說明	回覆情形
邱委員式鴻	
期末報告書應加上摘要，另外歷次工作會議紀錄亦應放進附錄；附錄三教育訓練簡報內容，應再增加課程表、簽到單及教育訓練相關照片。	感謝委員提醒，已配合加上摘要、會議記錄、教育訓練課程表、簽到單及相關照片。
本年度係針對純林之林型部分進行機器學習辨識樹種，而於第 2、3 年將擴展至辨釋其他混淆林型，有關研究進展前後關係應於報告書第 3 頁補敘之。	感謝委員提醒，已將混淆林型之研究規劃補充於第八章。

意見說明	回覆情形
期末報告第 8-9 頁未加入無人機拍攝之影像，請說明。	感謝委員指教，考慮到今年度並無使用到無人機拍攝之影像，因此予以修正，並將規劃為明年研究項目之一。
文獻回顧中提及深度學習之 CNN+DNN、U-Net 等，其中 U-Net 精度較高卻不採用之理由為何？	感謝委員指教，U-Net 與 CNN+DNN 所想要解決的任務類型不同，U-Net 處理的任務為影像分割，也就是每一個像素都會分類出一個類別；CNN+DNN 則主要處理影像分類的任務，影像分類是一張影像分出一個類別即可。 由於本年度並無取得像素等級的標記資料，無法訓練出影像分割模型， 因此本年度主要使用 CNN+DNN 進行影像分類的任務。
本研究使用 R、G、B、NIR 等波段及 NDVI 因子之相關成果，是否有回頭再檢視文獻回顧。	感謝委員指教，已重新審視並修正文獻回顧。
本研究所使用之地形資料不考慮 5m DEM 之理由為何？是計算量較大還是因為加上浮水印之 DEM 影響精度。	感謝委員指教，本團隊在選擇使用 20m 或 5m 之 DEM 時，主要考量到浮水印在產製各地形因子時所產生的雜訊，如期末報告書圖 3-12 所示，這樣的雜訊會影響最後的判釋結果，因此在本年度並沒有採用 5m 之 DEM。
地形因子、波段、NDVI 等各項因子使用之排列組合該如何擇定？	感謝委員指教，在我們實際測試後發現，將地形因子與光譜因子分開放入模型，所得成果較佳，推測是由於其本質上的不同所導致。
第 97 頁森林物件特徵萃取經驗之章節及相關文獻回顧，針對紋理之特徵該如何萃取？請研究團隊說明之。	感謝委員指教，有別於傳統的機器學習模型，需先將影像特徵萃取後再放入模型進行訓練；CNN 是透過訓練的方式，學習如何進行特徵萃取，方能助於模型較深層的分類模型進行分類。因此，無須先採用人工推論方式進行特徵萃取。
表 6-7 整體精度及第 110 頁整體準確率之間關聯性是什麼？請加強說明。	感謝委員指教，已修正於第六章 6-2 節。
簡報中有關於訓練過程中遭遇困難並經由第 2、3 次調整，並無在期末報告書敘述，且各項因子不等權之調整原則為何？	感謝委員指教，各特徵值權重的重要性已呈現於圖 6-46。模型的調整上，第二次的調整主要將光譜所產製的因子與高程所產製的因子分開，但高程所產製的因子中，坡向的數值分布界

意見說明	回覆情形
	在 0~360 度之間，其數值意義並不具有大小與倍數關係，與其他特徵值不同，因此分割成一個獨立的輸入。
以放大、縮小等方式增加訓練樣本是否會影響訓練成果？	感謝委員指教，航高本身也會導致同一個真實空間中的物件，在影像上呈現不同大小，因此透過此方式增加訓練資料的樣態尚屬合理。
優化演算的部分未說明訓練、CNN+DNN 等所花費之整體時間。	感謝委員指教，訓練所花費之時間與模型上線後的推論時間並不相關，模型總訓練的部分，以每個樹種 5000 組樣本為例，其收斂時間大約是三到四天。實測推論每張照片所需的時間為 0.011 秒，若將農航所 13824x7680 的原始影像，切割成 512x512 大小的影像，並為避免切割影像的邊界預測成效不佳的問題，以 256 個像素進行移動，共可切割成(53*x29**)個切割後影像，所花費時間約為 16.43 秒。 * (13824 – 512) / 256 + 1 = 53 ** (7680– 512) / 256 + 1 = 29
使用衛星影像是考量森林物候變化之考量點是什麼？請補充說明。	感謝委員指教，考量到航照影像拍攝時間多為冬季，而衛星影像時間密度高，可用來補足航照影像不足的時期。
吳委員淑華	
表 3-1 文獻收集總表臚列 60 篇文獻，篇幅長達 11 頁不易閱讀，建議表 3-1 移至附錄，並可加入對於這 60 篇文獻的綜整分析。例如應用不同影像（衛星影像、航空照片與 UAV 影像）進行分析其差異性。	感謝委員建議，已修正報告排版，並加入文獻綜整之章節。
文獻所整理的應用特徵有樹冠顏色、樹冠紋理、樹冠高程模型、光譜特徵、植生指標與其他特徵等，觀諸所列的 60 篇文獻中，似乎並未呈現有納入地形因子的重要評述，而本次研究所選取的訓練資料特徵參數高達 11 項，又其中 3、4 節所推導的地形因子，選做為後續訓練的重要因子，尤	感謝委員建議，已修正。

意見說明	回覆情形
其應注意地形因子並非樹種絕對的分布控制因子，建議應加強驗證說明。	
第四次全國森林資源調查林型圖資，其判釋係至林型（第二層分類）；本研究初步以引用至主要樹種與次要樹種來進行模型訓練，這可能會將當時判釋樹種誤差引入訓練過程，導致後續分析的誤差，建議後期研究應具體規劃執行，加強的地真資料之準確性。	感謝委員建議，森林資源調查資料彌足珍貴，地真資料的取得相當不容易，本計畫設計訓練模型，希望可最大化利用既有航攝影像與林型圖地真資料。當訓練流程與操作流程抵定，可變更資料集來源，以提升樹種分類正確性。
表 6-7 樹種初步判釋分類成果，應屬單一樹種自我判定的分類成果，未來在實務操作上，如何克服未知樹種的分類評估，以及混淆林型的分類評估？續期規劃應請補充，建議應依據今年成果，檢討不足或有待精進之處，提出更具體的改善建議，席望能在未來能有更好成果。	感謝委員建議，本計畫使用深度學習方法建立分類模型，是監督式學習的一種，訓練的類別取決於地真資料的種類，現階段僅能判斷未知樹種是否為 11 類之一。針對混淆林型的分類，基本上與今年的實作方法相近。另外，後續精進之處，亦於第八章補充說明之。
謝委員嘉聲	
期末報告中英文專有名詞大小寫、符號等格式應統一。	感謝委員提醒，已重新審視全文並修正之。
期末報告第 14 頁「……深度學習方法開始於 2012 年(Krizhevsky et al., 2012)。」此段文字應為誤繕，請刪除。	感謝委員提醒，已修正。
第 29 頁圖 3-4、圖 3-5 標示相反，請修正之。	感謝委員提醒，已修正。
第 37 頁有關永久樣區調查敘述方式較為不妥，亦引起讀者誤會，請修改文意。	感謝委員提醒，已修正。
第 49 頁 5m DEM 所遭遇問題改以 20m DEM 進行分析，主要受限於資料量龐大、浮水印之誤差等較無法說服，應改為主要受限於該資料係為管制機密資料。	感謝委員提醒，已修正。
第 49 頁地形因子坡向、粗糙度等描述內容請再審視修正之。	感謝委員提醒，已修正。
請於期末報告中相關圖加入 color bar，才能顯示圖中相關數值與顏色之對應關係；另通常習慣數值小至大係以顏色淺至深來表示。	感謝委員提醒，已修正。

意見說明	回覆情形
表 4-1 之最大似然估計 MLE 應非模糊分類法，請修正之。	感謝委員提醒，已修正。
第 59 頁影像光譜值之英文專有名詞非 Color，請修改。	感謝委員提醒，已修正。
表 6-1 最後一列「逐幀」混淆林、第 83 頁「選」轉矩陣為誤繕，請修正。	感謝委員提醒，已修正。
圖 6-7 中文字說明與內文敘述剛好顛倒，請修改。	感謝委員提醒，已修正。
圖 6-9 之右圖示意仍為中心透視投影，應修改為正射投影示意之。	感謝委員指教，左右兩圖皆為透視投影，欲表達之意思為向量資料反投影與網格資料反投影。
第 89 頁測試不同內縮範圍，最終都選定 25 公尺內縮範圍，此作法是否造成更大的問題？	感謝委員指教，考量到效率問題，本年度以定值縮減為縮減方法，並規劃於明年度透過 DSM 資料來改善此問題。
報告圖 6-11、圖 6-16 難以辨識，請重新調整或加上說明以俾辨識之。	感謝委員提醒，已修正。
第 104 頁選擇 512×512pixels 裁切、並移動是 256pixels 切幅之理由？	感謝委員指教，使用 512×512pixels 裁切並移動 256pixels 進行切割，是人員可判釋的最小單位，因此使用此等規格進行判釋。
圖 6-30 訓練回合統計情形無法顯示收斂，請說明之。	感謝委員指教，以於期末報告書圖修正。
蔡委員展榮	
除了人工智慧、森林等相關領域之人才外，研究團隊人力組成需再多增加測量相關專業專家；另如何有效整合各領域人才來進行合作，是本研究成功的一項關鍵。請問研究團隊上述兩項情況如何？若有其不足之處，未來 2 年如何改善？	感謝委員建議，本團隊人力組成目前已包含了遙測影像、電腦視覺、地理資訊、森林資源與攝影測量領域之人才。除了持續強化跨領域溝通與協做開發，未來亦不排除尋求專業學術研究人員支援，強化研究團隊專業能力。
第 14 頁「Zhang and Xie(2013)將 Hart 特徵與花圖像的 SIFT 特徵結合起來…」，此篇文獻並未提到此段內容，請確認此段文字出處並修改；另其他引用之文獻亦再確認正確性。	感謝委員提醒，此文獻為編輯疏忽，已修正並重新檢查。
有經驗之作業人員難免會有誤判情形，相信改以電腦處理也會誤判，該如何有效整合人工及自動化分類作業？	感謝委員指教，目前規劃以滾動式方法逐步修正人工標記錯誤，並由專業人士檢查電腦判釋分類結果，在雙重檢核的機制下應可減少誤判之情況。

意見說明	回覆情形
研究團隊係使用 2D 影像特徵進行分類？還是使用 3D 影像特徵進行分類？	感謝委員指教，本期計畫仍以 2D 判釋為主，明年會研析是否能透過 DSM 產製加入樹高資訊。
航攝影像、DEM 等各項資料因產製時間、解算處理不同，常有計算上之誤差，該如何進行有效套疊對位？係採用強制套合，抑或使用其他方法？建議將期末審查會議簡報資料（例如第 35 頁）新增內容加入期末報告書。	感謝委員指教，由於森林資料 10 年才更新一次，基本上可假設長時間變化不大，而 DEM 亦同，故時間對應上並無太大問題，而在對位上，目前以定值內縮的方式去除掉邊緣不符之處，明年度考量以影像產製 DSM 之方式校正對位上的偏移問題。
有關簡報資料相關問題如下： (1) 第 58 頁中 718 幅 DMC 影像對？還是 718 幅 DMC 影像？ (2) 第 65 頁提到的內縮 25 公尺，該作法皆適用於各區嗎？ (3) 第 68 頁增加 6 倍樣本數量，係僅單純旋轉、縮放等？此作法會與原影像為高相關。 (4) 第 100 頁自行由影像匹配產製 DSM，會有其他誤差需克服。	感謝委員指教。 (1)共 718 幅 DMC 影像。 (2)考量偏移之主要原因為樹高導致，又台灣樹高平均約 25 公尺，經測試後本年度以內縮 25 公尺作為改正，並規劃於明年度改善。 (3) 由於航高與航向不同也會導致物件在影像上呈現不同大小，因此透過此方式增加訓練資料的樣態尚屬合理。 (4)最佳解是能夠取得 DSM 資料，產製 DSM 需要解決的問題我們也會再與專家討論。
有關期末報告書內相關錯誤或問題（第 2、12、14-15、42、49-50、83-91、98-100、102、104、110-113、115、127、129、133 至 135、138、148 至 149 頁），請依會後提供之書面資料進行修正或補充回覆說明。	感謝委員指教，已修正。
葉委員堃生	
第 88 頁圖 6-10 右圖為消除反投影交叉情形，但仍有交叉扭曲產生，請查明相關資料並修改。	感謝委員指教，已修正。
第 79 頁處理原則第 1 點應該有誤，就數位影像並不會有特定之比例尺，此處是以觀看比例原則以 1:2000~1:3000，請再確認手冊撰寫內容。	感謝委員指教，已確認過手冊撰寫內容並修正。
有關第 135 頁森林分類流程實作中增加不同時期之航攝影像、正射影像或無人機影像部分，無人機之外方位參數誤差較大，若反投影系統性偏移有	感謝委員建議。

意見說明	回覆情形
產生更大之誤差；另正射影像係由航攝影像進行正射糾正之產品，實質上並無增加訓練樣本數。	

附錄三 文獻總表

No	文獻 作者	年分	影像來源 (衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 樹冠顏色	特徵B 樹冠紋理	特徵C 樹冠高度模型	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
1	Arockiaraj et al.,	2015	Satellite Imagery (Worldview-2		否	Mixed Forests					Spectral index			0.88	ML	Journal of Tropical Forestry and Environment
2	Baena et al.,	2017	UAV imagery	RGB images	否	Dry forest	Prosopis pallida (Algarrobo), Colicodendron scabridum (Sapote), and Cordia lutea (Overo), Vallesia glabra (Cun cun), Cynophalla flexuosa (Sune), Grabowskia boerhaaviifolia (Canutillo or Palo negro) and Parkinsonia praecox (Palo verde), Loxopterigium huasango (Hualtaco) and Bursera graveolens (Palo santo)			Canopy height model		Vegetation indices		0.31-0.69	Objects classified	PLoS ONE
3	Bolyn et al.,	2018	Satellite Imagery (Sentinel-2)		是	plantations					Spectral index			0.88	RF	Biotechnol. Agron. Soc. Environ.
4	Botella et al.,	2018	Multi type raster data	Multi type raster data	否	Mixed forests	50 species						Climatic and Environmental data(Pedologic, Potential Evapotranspiration, Hydrographic, Digital Elevation data), Land cover, GBIF species distubution		SNN, DNN and CNN	Multimedia Tools and Applications
5	Dabiri and Lang	2018	Aerial	Multispectral imagery	否	Mixed forests	Picea abies (PiAb), Populus canadensis (PoCa), and Populus balsamifera (PoBa), Fraxinus excelsior (FrEx), Alnus incana (Alln) and Salix alba (SaAl), Acer pseudoplatus and Quercus robur				Canopy spectral signature			0.85	RF	Preprints
6	dos Santos et al.,	2019	UAV imagery	RGB imagery	否	Urban forest	Urban forest tree species				Feature Pyramid Network			0.92	Faster-RCNN, YOLOv3, and RetinaNet	Sensors
7	Feng and Li	2019	UAV imagery	Multi-spectral	否	Urban forest		Crown color			Near-infrared features		Tree height	0.78-0.95	VBSD	Remote Sensing

No	文獻 作者	文獻 年分	影像來源 (衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 樹冠顏色	特徵B 樹冠紋理	特徵C 樹冠高程模型	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
8	Féret and Asner	2013	Aerial	Multispectral imagery	否	Mixed forests	Aleurites moluccana, Cananga orodata, Cecropia peltata, Cocos nucifera, Eucalyptus robusta, Flindersia brayleyana, Mangifera indica, Melochia umbellata, Metrosideros polymorpha, Pandanus tectorius, Persea americana, Pithecellobium saman, Psidium cattleianum, Psidium guajava, Syzygium jambos, Trema orientalis, Zingiber zerumbet				Canopy spectral signature			0.73	LDA, QDA, RDA and SVM	IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING
9	Ferreira et al.,	2016	Satellite Imagery (Worldview-3) and Hyperspectral data	Multi-spectral and Hyperspectral data	否	Seasonal semi-deciduous forests	Aspidosperma polyneuron, Astronium graveolens, Cariniana legalis, Cecropia hololeuca, Croton piptocalyx, Diatenopteryx sorbifolia, Hymenaea courbaril, Pachystroma longifolium					Vegetation indices		Hyperspectral 0.72-0.95, Worldview-3 0.65-0.87	LDA, SVMs with Linear and Radial Basis Function kernels, and RF	Remote Sensing of Environment
10	Franklin	2018	UAV imagery	Multispectral imagery	否	Mixed forests	Deciduous–conifer mixedwood, Deciduous-dominant mixedwood, Conifer-dominant mixedwood,Deciduous-dominant mixedwood			Crown size			Crown edge, Crown shape, Crown shape complexity	0.44, 0.56, and 0.69	Unsupervised clustering, maximum-likelihood statistical classifier, and RF	
11	Franklin et al.,	2017	UAV imagery	Multispectral imagery	否	Mixed forests	white cedar (Thuja occidentalis), eastern white pine (Pinus strobus), white spruce (Picea glauca) , juniper (Juniperus communis)			Canopy height model	Crown spectral			0.72	RF	Photogrammetric Engineering & Remote Sensing
12	Fricker et al.,	2019	Aerial	RGB imagery, the infrared (940 nm), red (650 nm), and blue (430 nm) spectrum.	是	Mixed-conifer forest	White fir (Abies concolor), Red fir (Abies magnifica), Incense cedar(Calocedrus decurrens), Jeffrey pine (Pinus jeffreyi), Sugar pine (Pinus lambertiana), Black oak (Quercus kelloggii), Lodgepole pine (Pinus contorta) Dead tree (any species)	Canopy color		Canopy Height Model (CHM)	Canopy spectral signature			0.76-0.90	CNN	Remote Sensing

No	文獻		影像來源(衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 樹冠顏色	特徵B 樹冠紋理	特徵C 樹冠形狀與結構	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
13	Garzon-Lopez et al.,	2013	Aerial	RGB images	否	old-growth	Attalea butyracea (Mutis ex L.f.)Wess. Boer (Aracaceae), and Astrocaryum standleyanum Bailey (Aracaceae), Jacaranda copaia Aubl. (Bignoniaceae) and Dipteryx panamensis (Pittier)	Canopy color	Texture				Crown contour, Crown typology, phenology	0.18-0.76	Spatial regressions	BIOTROPICA
14	Ghazi et al.,	2017	photo imagery	RGB imagery	否	Mixed forests	trees, herbs, and ferns							0.8	Deep learning	Neurocomputing
15	Hartling et al.,	2019	Satellite Imagery (Worldview-2/3)	Multispectral imagery	是	Urban forest	Green ash(Fraxinus pennsylvanica), Bald cypress(Taxodium distichum), Cottonwood (Populus deltoides), Silver maple (Acer saccharinum), Sugar maple (Acer saccharum), Pin oak (Quercus palustris), Austrian pine (Pinus nigra), Sycamore (Platanus occidentalis)		Texture		Canopy spectral signature	Vegetation indices		0.82	DenseNet, SVM and RF	Sensors
16	Hershey and Befort	1995	Aerial	Multi-spectral	否	Natural and plantion forests		Canopy color	Texture						Aerial photo interpretation	UADA forest service
17	Hesketh and Sánchez-Azofeifa	2012	Ground spectral	ASD FieldspecFR spectrometer	否	Natural and plantation forests	Doliocarpus multiflorus, Aristolochia maxima, Arrabidaea verrucosa, Stizophyllum riparium, Pleonotoma variabilis, Serjania atrolineata,Odontadenia punticulosa, Stigmaphyllon hypergyreum, Dioclea wilsonii, Gouania lupuloides, Forsteronia myriantha, Mikania leiostachya, Tontelea ovalifolia, Bonamia trichantha, Maripa panamensis, Jacquemontia sp., Pouteria reticulate, Passiflora vitifolia, Lonchocarpus longifolium, Doliocarpus major, Carapa guianensis, Prionostema aspera, Matayba apetala, Doliocarpus dentatus, Cordia bicolor, Amphilophium paniculatum,				Leaf spectral	Vegetation indices	Specific leaf area	0.80-0.93	Hierarchical clustering and dendrogram analysis	Remote Sensing of Environment

No	文獻		影像來源(衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 樹冠顏色	特徵B 樹冠紋理	特徵C 樹冠高程模型	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
	作者	年分														
							Manilkara bidentata, Pithecoctenium crucigerum, Aspidosperma cruenta, Trichostigma octandrum, Brosimum utile, Hiraea reclinata, Ficus nymphaeifolia, Forsteronia spicata, Arrabidaea patellifera,,Hippocratea volubilis, Serjania mexicana, Phryganocydia corymbosa,,Tetracera portobellensis, Anacardium excelsum, Luehea seemannii, Astronium graveolens, Cordia alliodora, Annona spraguei, Castilla elastica, Ficus insipida, Chrysophyllum cainito									
18	Hill et al.,	2010	Aerial	Multispectral imagery and airborne laser scanning data	是	Mixed forests	Ash, Aspen, silver birth, elm, Maple, Oak			Mean canopy height	Canopy spectral		Canopy density	0.39-0.82	Supervised Maximum Likelihood	Applied Vegetation science
19	Ho´scilo and Lewandowska	2019	Satellite Imagery (Sentinel-2)		否	broadleaf and coniferous forest					Spectral band		DEM	0.89	RF	Remote sensing
20	Immitzer et al.,	2012	Satellite Imagery (Worldview-2)	Multispectral imagery	否	Mixed forests	Norway spruce (Picea abies, (L) Karst.), Scots pine (Pinus sylvestris, L.), European beech (Fagus sylvatica, L.) and English oak (Quercus robur, L.). Secondary tree species are Silver fir (Abies alba, Mill.), European larch (Larix decidua, Mill.), Douglas fir (Pseudotsuga menziesii, (Mirb.) Franco), Lawson's cypress (Chamaecyparis lawsoniana, (A. Murr.) Parl.), Grand fir (Abies grandis, Lindl), Ponderosa pine (Pinus ponderosa, Douglas ex P. et C. Laws), European ash (Fraxinus				Canopy spectral signature			0.96	RF	Remote Sensing

No	文獻		影像來源(衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 樹冠顏色	特徵B 樹冠紋理	特徵C 樹冠形狀與點雲型	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
	作者	年分														
							excelsior, L.), European hornbeam (Carpinus betulus, L.), Turkey oak (Quercus cerris, L.), Silver birch (Betula pendula, Roth), European alder (Alnus glutinosa, L.), Persian walnut (Juglans regia, L.), Black locust (Robinia pseudoacacia, L.), European chestnut (Castanea sativa, Mill.), Sweet cherry (Prunus avium, L.), linden- (Tilia sp.), maple- (Acer sp.), elm- (Ulmus sp.) and poplar-species (Populus sp.)									
21	Kampen et al.,	2019	UAV imagery	Multi-spectral	是	Plantation and mixed forest stand	Norway spruce, Scots pine (Pinus sylvestris, L.), European silver fir (Abies alba, Mill.), European beech (Fagus sylvatica, L.) and European larch (Larix decidua, Mill.)				Canopy spectral signature	Vegetation indices			Random forests (RF)	Dreiländertagung der DGPF,
22	Kim et al.,	2009	Aerial	LIDAR point clouds	是	Mixed forests	Pinus, Larch, Spruce, Douglas-for, Western hemlock, Redwood, Western red cedar, Bigleaf maple, Sorbus, Prunus, Malus, Birch, Elm, Oak, Magnolia			Tree crown features (from point cloud)			Leaf on and off	0.73-0.9	Linear discriminant function	Remote Sensing of Environment
23	Knauer et al.,	2019	Aerial	Hyperspectral imaging data	否	Mixed forests	Pedunculate oak, Littleleaf lime, European aspen, Norway spruce, Black pine, Sycamore maple, Scotch pine, Sessile oak, Birch, European white birch, Weymouth pine, Douglas fir, Japanese larch, Serbian spruce, Oak, European beech, Poplar, European larch, Red oak, Robinia, Ash,ed alder, Sitka spruce	Crown color				Vegetation indices		0.73	CNN	Remote Sensing

No	文獻		影像來源(衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 樹冠顏色	特徵B 樹冠紋理	特徵C 樹冠高度模型	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
24	Korpela et al.,	2014	Aerial	Multispectral imagery	是	Mixed forests	Pine, Spruce, Birch	Crown color			Canopy spectral signature		illumination	0.87	QDA	Silva Fennica
25	Kulikova et al.,	2007	Aerial	Multi-spectral	否	Plantation	NA		Texture				Tree crown shapes		SVM	2007 15th European Signal Processing Conference
26	Liao et al.,	2018	Aerial	Hyperspectral data	是	Close-to-nature forest	Beech (Fagus sylvatica L.), copper beech (Fagus sylvatica L., 'Atropunicea'), pedunculate oak (Quercus robur L.), common ash (Fraxinus excelsior L.), European larch (Larix decidua Mill.), poplar (Populus spp.), and sweet chestnut (Castanea sativa Mill.). Sycamore maple (Acer pseudoplatanus L.) and alder (Alnus spp.)			Canopy height model	Canopy spectral signature			SVM 0.40-0.82, Deep learning 0.40-0.81	SVM, Deep learning	Digital Object Identifier
27	Michez et al.,	2016	UAV imagery	RGB images	否	Natural and plantion forests	Alnus glutinosa, Fraxinus excelsior, Acer pseudoplatanus, Salix sp., Alnus glutinosa, Picea abiesa, Acer pseudoplatanus, Quercus robur, Other (deciduous species)	Crown color		Canopy height model		Vegetation indices		0.81-0.90	RF	Environ Monit Assess
28	Morgan et al.,	2010	Aerial	RGB images	否	Natural and plantion forests		Crown Color	Texture	Size	Tone				Aerial photo interpretation	BioScience
29	Natesan et al.,	2019	UAV imagery	RGB images	否	Natural and planted forests	White pine, Red pine, Maple, Birch, Beech	Crown color	Texture					0.48-0.54	CNN	Remote Sensing and Spatial Information Sciences
30	Nelson	2017	Satellite Imagery (Sentinel-2)		否	broadleaf and coniferous forest					Spectral band			0.86	RF and ML	Physical Geography and Quaternary Geology
31	Nezami et al.,	2020	UAV imagery	Hyperspectral and RGB Imagery	是	Boreal forests	Scots pine, Norway spruce, and silver birch.	Crown color		Canopy height model				0.66-0.97	Deep Learning	Remote Sensing

No	文獻		影像來源(衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 辨識顏色	特徵B 辨識紋理	特徵C 辨識高程模型	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
	作者	年分														
32	Papeş	2013	Hyperspectral Satellite Imagery		否	broadleaf and coniferous forest					Spectral band			-	stepwise discriminant and function analysis	IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING
33	Pereira et al.,	2019	photo imagery	RGB imagery	否	Grape Plant Species	Tinta Amarela, Tinta Barroca, Tinto Cão, Touriga Franca, Touriga Nacional, and Tinta Roriz				The leaf feature			0.47-0.76	Deep Learning	Sensors
34	Persson et al.,	2018	Satellite Imagery (Sentinel-2)		否	broadleaf and coniferous forest					Spectral band			0.88	RF	Remote sensing
35	Pu and Landry	2012	Satellite Imagery (Worldview-2 and IKONOS)	Multispectral imagery	否	Urban forest	Sand Live Oak (QUGE), Laurel Oak (QULA), Live Oak (QUVI), Pine (PINE), Palm (PALM), Camphor (CICA), Magnolia (MAGR)	Crown color			Canopy spectral signature	Vegetation indices		0.38-0.62	LDA and CART	Remote Sensing of Environment
36	Puttonen et al.,	2010	Aerial	Multispectral imagery, Blue (400–580 nm), Green (500–650 nm), Red (590–675 nm), and NIR (675–850 nm). and airborne laser scanning data	是	Mixed forests	Spruce, pine, fir and beech	Crown color		Canopy height model (CHM)			Illumination Dependent Colour Channels (IDCC)	0.78	Supervised parametric classification	Remote Sensing
37	Raczko and Zagajewski	2017	Aerial	hyperspectral data (222-band)	否	Mixed forests	Birch, Beech, Larch, Alder and Spruce				Canopy spectral signature			ANN 0.77, SVM 0.68 and RF 0.62	SVM, RF and ANN	European journal of remote sensing

No	文獻		影像來源(衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 樹冠顏色	特徵B 樹冠紋理	特徵C 樹冠高程模型	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
	作者	年分														
38	Rafieyan et al.,	2009	Aerial	Multispectral imagery	否	Mixed forests	Gleditsia caspica (GL). Carpinus betulus (CA), Pterocarya fraxifolia (PT), Acer velutinum (AC) along with Cryptomeria japonica. Gleditsia caspica (GL) and Cupressus arizonica (CU)	Crown color			Vegetation indices			0.73 and 0.63	Nearest Neighbour classifier	The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences
39	Ruwaimana et al.,	2018	UAV RGB and IR cameras		否	Wetland				Tree crown features				0.94	Minimum Distance, SAM, ML	PLoS ONE
40	Saatchi and Rignot	1997	Satellite Imagery	SAR imagery	否	Mixed forests	Ack pine (Pinus banksiana), black spruce (Picea mariana), aspen (Populus tremuloids), balsam poplar (Populus balsamifera), and white spruce (Picea glauca), tamarack (Larix laricina), sedge (Carex s'pp.), swamp birch (Bemla pumila).						HH and VV polarizations	0.36-0.90	MAP, Bayesian classifier	Remote Sensing of Environment,
41	Sedliak et al.,	2017	Aerial	Multispectral imagery and airborne laser scanning data	是	Deciduous and conifer forest	Abies alba , Fagus sylvatica, Picea abies, Pinus sylvestris	Crown color						0.82-0.90	Object-based classification	Cent. Eur. For. J.
42	Sheeren et al.,	2016	Satellite Imagery (Formosat-2)		否	broadleaf and coniferous forest					Spectral band			0.91-0.95	GMM and nonparametric, k-NN, RF, SVM	Remote sensing
43	Shi et al.,	2020	Aerial	Multispectral imagery and airborne laser scanning data	是	Mixed forests	beech, birch, fir, maple and spruce			Tree crown features (from point cloud)	Near-infrared features			0.77	RF	J Appl Earth Obs Geoinformation
44	Shojanoori et al.,	2016	Satellite Imagery (Worldview-2)	Multispectral imagery	否	Urban forest	M. ferrea, S. saman and C. sumatrana species, M. ferrea and S. saman, C. sumatrana	Crown color	Texture		Canopy spectral signature			0.62	ML and SVMs	Sains Malaysiana

No	文獻 作者	文獻 年分	影像來源 (衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 顏色特徵	特徵B 紋理特徵	特徵C 樹高高程模型	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
45	Singh et al.,	2015	Aerial	RGB images and airborne laser scanning data	是	Mixed forests	D. alatus, Tetrameles nudiflora, Lagerstroemia calyculata, notably D. alatus and H. odorata			Canopy height model (CHM)	Spectral		Crown width values	0.83	ML and SAM	PLoS ONE
46	Sothe et al.,	2019	UAV imagery	RGB images and Hyperspectral image	否	Mixed forests	Luehea divaricata, Araucaria angustifolia, Mimosa scabrella, Lithrae brasiliensis, Campomanesia xanthocarpa, Cedrela fissilis, Cinnamodendron dinisii, Cupania vernalis, Matayba elaeagnoides, Nectandra megapotamica, Ocotea sp., Podocarpus lambertii	Crown color	Texture	Canopy height model (CHM)		Vegetation indices		0.72	SVM or RF	Remote Sensing
47	Stavrakoudis et al.,	2014	Satellite Imagery (QuickBird)	Multi-spectral and Hyperion data	否	Patches within the forest	Italian oak (Quercus frainetto), Calabrian pine (Pinus brutia), Black pine (Pinus nigra), Beech (Fagus sylvatica), and Norway spruce (Pice abies).				Canopy spectral signature			Hyperion 0.66, QuickBird 0.70 and Fusion 0.78	SVM	Remote sensing
48	Sun et al.,	2017	photo imagery	RGB imagery	否	Urban forest	Chinese buckeye, metasequoia, Ginkgo biloba, hybrid tulip tree, Weigela florida cv. red-prince, Yucca gloriosa, Euonymus kiautschovicus Loes, Berberis thunbergii var. atropurpurea, mottled bamboo, Celastrus orbiculatus, Parthenocissus quinquefolia, and Viburnum opulus, and etc.				The leaf feature, others an entire plant from			0.99	Deep Learning	Computational Intelligence and Neuroscience
49	Sun et al.,	2019	Aerial	RGB images and airborne laser scanning data	是	Welland	banyan tree (F. microcarpa Linn. f.), flame tree (D. regia), silk floss tree (C. speciosa A.St.-Hil.), Bauhinia (Bauhinia purpurea Linn.), eucalyptus trees (Eucalyptus robusta Smith), sakura tree (Cerasus sp.), pond cypress (Taxodium ascendens Brongn), Alstonia scholaris, Bischofia javanica Bl., Hibiscus tiliaceus Linn., and camphor tree	Crown color		Canopy height model				0.73	CNN	Forests

No	文獻		影像來源(衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 樹冠顏色	特徵B 樹冠紋理	特徵C 樹冠高程模型	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
	作者	年分														
							(Cinnamomum camphora (L.) Presl.)) and the fruit tree species (litchi (Litchi chinensis Sonn.), longan (Dimocarpus longan Lour.), banana (Musa nana Lour.), papaya (Carica papaya), carambola (Averrhoa carambola L.), and mango tree (Mangifera indica L.)									
50	Trichon and Julien	2016	Aerial	RGB images	否	Mixed forests	Carapa (Carapa procera), Goupi (Goupia glabra), Gonfolo rose (Qualea rosea) and Symphonia (Symphonia globulifera, Symphonia), Diaguidia (Sclerolobium melinonii)		Colour	Crown size			Crown architecture, Foliage texture, Crown status	0.87	Photo-interpretation	Forest Ecology and Management
51	Verlič et al.,	2014	Satellite Imagery (Worldview-2)	Multispectral imagery and airborne laser scanning data	是	Urban forest	Norway spruce, Scots pine, European beech, Sessile and Pedunculate oak and Sweet chestnut.			Canopy height model (CHM)	Canopy spectral signature			0.58	SVM or RF	Prethodno priopćenje – Preliminary communication
52	Virtanen et al.,	2004	Satellite Imagery (Landsat 5 TM images)	Multispectral imagery	否	Mixed forests	spruce (Picea obovata Ledeb.). Pubescent birch (Betula pubescens Ehrh.) is the most frequent broadleaved tree. Scots pine (Pinus sylvestris L.), Siberian fi r (Abies sibirica Ledeb.), larch (Larix sibirica Ledeb.) and birch				Canopy spectral signature			0.53	Parallelepiped decision rule	Polar Research
53	Wagner et al.,	2019	Satellite Imagery (Worldview-3)	Multi-spectral	否	Natural forest and eucalyptus plantation	Cecropia trees, natural forest and eucalyptus plantation and background	Crown color	Texture					0.97	U-net model	Remote Sensing in Ecology and Conservation
54	Wagner et al.,	2020	Satellite Imagery (Worldview-2)	Multi-spectral	否	Natural and Eucalyptus planted forests	Tibouchina pulchra and Cecropia hololeuca	Crown color	Texture				Elevation data, Climate data	0.95-0.98	U-net model	PLoS ONE
55	Warner et al.,	2006	Aerial	RGB images	否	Mixed forests	Oaks (Quercus spp.), tulip poplar (Liriodendron tuliperifera), and red maple (Acer rubrum)	Crown color						0.68-0.82	ML	Science in China: Series E Technological Sciences

No	文獻		影像來源(衛星/航照/UAV)	影像資料	光達輔助	林型(依據14類)	樹種	特徵A 樹冠顏色	特徵B 樹冠紋理	特徵C 樹冠高模型	特徵D 光譜特徵	特徵E 植生指標	其他特徵	分類精度	分類器	期刊
	作者	年分														
56	Waser et al.,	2011	Aerial	Multispectral imagery and airborne laser scanning data	是	Deciduous forest	Fagus sylvatica and Fraxinus excelsior and Acer sp., Alnus sp., and Betula sp., e Abies alba and Picea abies.			Canopy height model (CHM)	Canopy spectral signature			0.74-0.84	Multinomial regression	Remote Sensing of Environment
57	Weil et al.,	2017	UAV imagery	Multispectral imagery	否	Mixed forests	Pinus halepensis (evergreen conifer) and Quercus calliprinos (evergreen broad-leaved) ect.					Vegetation indices		0.85	SVM and RF	Remote Sensing
58	Weinstein et al.,	2020	Aerial	RGB imagery, the infrared (940 nm), red (650 nm), and blue (430 nm) spectrum.	是	Eastern Deciduous, Alpine, Oak woodland and Mixed pine	Live oak (Quercus agrifolia), blue oak (Quercus douglasii) and foothill pine (Pinus sabiniana) forest, red fir (Abies magnifica) and white fir (Abies concolor), Jeffrey pine (Pinus jeffreyi) and lodgepole Pine (Pinus contorta), maple (Acer rubrum) and white oak (Quercus alba).	Crown color		Canopy height model	Canopy spectral signature		Crown width	0.54 precision for Eastern Deciduous, 0.61 for Oak woodland,0.59 precision for Mixed Pine, 0.26 precision for Alpine.	Deep learning	Ecological Informatics
59	Yu et al.,	2017	Aerial	Multispectral airborne laser scanning	是	Natural and plantation forests	Pine, spruce and Birch			Tree crown features (from point cloud)	Spectral information			0.61	RF	Remote Sensing
60	行政院農林航空測量所	2019	高光譜影像		否	Mixed forests			Texture		Spectral signature	Geometrical Feature		0.63	ML, SVM, CNN and KNN	林務局

附錄四 工作會議記錄

機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
會議紀錄

壹、開會事由：期中審查會議會前會報告

貳、開會時間：民國 109 年 06 月 19 日（星期五）上午 9 時 30 分

參、開會地點：行政院農業委員會林務局農林航空測量所

肆、與會人員：(農航所)葉堃生、黃宗仁；

(興創知能)鄭錦桐、鍾智昕、陳書齊、王選仲。

伍、討論意見：

(一) 擴增樹種，再加入 6 種，共列 12 種樹種；

(1) 針葉林：冷杉、鐵杉、檜木(紅檜、扁柏)、杉木(巒大杉、杉木等)、台灣杉

(2) 闊葉林：相思樹

(二) 原先以航攝影像的 R、G 、B、NIR 四波段作訓練，評估加入 NDVI(Normalized Difference Vegetation Index,標準化植被指數)或其他指數作為多波段。(欲加入之指數會再與鍾老師討論決定)

(三) 考量提供不同判釋人員視角之影像予模型進行訓練，將所有樹種皆以資料增強方法增加旋轉與翻轉後的訓練資料。

(四) 加入 DEM 高程資訊，並且研議增加其他地形因子如坡度、坡向及粗糙度等資訊。

(五) 明年度之研究方向於期末前討論後提供，評估方向包含：

1. 提供農航所影像標記介面(classification or/and object detection)
2. 陰影問題，參考太陽仰角給予權重
3. 設計人機互動介面檢核誤判之樣本
4. 加入高度與分區概念的因子

陸、散會：下午 12 時 00 分

機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
會議紀錄

壹、開會事由：工作進度會議報告

貳、開會時間：民國 109 年 07 月 30 日（星期四）上午 10 時 00 分

參、開會地點：行政院農業委員會林務局農林航空測量所

肆、與會人員：(農航所)葉堃生、黃宗仁；
(興創知能)陳書齊、王選仲。

伍、討論意見：

(一) 於期末時說明由於臺灣肖楠樣本數過少且平均面積較小之故，本期暫不列入樹種判釋的清單內，未來建議可採用多年度影像提升數量。

(二) 本期教育訓練擬訂於 10/26-30 其中一日；或可評估拆為兩日進行，分為經驗分享及技術講座兩場。技術講座可於農航所辦理；經驗分享講座(日本專家學者視訊會議)可於林務局辦理，但考量局內網路設備，建議可於 8 月擇一日進行視訊會議之測試。

陸、散會：上午 11 時 30 分

機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
會議紀錄

壹、開會事由：工作進度會議報告

貳、開會時間：民國 109 年 08 月 21 日（星期五）下午 14 時 00 分

參、開會地點：行政院農業委員會林務局農林航空測量所

肆、與會人員：(農航所)鄧國禎、葉堃生、黃宗仁；

(興創知能)鄭錦桐、鍾智昕、陳書齊、王選仲。

伍、討論意見：

(一) 教育訓練分為兩場次進行，第一場預計於9月底進行經驗講座分享，並於 9 月初於局內測試；第二場預計於 10 月底於所內進行技術講座。

(二) 預計於年底完成本案第二期簽約，建議於後期工作會議提出明年度工作項目建議。

(三) 本期採用訓練之因子於訓練結果後提供各因子貢獻分析之報表，以利掌握於模型中各因子影像之訓練比重。

(四) 研議下一期加入航攝影像資料時間資訊，並納入不同時間同一地區之多期影像，以利評估落葉型樹種之特性可否精進模型準確性。

(五) 期末前待辦事項：

1. 擴增樹種，本期共訓練 11 種樹種，包含：
   (1)針葉林：松樹(二葉松、五葉松等)、柳杉、冷杉、鐵杉、檜木(紅檜、扁柏)、杉木(巒大杉、杉木等)、台灣杉。
   (2)闊葉林：闊葉林：臺灣赤楊、相思樹。
   (3)竹林：單桿狀竹、叢生狀竹。
2. 評估加入 NDVI(Normalized Difference Vegetation Index,標準化植被指數)或其他指數作為多波段。
3. 考量提供不同判釋人員視角之影像予模型進行訓練，將所有樹種皆以資料增強方法增加旋轉與翻轉後的訓練資料。
4. 加入 DEM 高程資訊，研議增加其他地形因子，包含：坡度、坡向及粗糙度(TRI、TPI)。
5. 提供各因子貢獻程度之分析成果。

陸、散會：下午 15 時 30 分

機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
會議紀錄

壹、開會事由：工作進度會議報告

貳、開會時間：民國 109 年 10 月 21 日（星期三）下午 14 時 00 分

參、開會地點：行政院農業委員會林務局農林航空測量所

肆、與會人員：(農航所)鄧國禎、黃宗仁；

(興創知能)鄭錦桐、鍾智昕、王選仲、吳笙緯。

伍、討論意見：

(一) 期末報告內容確認與補充：

1. 農航所有提供 5m 的 DEM，須說明最後不使用的原因。
2. 最後一章可放明年規劃 ，論述可從今年結論推導至還缺甚麼，帶出明年工項規劃。
3. 須說明期中期末判釋成果、用了哪些地型因子、航照影像的拍攝時間、各光譜貢獻值

(二)明年規劃事項：

1. 研究高解析度航攝及 UAV 影像以機器學習技術自動化萃取森林覆蓋型之演算模式與實作
   - 目前：已完成航照影像判釋林型的模型
   - 規劃：使模型能真的使用而非單純研究
     (1) 校正反投影偏移 (立體影像對產製 DSM、小部分 DSM 訓練模型、全球森林模型)
     (2) 增加少樣本物種之影像資料
2. 評估機器學習相關軟體與國內高速運算資源及測試
   - 目前：使用 python+keras，在 30 萬等級的工作站即能平行化高速運算
   - 規劃：評估不同電腦運算模型所需時間 (有時間、硬體上的考量)

3. 研究機器學習演算法及流程效能提升方案
   - 目前：已經優化運算速度，有透過 NDVI 跟地文因子優化演算法
   - 規劃：
     (1) 評估各波段組合指標對判釋成果影響
     (2) 評估優化高解析度影像判釋的深度學習方法
     (3) 評估以衛星影像的光譜資訊輔助增加物候資訊
4. 以機器學習技術自動萃取森林物件特徵演算法評估測試與調查流程建置
   - 目前：已使用 CNN 自動萃取
   - 規劃：設計軟硬體介面，讓農航所實際試用
5. 投稿至少 1 篇論文至國內外期刊或研討會
6. 教育訓練

(三) 教育訓練將在 2020 年 10 月 26 日舉辦於農航所，其日程表規劃如下：

時間	時數	課程名稱	講師
9:20-9:30	10 分	報到入座	-
9:30-10:30	60 分	本計畫現況成果與未來規劃	興創知能 鄭錦桐博士
10:30-10:40	10 分	休息時間/交流	-
10:40-11:40	60 分	機器學習應用於林業之相關實例與文獻回顧	宜蘭大學 鍾智昕教授
11:40-12:00	10 分	綜合討論	-
12:00-14:00	午休時間		
14:00-15:30	90 分	技術研發講師 深度學習基礎(CNN & DNN)、深度學習影像分割模型	興創知能 技術研發講師
15:30-16:00	30 分	綜合討論	-

(四) 各項期程：

1. 11 月 4 日下午 2 時召開期末報告會前會
2. 11 月 10 日前繳交期末報告書(含 12 本報告書與電子檔乙份)
3. 12 月 10 日前繳交修正後報告書(含 12 本報告書與電子檔乙份)
4. 12 月底前完成第二期的服務建議書

陸、散會：下午 16 時 30 分

機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
會議紀錄

壹、開會事由：期末審查會前會議

貳、開會時間：民國 109 年 11 月 04 日（星期三）下午 14 時 00 分

參、開會地點：行政院農業委員會林務局農林航空測量所

肆、與會人員：(農航所)鄧國禎、黃宗仁

(興創知能)鄭錦桐、王選仲、吳笙緯。

伍、討論意見：

(一)增加 DEM 訓練因子後，期中分類結果的 kappa 值從 0.4 提升至 0.6，因此我們認為加入地形因子有助於模型訓練分類，所以在期末階段的訓練因子增加了 DEM 與其衍生產物(Slope、Aspect、Roughness、TPI、TRI)，另外考量到 NDVI 值對植生也有一定的分類幫助，故也增加此因子，於期末共使用了 11 種訓練因子。

(二)藉由增加訓練因子與調整 CNN 模型之超參數，目前整體精度達 47%。

(三)由農航所內同仁判釋模型訓練成果。

(四)需在 11 月 10 日前繳交期末報告書，期末審查會議預計安排於 11 月底。

陸、散會：下午 16 時

附錄五 教育訓練簡報

計畫主持人 - 鄭錦桐博士

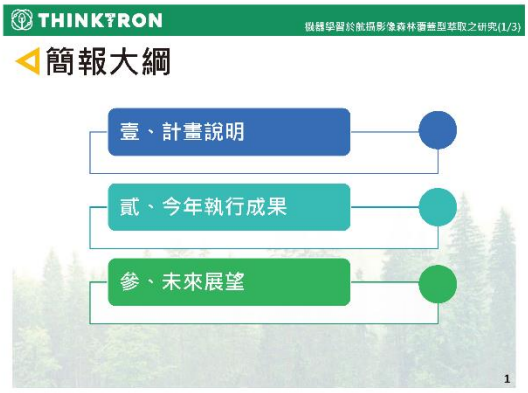

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
貳
109年執行成果
一、資料蒐集
二、森林物件萃取模型設計與建立
6

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
一、資料蒐集
文獻蒐集
森林資源管理方法
航遙測影像之應用
機器學習方法導入
航攝影像蒐集
調庫測試樣區選定
樣區航攝影像製裝
取得DMC航攝影像共718張
現地資料蒐集
全國森林資源調查
永久樣區調查
國有林檢定調查
第四次森林資源調查區實取得
其他資料蒐集
數值正型模型
地形因子萃取
全島各縣市森林覆蓋範圍
(第四次森林資源調查報告)
區位 | 總面積(公頃) | 森林覆蓋面積(公頃) | 覆蓋率
林地 | 1,993,205 | 1,781,660 | 89.38%
其他土地 | 1,625,791 | 415,430 | 25.24%
合計 | 3,618,996 | 2,197,090 | 60.71%
臺灣森林資源多樣性高
地形陡峭資源掌握困難
AI輔助提升調查效率
7

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
一、資料蒐集
1. 文獻蒐集
• 針對蒐集到之相關文獻彙整成總表。
文獻蒐集總表包含欄位：
作者(文獻)、年份(文獻)、影像來源(衛星/航照/UAV)、LiDAR輔助、林型、樹種、林型因子(特徵)A-E、分類精度、波段選擇、Window size、Pixel size、地面樣區調查、分類器、期刊、簡名
目前共51篇
8

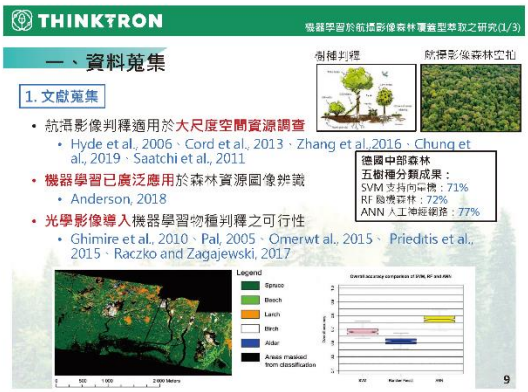
THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
一、資料蒐集
1. 文獻蒐集
• 航攝影像判釋適用於大尺度空間資源調查
• Hyde et al., 2006、Cord et al., 2013、Zhang et al.,2016、Chung et al., 2019、Saatchi et al., 2011
• 機器學習已廣泛應用於森林資源圖像辨識
• Anderson, 2018
• 光學影像導入機器學習物種判釋之可行性
• Ghimire et al., 2010、Pal, 2005、Omerwt al., 2015、Prieditis et al., 2015、Raczko and Zagajewski, 2017
樹種判釋
航攝影像森林空拍
德國中部森林
五樹種分類成果：
SVM支持向量機：71%
RF隨機森林：72%
ANN人工神經網路：77%
Legend
Spruce
Beech
Larch
Birch
Alder
Areas masked from classification
9

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
一、資料蒐集
1. 文獻蒐集
• 存在影像資料樣態複雜判釋難度高挑戰多
• Ghazi et al., 2017
• 深度學習改善特徵選取方法提升分析效率
• LeCun et al., 2015、Wagner et al., 2019
拍攝陰影樣態差異
深度學習特徵萃取
Silva et al. 2016 Within Site Training
Eastern Deciduous
Mixed Pine
Alpine
Oak Woodland
10

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
一、資料蒐集
2. 現地資料蒐集
現地調查計畫盤點
全國性森林資源調查
第四次調查項目
林地調查、森林林型圖繪製、土地利用型圖繪製、森林蓄積調查(地面樣區調查、航照樣點判釋)、林地以外之森林覆蓋調查、以及野生動物調查等。
現地資料由此計畫調查成果為主
項目/次別 | 第一次 | 第二次 | 第三次 | 第四次
調查時間 | 1954-1956 | 1972-1977 | 1990-1993 | 2008-2010
主辦單位 | 農復會 | 林務局 | 林務局 | 林務局
拍攝航向 | 東西向 | 南北向 | 南北向 | 南北向
覆蓋範圍 | 未覆蓋全島 | 覆蓋全島 | 覆蓋全島 | 覆蓋全島
照片樣點 | 37,945點 | 134,046點 | 286,925點 | 191,240點
地面樣區 | 545個 | 4,132個 | 3,996個 | 3,648個
取樣方法 | 雙重分層取樣 | 雙重分層取樣 | 分層取樣 | 航照樣點雙重取樣
樣區狀態 | 五居同心圓 | 樣線透動面積 | 固定矩形 | 固定矩形
樣區決定 | 以Neyman公式計算地面樣區，依最適分配決定 | 系統取樣後，再進機取樣 | 系統取樣 | 系統取樣
調查方法 | 同心圓樣區調查 | 水平樣線調查 | 水平樣線調查 | 水平樣線調查
資料來源：從原來調查量整合為第四次森林資源調查
11

第一層分類(IPCC name)	第二層分類(type name)	內政部國土利用調查	第三次森林資源調查
林地FL	01針葉樹林型 02闊葉樹林型 03針闊葉樹混淆林 04竹林 05竹闊混淆林 06竹針混淆林 07竹針闊混淆林 08待成林地	02森林使用土地	011冷杉天針～190人竹闊針混等 44個林型類別 650伐木跡地

類別	樹種	林型圖內polygon數量	平均面積(平方公尺)
針葉樹林型	松樹(二葉松五葉松等)	13,529	66,059.73
	柳杉	9,983	31,230.37
	冷杉	5,930	46,873.66
	鐵杉	11,217	68,445.88
	檜木(紅檜、扁柏)	6,966	65,864.47
	杉木(巒大杉杉木等)	3,888	21,107.04
	臺灣肖楠	1,872	5,902.44
	台灣杉	1,076	39,975.24
闊葉樹林型	台灣赤楊	1,037	46,519.48
	相思樹	593	49,683.74
	光臘樹	48	100,245.54
	大葉桃花心木	16	16,259.45
	台灣櫸	64	42,482.11
	木油桐	70	19,964.02
	銀合歡	1	184,389.24
竹林	叢生狀竹	36,399	16,864.43
	單桿狀竹	20,160	17,960.75

圖資總類		規格	比例尺	備註
航空照片	彩色/黑白、DMC數位航空照片(未放大)	相紙，30x30cm、16x30cm	無固定比例尺	● 民國62~90年以前為黑白照片 ● 民國90年以後為彩色照片 ● 民國97年以前為傳統底片掃描影像 ● 民國97年以後陸續改為數位影像(含NIR)
	彩色/黑白、DMC數位航空照片(局部放大10倍)	相紙，30x30cm、50x50cm		
	黑白照片掃描影像檔	光碟片，14μm，tif格式		
	彩色照片掃描影像檔	光碟片，14μm，tif格式		
	DMC數位影像檔	光碟片，13824*7680pix，tif格式		
	ADS數位影像檔	光碟片，以1/5000基本圖幅計，tif格式		
像片基本圖	林區像片基本圖	紙圖，60cm*76cm	1/5000	含林班、小班損號、林相、林齡級、材積級、等高線、河流、道路、自營林標等標註
	金門衛星影像圖		1/5000	全屬機密級
正射影像	正射影像圖	紙圖，60cm*76cm	1/5000	含圖框座標，無其他標註
	正射影像檔	光碟片，地面解析度25、37.5、50cm含tif影像、tfw坐標檔及dxf圖框註記檔		

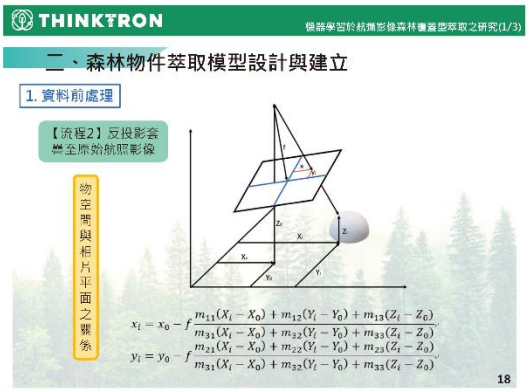
THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
1. 資料前處理
【流程2】反投影會共線至原始航照影像
物空間與相片平面之關係
$x_i = x_0 - f\frac{m_{11}(X_i - X_0) + m_{12}(Y_i - Y_0) + m_{13}(Z_i - Z_0)}{m_{31}(X_i - X_0) + m_{32}(Y_i - Y_0) + m_{33}(Z_i - Z_0)}$
$y_i = y_0 - f\frac{m_{21}(X_i - X_0) + m_{22}(Y_i - Y_0) + m_{23}(Z_i - Z_0)}{m_{31}(X_i - X_0) + m_{32}(Y_i - Y_0) + m_{33}(Z_i - Z_0)}$
18

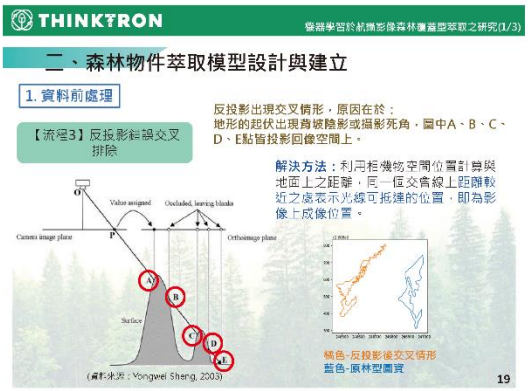
THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
1. 資料前處理
【流程3】反投影錯誤交叉排除
反投影出現交叉情形，原因在於：
地形的起伏出現背坡陰影或攝影死角，圖中A、B、C、D、E點皆投影回像空間上。
解決方法：利用相機物空間位置計算與地面上之距離，同一恆交會線上距離較近之處表示光線可抵達的位置，即為影像上成像位置。
Value assigned
Occluded, leaving blanks
Camera image plane
Orthoimage plane
Surface
(資料來源：Yongwei Sheng, 2003)
綠色-反投影後交叉情形
藍色-原林型圖資
19

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
1. 資料前處理
【流程4】像空間內插
以內插方法解決正射畫布解析度不足問題(原始影像解析度0.3~0.5m)
內插結果
20

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
1. 資料前處理
【流程1~4】)反投影成果
原始正射
反投影成果
21

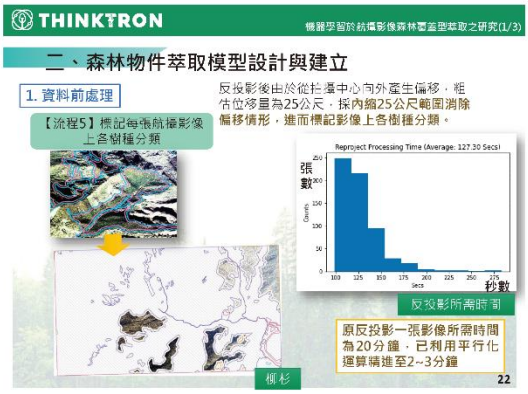
THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
1. 資料前處理
【流程5】標記每張航攝影像上各樹種分類
反投影後由於從拦截中心向外產生偏移，經估移量為25公尺，採內縮25公尺範圍消除偏移情形，進而標記影像上各樹種分類。
Reproject Processing Time (Average: 127.30 Secs)
張數
秒數
反投影所需時間
原反投影一張影像所需時間為20分鐘，已利用平行化運算精進至2~3分鐘
柳杉
22

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
1. 資料前處理
【流程6】影像樹種分類進行模型樣本建立
影像切片
每張尺寸512*512pixel
在影像上每移動256pixels裁切一張
移除非屬該樹種之資訊
每格影像包含50%以上的樹種範圍
23

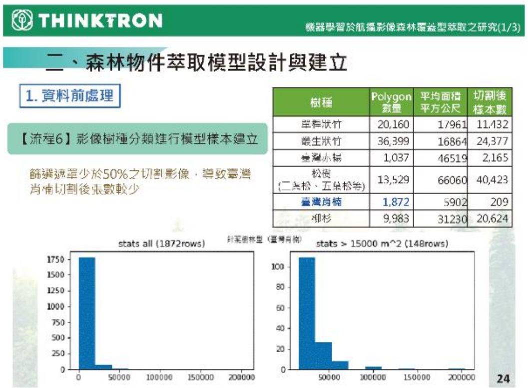
THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
1. 資料前處理
【流程6】影像樹種分類進行模型樣本建立
篩選遮罩少於50%之切割影像，導致臺灣肖楠切割後張數較少
樹種 | Polygon數量 | 平均面積平方公尺 | 切割後樣本數
單桿狀竹 | 20,160 | 17961 | 11,432
叢生狀竹 | 36,399 | 16864 | 24,377
臺灣赤楊 | 1,037 | 46519 | 2,165
松樹(二葉松、五葉松等) | 13,529 | 66060 | 40,423
臺灣肖楠 | 1,872 | 5902 | 209
柳杉 | 9,983 | 31230 | 20,624
stats all (1872rows)
stats > 15000 m^2 (148rows)
24

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
1. 資料前處理
【流程7】樣本資料增強
資料增強：由於臺灣肖楠樣本數量少，利用旋轉90度、180度、270度、左右翻轉與上下翻轉，增加樣本數。
Data Aumentation
x
x_flip0
x_flip1
x_rot90
x_rot180
x_rot270
樹種 | 切割後樣本數
單桿狀竹 | 11,432
叢生狀竹 | 24,377
臺灣赤楊 | 2,165
松樹(二葉松、五葉松等) | 40,423
臺灣肖楠 | 1,279
柳杉 | 20,624
25

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
2. 森林物件萃取標準化流程架構規劃
檢訂森林調查計劃
約10年更新
全國森林資源調查
每15年-20年不定期更新
-第三次森林資源調查報告
-第四次森林資源調查報告
每5年更新
森林圖資更新作業
農航所航照影像倉儲
光譜解析力、空間解析力
時間解析力、輻射解析力
AI訓練模型資料
林型圖
檢訂調查資料
永久樣區資料
航攝影像
特徵萃取概念應用
色調、顏色、紋理、大小、形狀、組織、圖案、高度、陰影、立地、關聯物
基於第四次森林資源調查林型圖資影像判釋資料庫
更新資料
AI模型建立
林型圖 林地FL
IPCC name
第二層分類
type name
樹種
01.針葉樹林型
02.闊葉樹林型
03.針闊葉樹混淆林
04.竹林
05.竹闊混淆林
06.竹針混淆林
07.竹針闊混淆林
08.待成林地
26

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
2. 森林物件萃取標準化流程架構規劃
航攝影像訓練資料篩選
類別 | 樹種 | 林型圖內polygon數量 | 平均面積(平方公尺)
針葉樹林型 | 松樹(二葉松五葉松等) | 13,529 | 66,059.73
 | 柳杉 | 9,983 | 31,230.37
 | 冷杉 | 5,930 | 46,873.66
 | 鐵杉 | 11,217 | 68,445.88
 | 檜木(紅檜、扁柏) | 6,966 | 65,864.47
 | 杉木(巒大杉杉木等) | 3,888 | 21,107.04
 | 臺灣肖楠 | 1,872 | 5,902.44
 | 台灣杉 | 1,076 | 39,975.24
闊葉樹林型 | 台灣赤楊 | 1,037 | 46,519.48
 | 相思樹 | 593 | 49,683.74
 | 光臘樹 | 48 | 100,245.54
 | 大葉桃花心木 | 16 | 16,259.45
 | 台灣櫸 | 64 | 42,482.11
 | 大油桐 | 70 | 19,964.02
 | 銀合歡 | 1 | 184,389.24
竹林 | 叢生狀竹 | 36,399 | 16,864.43
 | 單桿狀竹 | 20,160 | 17,960.75
航攝影像林型圖判釋統計
航攝影像 | 資料筆數
推掃式影像(ADS) | 95,779 張
正射影像(TIF) | 1,874 張
傳統影像 | 1,107 張
片幅式影像(DMC) | 227,118 張
以第四次全國森林資源調查11類樹種圖層判釋成果，隨機對全國航攝影像進行隨機抽樣。
已取得計畫使用718幅DMC影像對
27

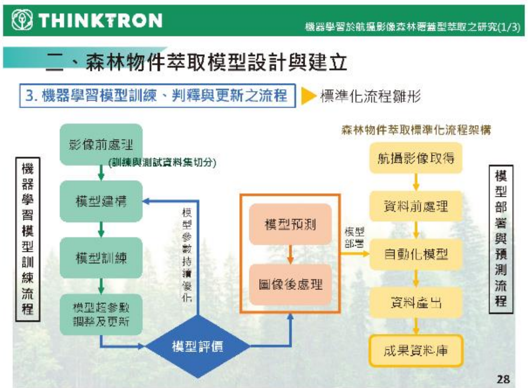
THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
3. 機器學習模型訓練、判釋與更新之流程
標準化流程雛形
機器學習模型訓練流程
影像前處理
(訓練與測試資料集切分)
模型建構
模型訓練
模型超參數調整及更新
模型參數持續優化
模型評價
模型預測
圖像後處理
模型部署
森林物件萃取標準化流程架構
航攝影像取得
資料前處理
自動化模型
資料產出
成果資料庫
模型部署與預測流程
28

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
4. 期中階段訓練情形
採用分類模型：CNN+DNN
採七比三之比例切分訓練與測試資料集
Data
Training Set (70%)
Testing Set (30%)
整體精度 OA = X11+X22 / X11 &X22&X12&X21
判斷為真，實際為真+判斷為否，實際為否/所有資料
生產者精度 PA = X11 / X11&X21
判斷為真，實際為真/判斷為真
使用者精度 UA = X11 / X11&X12
判斷為真，實際為真/實際為真
誤差矩陣 | 分類成果
類別1 | 類別2 | 生產者精度PA
現地資料 類別1 | X11 | X12 | PA1
類別2 | X21 | X22 | PA2
使用者精度UA | UA1 | UA2 | -
整體精度：OA | 平均精度：AA | Kappa指標：K
29

THINKTRON 機器學習於航攝影像森林覆蓋型萃取之研究(1/3)

二、森林物件萃取模型設計與建立

4. 期中階段訓練情形

▷六類樹種訓練結果

訓練結果：整體精度 51.28%，Kappa值為0.51

Baseline定義：選型猜最多多數別的結果

誤差矩陣		分類成果		
		類別1	類別2	生產者精度PA
現地資料	類別1	X_{11}	X_{12}	PA1
	類別2	X_{21}	X_{22}	PA2
	使用者精度UA	UA1	UA2	-
整體精度：OA		平均精度：AA		Kappa指標：K

樹種	X_{11}	X_{22}	X_{12}	X_{21}	Baseline	整體精度	生產者精度PA	使用者精度UA
單桿狀竹	88	1,443	191	78	84.50%	85.06%	31.54%	53.01%
叢生狀竹	200	1,422	112	66	82.67%	90.11%	64.10%	75.19%
松樹（二葉松、五葉松等）	171	1,225	151	253	82.11%	77.56%	53.11%	40.33%
臺灣肖楠	210	1,349	92	149	83.22%	86.61%	69.54%	58.49%
柳杉	107	1,423	192	78	83.39%	85.00%	35.79%	57.84%
臺灣赤楊	147	1,261	139	253	84.11%	78.22%	51.39%	36.75%

30

THINKTRON 機器學習於航攝影像森林覆蓋型萃取之研究(1/3)

二、森林物件萃取模型設計與建立

4. 期中階段訓練情形

▷被錯誤分類成其他樹種之次數

▷單桿狀竹

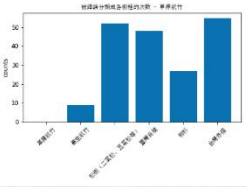

▷叢生狀竹

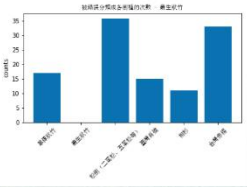

31

THINKTRON 機器學習於航攝影像森林覆蓋型萃取之研究(1/3)

二、森林物件萃取模型設計與建立

4. 期中階段訓練情形

▷被錯誤分類成其他樹種之次數

▷松樹（二葉松、五葉松等）

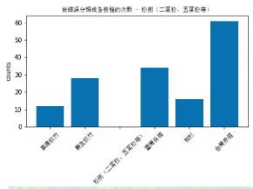

▷臺灣肖楠

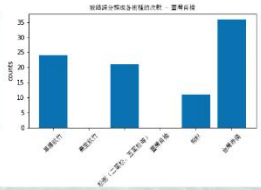

32

THINKTRON 機器學習於航攝影像森林覆蓋型萃取之研究(1/3)

二、森林物件萃取模型設計與建立

4. 期中階段訓練情形

▷被錯誤分類成其他樹種之次數

▷柳杉

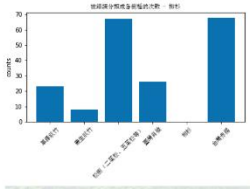

▷臺灣赤楊

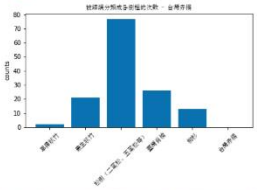

33

THINKTRON 機器學習於航攝影像森林覆蓋型萃取之研究(1/3)

二、森林物件萃取模型設計與建立

4. 期中階段訓練情形

▷單桿狀竹

紅字為與農航所確認之結果

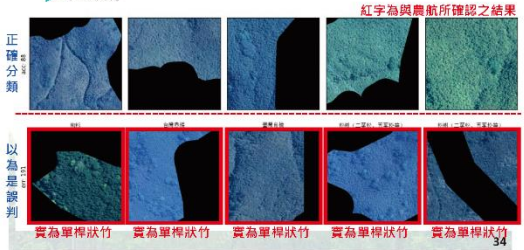

34

THINKTRON 機器學習於航攝影像森林覆蓋型萃取之研究(1/3)

二、森林物件萃取模型設計與建立

4. 期中階段訓練情形

▷叢生狀竹

紅字為與農航所確認之結果

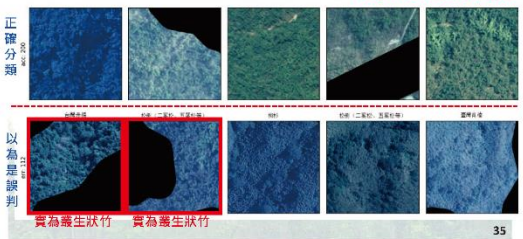

35

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
4. 期中階段訓練情形
▷松樹（二葉松、五葉松等）
紅字為與農航所確認之結果
正確分類
以為是誤判
賣為松樹
賣為松樹
36

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
4. 期中階段訓練情形
▷臺灣肖楠
非臺灣肖楠
紅字為與農航所確認之結果
正確分類
以為是誤判
非臺灣赤楊
賣為臺灣肖楠
37

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
4. 期中階段訓練情形
▷柳杉
紅字為與農航所確認之結果
正確分類
以為是誤判
賣為柳杉
賣為柳杉
38

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
二、森林物件萃取模型設計與建立
4. 期中階段訓練情形
▷臺灣赤楊
紅字為與農航所確認之結果
正確分類
以為是誤判
非叢生狀竹
非叢生狀竹
非叢生狀竹
39

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
參
明年規劃與未來展望
一、 110年執行規劃
二、未來展望
40

THINKTRON
機器學習於航攝影像森林覆蓋型萃取之研究(1/3)
一、110年執行規劃
原先規劃
2020目前進度
2021新規劃之操作狀況
1. 研究高解析度航攝及UAV影像以機器學習技術自動化萃取森林覆蓋型之適宜模式與實作
已完成航攝影像判釋林型之模型
1. 校正反投影精準
2. 增加少樣本物種之影像資料
2. 評估機器學習相關軟體與國內高速運算資源及測試
1. 已經使用機器學習軟體 Python + Keras
2. 已經以平行化運算進行高速運算 (30萬工作站)
3. 研究機器學習演算法及流程效能提升方案
1. 已經根據地文因子與植生指標優化演算法，
2. 已經優化運算速度: 90min/img => 85s/img
1) 反投影計算: 10min/img => 0.5s/img
2) 反投影內插: 60min/img=> 0.5s/img
1. 評估優化高解析度影像判釋之深度學習方法
2. 評估各波段組合指標對判釋成果之影響
3. 評估高量光譜輔助物候特性之可行性
4. 以機器學習技術自動萃取森林物件特徵演算法評估測試與流程建置
已經使用自動化物件萃取之演算法CNN
根據提高森林資源調查流程自動化程度之軟硬體介面
5. 投稿至少1篇論文至國內外期刊或研討會
本期實際之主要方法已發表於ISPRS: H.-C. Wang, XLIII-B2-2020, GENERAL DEEP LEARNING SEGMENTATION PROCESS USED IN REMOTE SENSING IMAGES
6. 教育訓練
41

THINKTRON 機器學習於航攝影像森林覆蓋型萃取之研究(1/3)

一、110執行規劃

測試加入DSM或其他方法，以期改善偏移問題

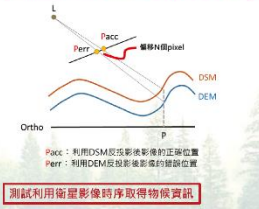

Pacc：利用DSM反投影後影像的正確位置
Perr：利用DEM反投影後影像的錯誤位置

測試利用衛星影像時序取得物候資訊

- 物候資訊可做為判釋因子之一，然而航照影像之頻數尚不足萃取物候資訊。
- 規劃加入衛星影像的光譜資訊輔助萃取各林型之物候，觀察對判釋精度之影響。

42

THINKTRON 機器學習於航攝影像森林覆蓋型萃取之研究(1/3)

二、未來展望

- 讓模型真正運作，而非紙上談兵
- 有效優化現行流程

43

THINKTRON 機器學習於航攝影像森林覆蓋型萃取之研究(1/3)

THANK YOU

44

協同主持人－鍾智昕博士

機器學習應用於
林業之相關實例
與文獻回顧
鍾智昕 Ph.D

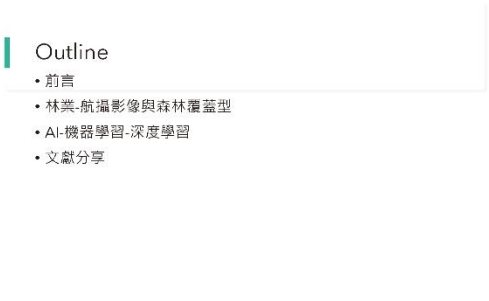
Outline
• 前言
• 林業-航攝影像與森林覆蓋型
• AI-機器學習-深度學習
• 文獻分享

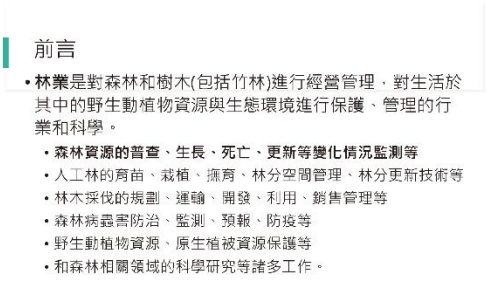
前言
• 林業是對森林和樹木(包括竹林)進行經營管理，對生活於其中的野生動植物資源與生態環境進行保護、管理的行業和科學。
• 森林資源的普查、生長、死亡、更新等變化情況監測等
• 人工林的育苗、栽植、撫育、林分空間管理、林分更新技術等
• 林木採伐的規劃、運輸、開發、利用、銷售管理等
• 森林病蟲害防治、監測、預報、防疫等
• 野生動植物資源、原生植被資源保護等
• 和森林相關領域的科學研究等諸多工作。

Why should foresters recognize trees species?
• 樹種組成是描述森林類型的重要基本資料，亦為森林經營與管理的必要資訊(Waser et al., 2011)。
• 精確的林木樹種分布空間資訊，是研究森林動態的關鍵訊息
• 森林經營管理
• 生態保育監測
• 生物多樣性現況
• 國土規劃
• 估計碳排放量
• 環境教育
• 其他生態系統服務

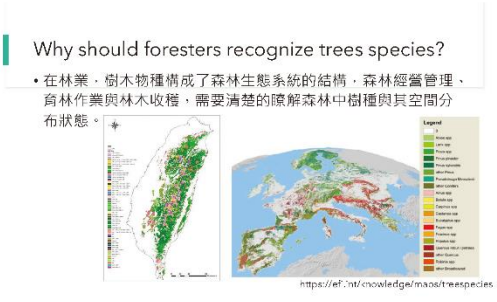
Why should foresters recognize trees species?
• 在林業，樹木物種構成了森林生態系統的結構，森林經營管理、育林作業與林木收穫，需要清楚的瞭解森林中樹種與其空間分布狀態。
https://efi.int/knowledge/maps/treespecies

樹木識別訓練
（圖片來源：Adobestock）
http://web12.ravs.ntct.edu.tw/manage/script/ife/ife_rpdet.asp?_id=446&SearchWords=&page=46

科技提供樹木識別一個方便的工具

https://www.woodlandtrust.org.uk/trees-woods-and-wildlife/british-trees/how-to-identify-trees/

國家尺度森林資源管理

- 森林-係指區域範圍內以木本植物群落為主體所構成的生態系統。
- 聯合國糧食及農業組織對森林的定義為面積在0.5公頃以上，林木高度至少5公尺，樹冠覆蓋率大於10%，或林木在原生地可到此標準的土地（FAO,2015）。
  - 林分(stand)是指群生之林木與鄰近的森林在樹種組成、林齡、空間分布或其他性狀有明顯區別的森林。
  - 森林類型(Forest type)是對於林分的一種分類標記，主要由一定區域範圍中的樹木組成種類決定。

調查林分中樹木種類，是一個非常耗費人力過程

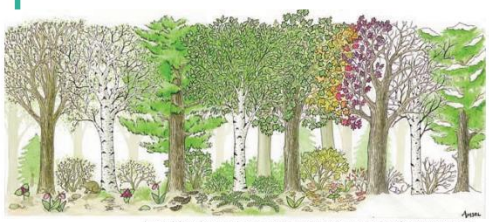

http://blogs.hernico.k12.va.us/21/2016/03/25/tree-identification-project/

大尺度的調查工具

https://waypoint.sensefly.com/infographic-geospatial-data-collection-drones-satellite-manned/

森林覆蓋型或樹種辨識

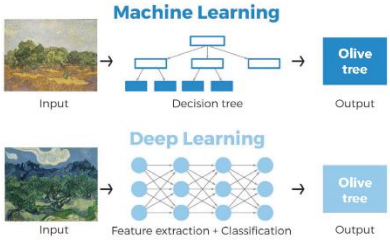

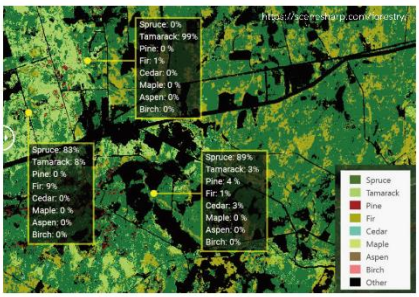

AI-機器學習-深度學習

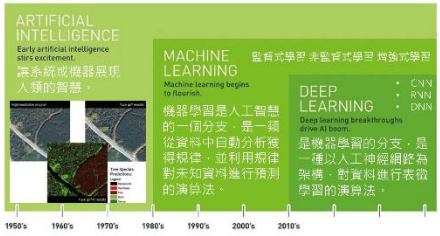

Seeing the Tree and the Forest

https://agriharvest.tw/archives/11073

森林性狀及分類

- 林分的性狀一般指林分的外貌狀態(status)
- 由樹種、林齡、密度、林木空間位置與樹冠級等組合，因此，可透過樹種組成(species composition)、林分結構(stand structure)、林分蓄積量(stand growing stock) 等來描述其森林性狀及分類。

形成機制

- 天然林:主要以林木自身的繁殖更新能力生成之森林，樹種、林齡與樹冠層結構複雜，包含地被植群、幼苗、幼木、成熟木、枯立木與倒木。
- 人工林:係指透過人為方式以種子、苗木或分生組織為材料所建立的森林，多以苗木栽植造林。
- 次生林:天然林係因人為伐採、崩塌、火災或其他原因破壞後，透過天然更新機制所形成的森林。

樹種組成:針葉樹、闊葉樹與竹林

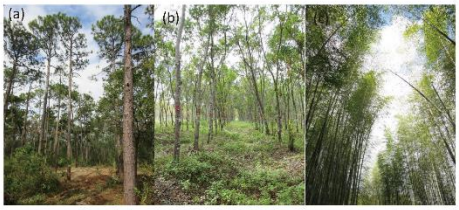

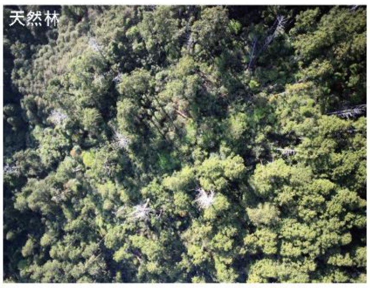

航照與森林類型判釋

- 最早在1920s航空影像被應用在森林與自然資源管理，1940s後逐漸受到重視，用來描繪林型地圖則是在1950s之後(Paijmans, 1951；Aldrich, 1953；Sandor, 1955)。
- Paijmans (1951)在Malili forests of the Celebes (Sulawesi)，拍攝了1:10000的航空照片，並提出航空照片在一定比例下可以識別樹種。
- Francis（1955）使用1:25000識別了10種婆羅洲紅樹林樹種。
- Hannibal（1962）從航空照片識別單一樹種所形成的植物群落。

http://www.fao.org/3/a3200e02.htm

如何在航照上識別森林類型和樹木種類？

- 每個圖片判釋員，都可能會隨著知識與經驗的增加，發展出自己的判釋思維。
- 航空照片上的特徵(樹冠特徵、紋理或葉子顏色, (Heller et al., 1964）。
- 樹種的生理(陰性或陽性)，適應的氣候環境。

航空照片上的特徵

- 1960s以後航空攝影被廣泛使用於識別樹木種類和森林類型。
- 依據航空照片的紋理(texture)、顏色(color) 、色調(tone) 、形狀(shape) 、尺寸(size)和型態(pattern)等定性特徵，進行森林類型或樹種識別。

航照判釋原則

- **色調及顏色(tone/color)**：目標物件之成像特性，通常吸收光線愈多者，影像色調則愈深，吸收光線少，而反射多者，則其色調必淡，如紅檜呈現紅褐色樹冠。
- **大小(size)**：目標物件之幾何形態，照片上影像外表面積之大小，亦為識別重要因素之一，如能量取樹冠大小(寬度)，即易予區別，因此判釋時應注意照片比例尺，以免發生錯誤之判斷。
- **形狀(shape)**：目標物件之輪廓，形狀為判斷物體的重要依據，如針葉樹之樹冠多呈圓錐形，灌叢通常樹冠呈半球型貼於地面，且因航照圖有拍攝角度的影響，所以在實際判釋影像時，須留意是否需要旋轉影像以利判讀。
- **紋理組織(texture)**：根據影像表面結構之粗細，以識別物體之類別，組織為判釋林木最重要之依據，如密生幼林為細組織，過老林木為粗鬆組織，針葉樹為較細組織，闊葉樹為粗狀組織。
- **圖案型態(pattern)**：目標物件於空間中之排列情形，目標物件群體之綜合表徵，所有照片上顯示之地物排列情形，均由人為或自然因素使然，人為地物之排列，其型態多有規則，在照片上容易辨別，如林業人員由林木排列情形可判斷是否為造林地，如人工林樹冠整齊劃一。
- **陰影(shadow)**：輔助辨識目標物件本體之特性，容易以其陰影形狀區別，並可由其陰影之長度測出物體之高度，但陰影的缺點為遮掩了許多地物的影像。
- **立地(site)**：目標物件所處之環境狀態，立地環境在照片判釋上佔極重要之地位，因林木受立地因子影響而限制分佈，如針葉樹大多出現在較高海拔地區，或者坡向(向陽背陽)與生長的關係。
- **關聯物(related object)**：目標物件伴隨出現之其他物件，大多數物體附近有一些與之相關的地物同時存在，以協助辨認，如伴生植物等。

航空照片上的特徵

Table 11.2. Aerial photographic crown characteristics of major conifers occurring in New Hampshire, New York, and Vermont (Ciesla, 1984).

SPECIES	CROWN TYPE	CROWN APEX	CROWN MARGIN	FOLIAGE TEXTURE
Red or black spruce	Broadly conical	Obtuse	Lobed	Medium
Balsam fir	Narrowly conical	Acute/acuminate	Finely serrate	Fine
Eastern hemlock	Broadly conical	Obtuse	Sinuate	Fine
Eastern white pine	Irregular, horizontal branching	Broadly rounded	Lobed/parted	Medium
Red pine	Open, rounded	Broadly rounded	Finely serrate	Fine
Eastern larch	Narrowly conical	Acute	Finely serrate	Fine
Northern white cedar	Oval	Broadly rounded	Entire/sinuate	Medium

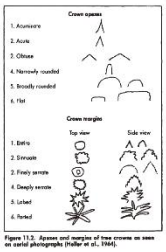

Figure 11.2. Apexes and margins of tree crowns as seen on aerial photographs (Heller et al., 1964).

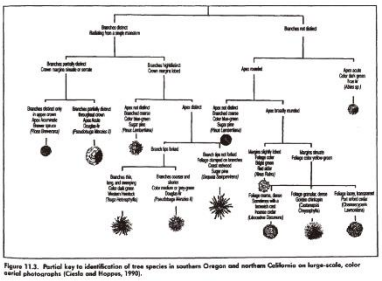

Figure 11.3. Partial key to identification of tree species in southern Oregon and northern California on large-scale, color aerial photographs (Ciesla and Hoppus, 1990).

自動化林木樹種判釋技術

- 1990s以後開始半自動或自動分類
- 在很大的空間範圍透過現地調查森林物種組成，必須花費相當高的金錢、勞力與時間成本。
- 隨著影像解析度的增加與所蒐集資訊更多元(近紅外光、多光譜、光達)，樹種的分類已經朝向半自動或自動分類識別單株林木樹冠的方法（Wulder,1998; Bolduc et al.,1999; Erikson, 2004）。
- 使用遙測資料對林木進行自動判釋與繪製樹種分布，一直是遙測和森林生態學家的重要研究目標之一(Condit et al.,2000; Ferreira et al., 2016; Laybros et al., 2019; Weinstein et al., 2020)。

傳統統計方法

- Regression techniques(Féret and Asner, 2013)
- Multinomial regression(Waser et al., 2011)
- Principal component analysis (PCA, Mamoru and Ken-ichiro, 2005; Pal and Mather, 2006)
- Linear discriminant analysis (LDA, Kim et al., 2009;Immitzer et al., 2012)
- 廣義線性模型（generalized linear models, GLM），被用於建立樹種群落空間分佈的預測模型（Guisan et al., 2004）。

機器學習與深度學習

- **機器學習**
- Random Forest (RF, Immitzer et al.,2012)
- Support vector machine (SVM, Kulikova et al., 2007)
- Bayesian classifier(Saatchi and Rignot, 1997)
- Maximum likelihood classification(Warner et al., 2006)
- etc.

- **深度學習技術**引領影像分類革命，開始於2012年AlexNet（Krizhevsky et al., 2012）。
- SNN, DNN and CNN(Botella et al., 2018)
- U-net(Wagner et al., 2020)
- etc.

機器學習的分類器

- 50+機器學習分類器研究，大多應用於4至40種樹種，分類準確性(Classification accuracies)約為63%至98%。

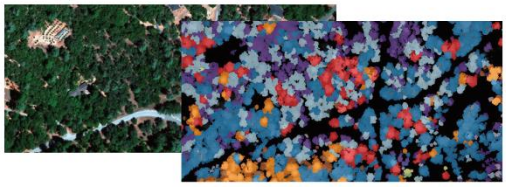

難點

- (1)運用遙測影像進行樹種分布圖的繪製，在許多的研究中證明是一項艱鉅的挑戰(Fassnacht et al.,2016)
- (2) 樹木受到光照、形狀、大小、紋理，以及鄰近樹冠的混合效應，使樹木冠層呈現高度結構複雜性(Fricker et al., 2019)
- (3)用於訓練分類器的空間精確與地真資料(Fricker et al., 2019)。

- 為了克服這些挑戰，在遙感資料種類和分類技術方面，採取了許多不同的方法。

文獻回顧

- Tree species identification on large-scale aerial photographs in a tropical rain forest, French Guiana–application for management and conservation.
- Tree Species Discrimination in Tropical Forests Using Airborne Imaging. Spectroscopy.
- Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images.
- A Convolutional Neural Network Classifier Identifies Tree Species in Mixed-Conifer Forest from Hyperspectral Imagery.
- Cross-site learning in deep learning RGB tree crown detection.

Tree species identification on large-scale aerial photographs in a tropical rain forest, French Guiana –application for management and conservation

- Trichon and Julien, 2016

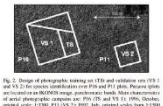

Data set and method

- The Paracou Experimental Station in French Guiana.
- Over 119 ha (16 plots), trees above 10 cm dbh are labelled, inventoried and monitored.
- Aerial photographs
- used a FM2 Nikon camera with a 35 mm(Fuji colour slides)
- Scale 1:1500, 1:3000 and 1:8000

Class of criteria

- Crown size
- Crown status
- Crown contour
- Crown architecture
- Foliage cover
- Foliage texture
- Colour
- **Phenoloy**

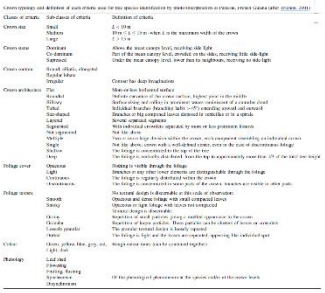

Table 2
Crown key features for the 12 SGS (species or group of species) observed on a training set area (part of P16 plot), Paracou experimental station, French Guiana (after Trichon, 2001)

SGS (species or group of species) *botanical name*, family	Crown key features
Angélique *Dicorynia guianensis*, Caesalpiniaceae	Large, co-dominant to emergent, deep, rounded, opaceous to light foliage, dark to greyish green, grainy to granular texture
Carapa *Carapa procera*, Meliaceae	Small, multiple crown, tufted branches and star-shaped crownlets
Diaguidia *Sclerolobium melinonii*, Caesalpiniaceae	Medium, co-dominant, round, layered, opaceous and continuous yellowish green foliage, grainy texture
Gonfolo gris *Ruizterania albiflora*, Vochysiaceae	Large, emergent, round, opaceous and continuous light green foliage, granular texture (crownlets)
Gonfolo rose *Qualea rosea*, Vochysiaceae	Large, codominant to emergent, cauliflower-like crown, opaceous and continuous dark green foliage, smooth texture
Goupi *Goupia glabra*, Celastraceae	Large, co-dominant, tufted, opaceous to light foliage bluish green to grey, smoky texture
Grignon *Ocotea rubra*, Lauraceae	Large, co-dominant to emergent, deep and billowy crown, discontinuous light green foliage, loosely granular texture
Kimboto *Pradosia cochlearia*, Sapotaceae	Large, emergent, layered, opaceous to light foliage, discontinuous, grey-green to orange, smoky texture
Lebi koko *Licania* spp., Chrysobalanaceae	Small and suppressed, mottled colour green/orange, grainy texture
Maho cigare *Couratari multiflora*, C. spp., Lecythidaceae	Medium, emergent, light and discontinuous foliage, light green to yellow, dotted texture
Symphonia *Symphonia globulifera*, S. sp.1, Clusiaceae	Small, suppressed to emergent, single star-shaped crown
Wacapou *Vouacapoua americana*, Caesalpiniaceae	Medium, co-dominant to suppressed, rounded, opaceous and continuous bluish-green foliage, granular texture

Results

- Tree species of **small size**, whatever their characteristics, **cannot be investigated** through this method.
- **rare species will be difficult to catch** because of the difficulty to get training samples and because their chance to appear in large areas of survey will be low.
- A significant contribution to analysis of very high-resolution(VHR) remote sensing data.

Tree Species Discrimination in Tropical Forests Using Airborne Imaging Spectroscopy

Féret and Asner 2013

Data set and method

- The Nanawale Forest Reserve in Island of Hawaii.
- The spectral data contains 24 spectral bands (390 nm and 1044 nm, resolution: 0.5m)
- **Tree species and indvidual position (GPS)**

- Linear discriminant analysis (LDA)
- Quadratic discriminant analysis (QDA)
- Regularized discriminant analysis (RDA)
- k-nearest neighbor algorithm (k-NN)
- Artificial neural networks (ANNs)
- linear SVM(L-SVM)
- RBF-SVM

TABLE III
DESCRIPTION OF THE CLASSIFIERS STUDIED, THE FREE PARAMETERS TO OPTIMIZE, AND THE OPTIMIZATION METHOD APPLIED

Algorithm	Type	Free parameters	Optimization
LDA	Parametric	/	/
QDA	Parametric	/	/
RDA	Parametric	λ, γ_{RDA}	Exhaustive grid-search, LOO-CV
k-NN	Non-Param.	*K*	LOO-CV
MLP-ANN	Non-Param.	α, nb. epochs, nb. layers, nb. neurons per layer	Trial and error, 2-fold CV
L-SVM	Non-Param.	*C*	Exhaustive grid-search, 10-fold CV
RBF-SVM	Non-Param.	C, γ_{SVM}	Exhaustive grid-search, 10-fold CV

Species

TABLE I
PURE SPECIES IDENTIFIED AND LOCATED IN THE CAO-ALPHA IMAGERY

Species	Code	Pixels	Crowns	$\bar{X}_{PIXELS/CROWN}$
Aleurites moluccana	ALEMOL	6,745	168	40.1
Cananga orodata	CANORD	117	1	117.0
Cecropia peltata	CECPEL	7,039	138	51.0
Cocos nucifera	COCNUC	228	10	22.8
Eucalyptus robusta	EUCROB	3,900	22	177.3
Flindersia brayleyana	FLIBRA	357	4	89.3
Mangifera indica	MANIND	53,719	160	335.7
Melochia umbellata	MELUMB	425	6	70.8
Metrosideros polymorpha	METPOL	259	23	11.3
Pandanus tectorius	PANTEC	2,574	40	64.4
Persea americana	PERAME	208	2	104.0
Pithecellobium saman	PITSAM	5,885	46	127.9
Psidium cattleianum	PSICAT	2,472	58	42.6
Psidium guajava	PSIGUA	2,109	50	42.2
Syzygium jambos	SYZJAM	4,886	16	305.4
Trema orientalis	TREORI	16,154	46	351.2
Zingiber zerumbet	ZINZER	122	1	122.0

TABLE II
DATA CORRESPONDING TO CANOPY CROWNS CONTAINING MIXED SPECIES IDENTIFIED AND LOCATED IN THE CAO-ALPHA IMAGERY

Species combination	Pixels	Crowns	$\bar{X}_{PIXELS/CROWN}$
ALEMOL + CECPEL	1,707	12	142.3
ALEMOL + PANTEC	292	3	97.3
CECPEL + Bambusa vulgaris	241	1	241.0
CECPEL + MANIND	197	2	98.5
CECPEL + MELUMB	114	1	114.0
CECPEL + METPOL	223	3	74.3
CECPEL + PANTEC	5,895	70	84.2
CECPEL + PANTEC + MANIND	163	7	23.3
CECPEL + PSIGUA	1,799	20	90.0
CECPEL + TREORI	539	2	269.5
PANTEC + PSIGUA	325	4	81.3
PITSAM + PSICAT	1,137	4	284.3

Results

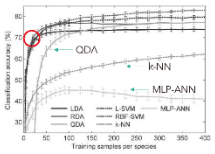

Fig. 1. Variation of classification accuracy (+1 SD) with respect to an increasing training sample size per species, performed with parametric classifiers (solid lines) and nonparametric classifiers (dotted lines). Classification includes ten species.

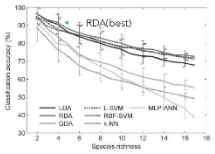

Fig. 2. Variation of classification accuracy (+1 SD) with the species richness level, performed with parametric classifiers (solid lines) and nonparametric classifiers (dotted lines). Training data includes 50 samples per species and 17 species are included in the experiment.

Results

RDA TRAINED WITH 50 SAMPLES

Species	Producer's accuracy (%)	User's accuracy (%)
ALEMOL	86.9	90.2
CANORD	79.3	80.6
CECPEL	49.7	41.1
COCNUC	91.3	97.1
EUCROB	89.9	96.4
FLIBRA	63.2	77.6
MANIND	90.1	82.7
MELUMB	59.9	52.9
METPOL	86.8	84.8
PANTEC	54.9	55.3
PERAME	85.7	88.3
PITSAM	53.8	50.8
PSICAT	62.1	53.6
PSIGUA	47.4	47.7
SYZJAM	98.1	98.9
TRIORI	72.0	79.7
ZINZER	72.7	86.1
Overall accuracy (%)		73.2

Species / mixed species	Producer's accuracy (%)	User's accuracy (%)
ALEMOL + CECPEL	27.6	28.1
ALEMOL + PANTEC	62.5	64.4
CECPEL + MANIN	55.5	52.8
CECPEL + MELUMB	93.8	90.3
CECPEL + METPOL	66.7	73.4
CECPEL + PANTEC	13.6	14.2
CECPEL + PANTEC + MANIND	70.4	67.3
CECPEL + PSIGUA	43.4	36.0
CECPEL + TREORI	45.3	52.6
CECPEL + Bambusa vulgaris	57.9	69.0
PITSAM + PSICAT	54.1	60.3
PSIGUA + PANTEC	62.1	73.4
Overall Accuracy (%)		61.7

Results

- The **spatial information** improves spectral classification.
- The **increasing confusion** induced by **mixed pixels of canopy**.
- Information about **canopy structure cannot be retrieved easily** from **spectroscopic measurements**.
- This study shows the potential of VIS/NIR hyperspectral imagery to identify species in tropical forests.
- Recent advances in 3-D segmentation using LiDAR show very promising results for tree species classification.

Comparison of support vector machine, random forest and neural network classifiers for tree species classification on airborne hyperspectral APEX images

Raczko and Zagajewski, 2017

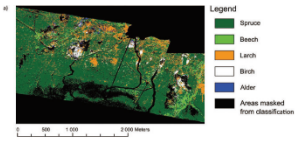

Data set and method

- The Karkonosze National Park, Poland
- APEX hyperspectral data.(380–2500 nm, 222-band dataset
- ->40 bands selection by PCA)
- Spatial resolution: 3.35m.
- 5 m tall were considered as valid location sources.
- Non-forested areas were masked by NDVI.(lower than 0.2)
- SVM, RF and ANN (R statistical software, "e1071", "randomForest", "nnet" package)

classification accuracy

- Of all compared classification results, ANN achieved the highest median overall classification accuracy (77%) followed by SVM with 68% and RF with 62%.
- ANN had the highest median kappa, at 0.72, while SVM and RF had 0.61 and 0.52 median kappa, respectively.

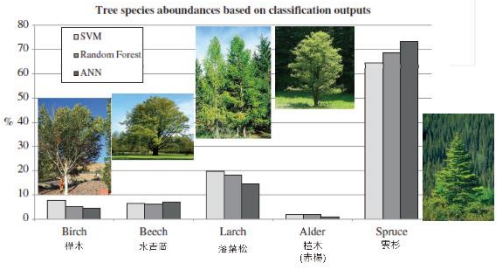

Results

- Optimal training pixels of SVM and RF.
- Some studies recommended at least **400 pixels** per class as the optimal number of pixels for classification purposes (Kavzoglu & Mather, 2003).
- using 60 pixels per class (Fassnacht et al., 2014; Ghosh et al., 2014).
- every classified species is represented by **120 pixels**.

A Convolutional Neural Network Classifier Identifies Tree Species in Mixed-Conifer Forest from Hyperspectral Imagery

Fricker et al., 2019

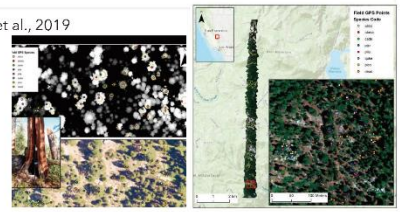

Data set and method

- Teakettle Experimental Forest (TEF) in the Southern Sierra Nevada Mountains.
- The airborne remote sensing **LiDAR and hyperspectral** imagery data(resolution 1m, **NEON's program**)
- The "overstory" trees with large canopies. (tree sizes >5 m tall).

Tree species

Table 1. The scientific name, common name, four-letter abbreviated species code, and the number of trees per species used in our study.

Code	Scientific Name (Common Name)	Abbreviation	Number
0	*Abies concolor* (White fir)	abco	119
1	*Abies magnifica* (Red fir)	abma	47
2	*Calocedrus decurrens* (Incense cedar)	cade	66
3	*Pinus jeffreyi* (Jeffrey pine)	pije	164
4	*Pinus lambertiana* (Sugar pine)	pila	68
5	*Quercus kelloggii* (Black oak)	quke	18
6	*Pinus contorta* (Lodgepole pine)	pico	62
7	Dead (any species)	dead	169

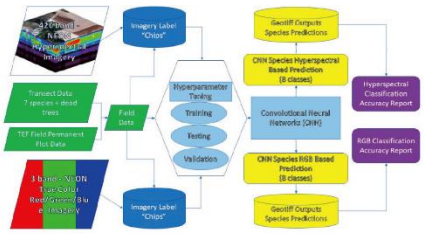

Research objectives

- Evaluate the application of CNNs to identify tree species in hyperspectral imagery compared to a Red-Green-Blue (RGB) imagery.
- Assess the accuracy of the tree species classification using a test dataset which is distinct from the training and validation data.

Results

- The best hyperparameter settings of CNN
- patch size of L = 15
- regularization strength of $\alpha = 0.001$
- C = 32 filter kernels in the first convolutional layer up to a maximum of C' = 128 kernels.

Results

Table 2. Summary results table reporting the precision, recall and F-Score for the average of 10 folds of the k-fold cross validation for both the Red-Green-Blue subset and hyperspectral imagery.

Species	Species Code	Hyperspectral			RGB		
		Precision	Recall	F-score	Precision	Recall	F-Score
White fir	0	0.76	0.81	0.78	0.46	0.53	0.49
Red fir	1	0.76	0.72	0.74	0.41	0.30	0.35
Incense cedar	2	0.90	0.85	0.88	0.50	0.44	0.47
Jeffrey pine	3	0.93	0.96	0.95	0.65	0.73	0.69
Sugar pine	4	0.90	0.96	0.93	0.67	0.68	0.67
Black oak	5	0.73	0.61	0.67	0.69	0.61	0.65
Lodgepole pine	6	0.84	0.87	0.86	0.54	0.47	0.50
Dead	7	0.90	0.85	0.88	0.88	0.86	0.87
Ave/Total		0.87	0.87	0.87	0.64	0.64	0.64

Results

- The hyperspectral CNN model outperformed the RGB CNN model by 23% on average.

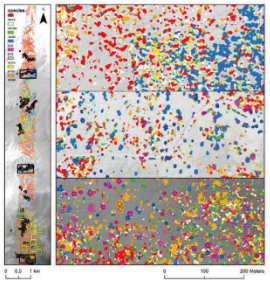

Fig 4. hyperspectral CNN, a: high, mid, and lower elevation sites.

Cross-site learning in deep learning RGB tree crown detection

Weinstein et al., 2020

Data set and method

- National Ecology Observation Network (NEON) Airborne Observation Platform.
- San Joaquin Experimental Range, California.
- RGB data are a 1 km × 1 km (GSD: 0.1m)
- LiDAR data (4-6 points/m^2)

- Hand annotations
- to a LiDAR canopy height model and removed any trees less than 3 m in height.(vegetation >3 m in height).)
- LiDAR tree detection-the lidR R *package*

- *Convolutional ncural networks*

Conceptual workflow of proposed approach for airborne detection of individual tree crowns.

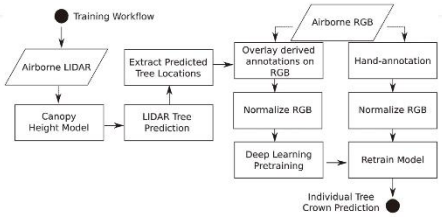

Ablation curves of the proportion of hand-annotation training data for each site.

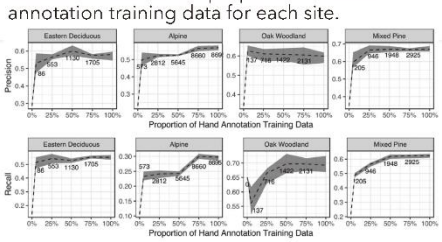

Classification accuracy

- Within-site predictions ranged from 0.60 recall and 0.75 .
- Mixed Pine to 0.34 recall and 0.55 precision in Alpine.
- Eastern Deciduous site from 0.44 and Oak Woodland from 0.6.
- Remote sensing methods have limited ability to quantify **small and subcanopy trees** (Aubry-Kientz et al., 2019), and RGB only methods are particularly susceptible to this limitation because they cannot see trees below the sun-exposed canopy.

航遙測樹種分類趨勢

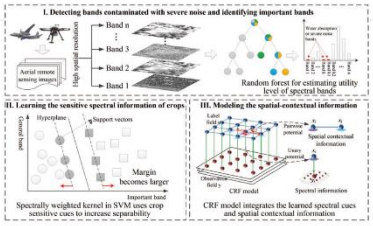

(Zhao et al., 2020)

高解析度影像+多光譜資料

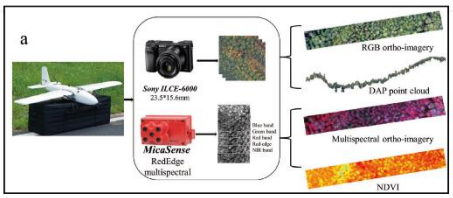

(Xu et al., 2020)

建議樹種辨識加入衛星影像光譜資訊

- Sentinel-2的春季和秋季的red-edge和SWIR band，對於分類樹種有顯著的效果，反應林木物種之間物候差異(Persson et al., 2018)。

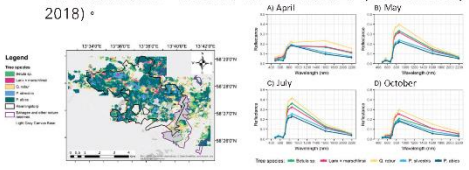

結合LiDAR與光譜資料

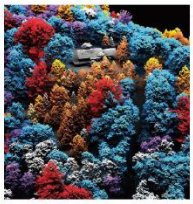

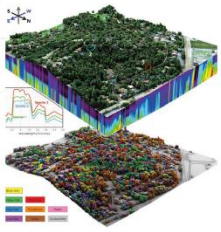

結語

- 台灣林分常由多種樹種混合組成與相鄰重疊複冠，在林型分類上具有挑戰性。
- 國際在應用機器學習辨識林型/樹種研究趨勢，包含考量整合多元遙測資料、多時期影像與加入3D資訊。
- 多時期影像資料，建議嘗試加入衛星影像遙測光譜資訊，補充山區航測影像物候資訊。
- 3D資料，LiDAR的DTM可提供地形資訊，與立地環境條件。DSM與DTM相減可計算CHM，提供林木樹高與冠幅相關資訊。
- 建立一套航攝影像與森林覆蓋型機器學習技術，達到自動化判釋林型，輔助傳統航照判釋。

•THANKS

•Q & A

https://tinyurl.com/NIU3dm-2020

AI 工程師 – 王選仲

農航所森AI案教育訓練
農航所之AI實務 - 以林型判釋為例
2020.10.26
研發工程師 王選仲
THINKTRON 興創知能股份有限公司

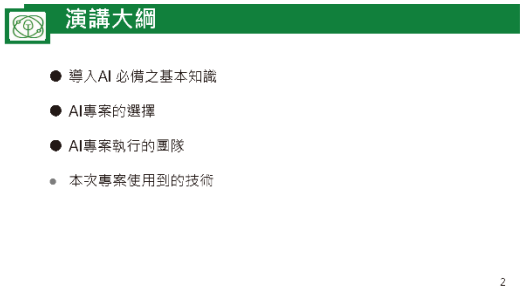
演講大綱
導入AI 必備之基本知識
AI專案的選擇
AI專案執行的團隊
本次專案使用到的技術
2

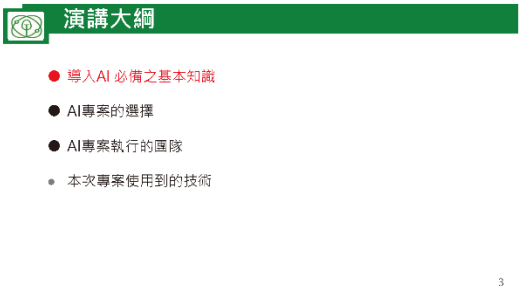
演講大綱
導入AI 必備之基本知識
AI專案的選擇
AI專案執行的團隊
本次專案使用到的技術
3

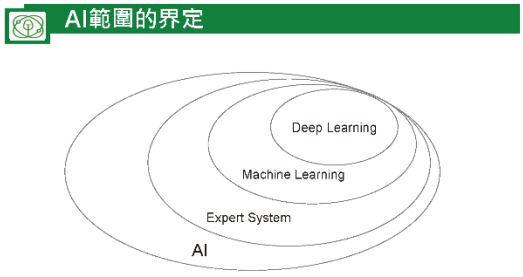
AI範圍的界定
Deep Learning
Machine Learning
Expert System
AI
4

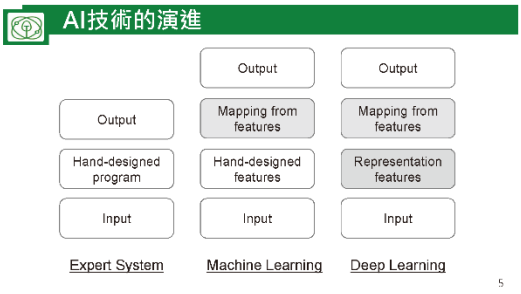
AI技術的演進
Output
Output
Mapping from features
Hand-designed program
Hand-designed features
Representation features
Input
Input
Input
Expert System
Machine Learning
Deep Learning
5

AI技術的演進
專家系統
機器學習
深度學習
特徵值萃取
人
人
機器
判斷邏輯
人
機器
機器
6

AI 系統的規劃與執行

7

AI 的技術範疇及演算法

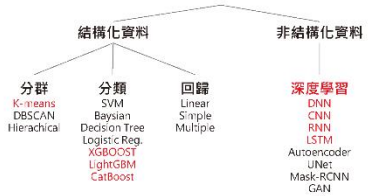

8

AI 的任務類型

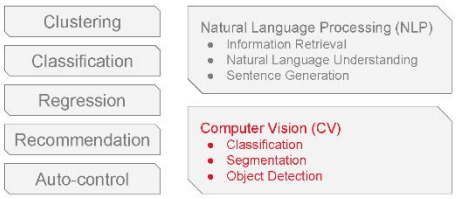

9

What is the Task

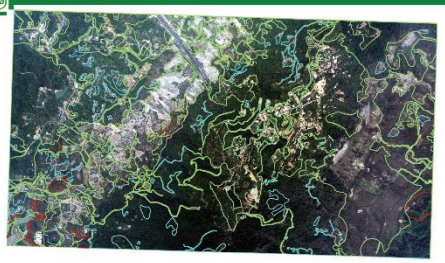

10

AI 的驗證方法

1. 訓練資料 & 驗證資料 & 測試資料
   a. 訓練資料(60%)
   b. 驗證資料(20%)
   c. 測試資料(20%); 最好大於1000筆
2. 評價標準
   a. 類別資料(兩類或多類):
      i. Accuracy
      ii. Precision & Recall
      iii. F1-Score
   b. 連續資料:
      i. Mean Square Error (MSE)
      ii. Root Mean Square Error (RMSE)
      iii. Mean Absolute Error (MAE)
   c. Segmentation: Overlapping rate

11

AI 的評價標準 - 類別資料

整體經度 $= \frac{TP+TN}{TP+TN+FP+FN}$

生產者經度 $= \frac{TP}{TP+FP}$

使用者經度 $= \frac{TP}{TP+FN}$

$$F-score = \frac{2}{1/precision + 1/recall}$$

Confusion Matrix

		Model判定	
		Positive	Negative
正確答案	True	TP	TN
	False	FP	FN

12

AI 的評價標準 - 連續變數

Metric	Definition
Mean Squared Error (MSE)	$MSE = \frac{\sum_{i=0}^{N-1}(y_i - \hat{y}_i)^2}{N}$
Root Mean Squared Error (RMSE)	$RMSE = \sqrt{\frac{\sum_{i=0}^{N-1}(y_i - \hat{y}_i)^2}{N}}$
Mean Absoloute Error (MAE)	$MAE = \sum_{i=0}^{N-1} \lvert y_i - \hat{y}_i \rvert$

13

AI 的評價標準 - Segmentation

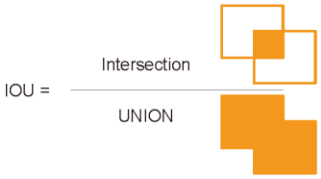

14

標記資料提供義務

人可以舉一反三，
AI 只能舉三反一。

15

AI 系統的規劃與執行

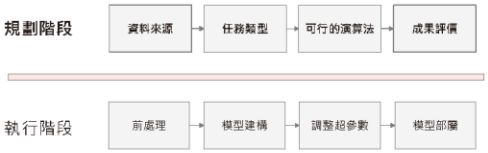

16

演講大綱

- 導入AI 必備之基本知識
- AI專案的選擇
- AI專案執行的團隊
- 本次專案使用到的技術

17

如何選擇AI專案

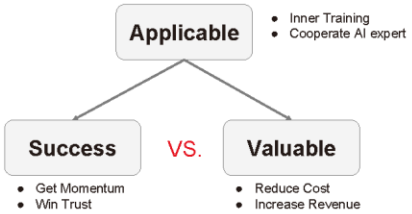

18

如何選擇AI專案

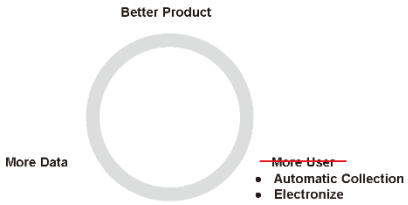

19

演講大綱

- 導入AI 必備之基本知識
- AI專案的選擇
- AI專案執行的團隊
- 本次專案使月到的技術

20

執行團隊的架構

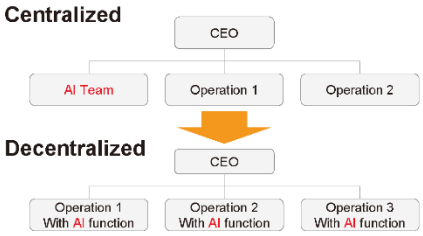

21

團隊的成就來源

團隊的成就來源

演講大綱

- 導入AI 必備之基本知識
- AI專案的選擇
- AI專案執行的團隊
- 本次專案使月到的技術

24

AI 系統的規劃與執行

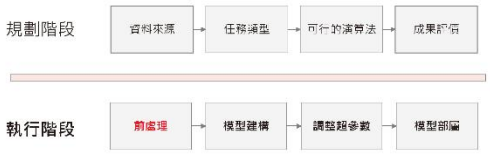

25

前處理 - 素材

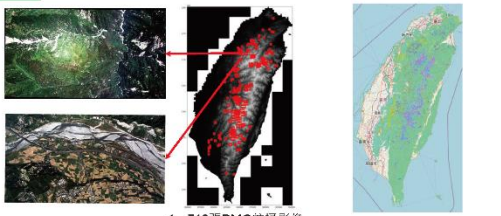

1. 718張DMC航攝影像
2. 含台20m DEM
3. 第四次森林資源調查林型圖

26

前處理 - 目標與規劃

1. 反投影: 把林型圖投影到影像上
   a. 反投影要以「網格」或是「向量」進行?
   b. 直接使用20m DEM當作高程進行反投影?
   c. 地面物件(林型圖、DEM、Slope、Aspect...)都要逐一反投影?

1. 創造訓練資料: 切圖至模型可接受大小(e.g. 256 * 256)
   a. 反投影偏移如何處理?
   b. 要做成pixel based的Label或是image based的Label?

27

TronGisPy

- Python 介面的GIS全功能套件
- GIS網格資料AI前處理套件

1. Raster: 存儲Raster檔案所需的所有資訊
2. CRS: 座標系統轉換(epsg/wkt, npidx/coords)
3. TypeCast: 資料格式轉換(gdal/numpy)
4. ShapeGrid: 網格資料與像量資料的互動
5. Normalizer: 正規化影像的數值分布
6. AeroTriangulation: 空中三角模型
7. Interpolation: 網格遺漏值內插
8. SplittedImage: 圖片切割創造訓練資料
9. DEMProcessor: 產制DEM的特徵值
10. GisIO: File-based GIS Operation

TronGisPy

28

前處理 - 地文因子產制

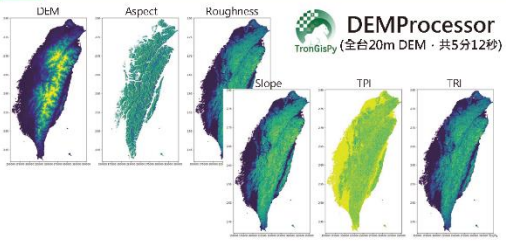

前處理- 網格化林型圖

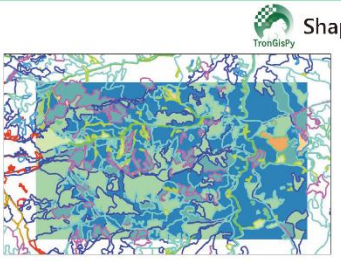

30

前處理- 內插DEM

Interpolation

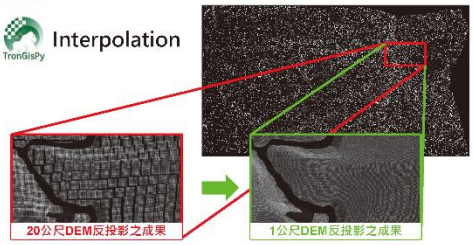

31

前處理- 反向投影程式撰寫

AeroTriangulation
(加速: 10 min => 0.5 sec)

$$x_i = x_0 - f\frac{m_{11}(X_i - X_0) + m_{12}(Y_i - Y_0) + m_{13}(Z_i - Z_0)}{m_{31}(X_i - X_0) + m_{32}(Y_i - Y_0) + m_{33}(Z_i - Z_0)}$$
$$y_i = y_0 - f\frac{m_{21}(X_i - X_0) + m_{22}(Y_i - Y_0) + m_{23}(Z_i - Z_0)}{m_{31}(X_i - X_0) + m_{32}(Y_i - Y_0) + m_{33}(Z_i - Z_0)}$$

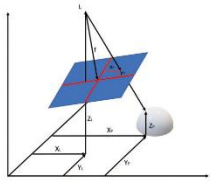

32

前處理- 反向投影遮蔽問題

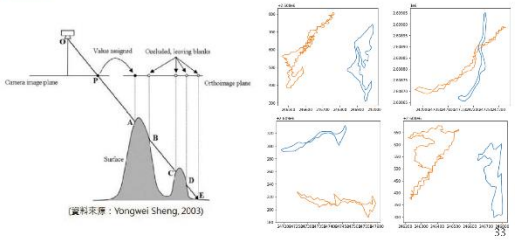

33

前處理- 反向投影遮蔽問題解決方案

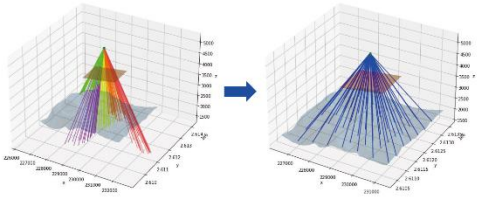

34

前處理- 填空反投影結果

Interpolation
(加速: 60 min => 0.5 min)

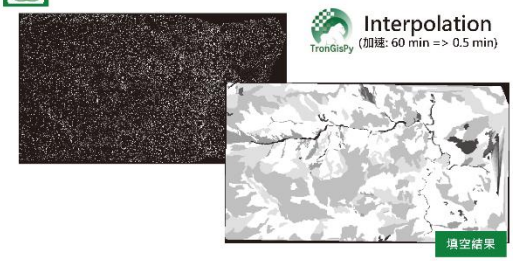

前處理 - 反投影成果

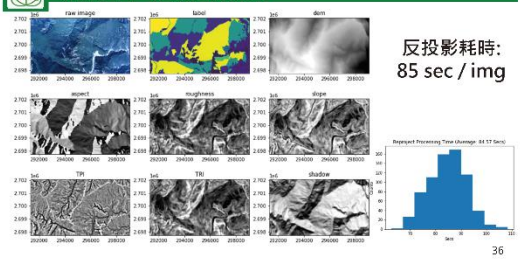

反投影耗時:
85 sec / img

36

尚未解決的問題 - DEM vs. DSM

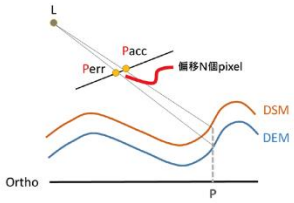

Pacc：利用DSM反投影後影像的正確位置
Perr：利用DEM反投影後影像的錯誤位置

37

尚未解決的問題 - DEM vs. DSM

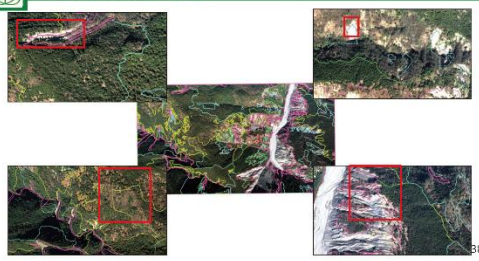

38

前處理 - 暫時性解決方案: 內縮多邊形

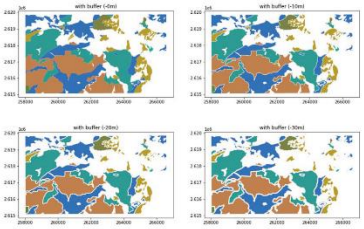

39

前處理 - 暫時性解決方案: 內縮多邊形

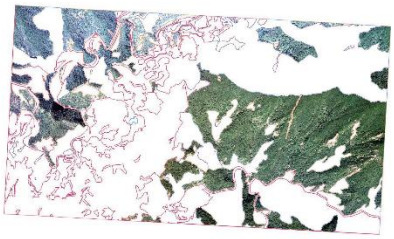

40

前處理 - 創造訓練資料

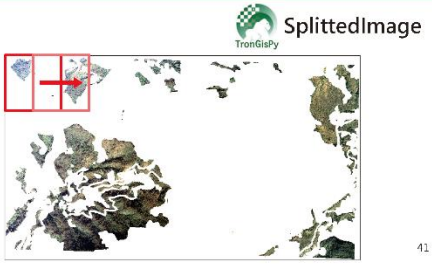

41

前處理 - 創造訓練資料成果

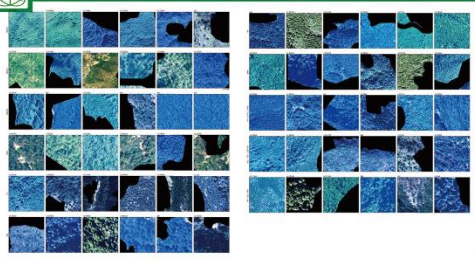

42

前處理 - 創造訓練資料統計

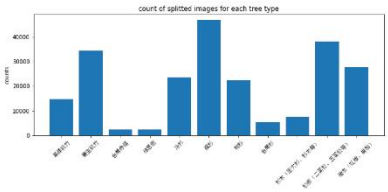

43

AI 系統的規劃與執行

44

How CNN Works

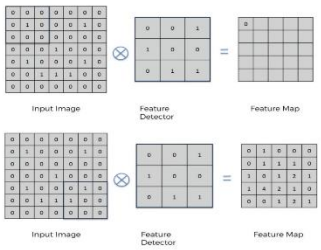

45

Why CNN Works

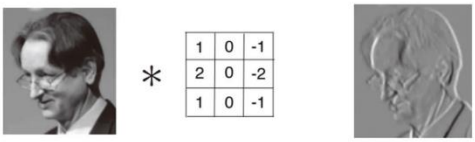

46

Pooling Layer

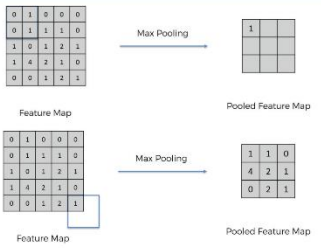

47

Why CNN Extract Features

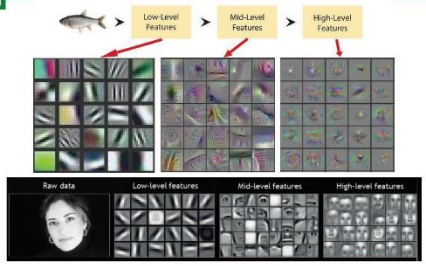

48

Classification (CNN + DNN)

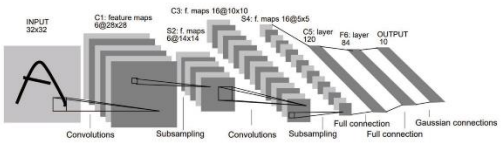

49

Semgentation (U-Net)

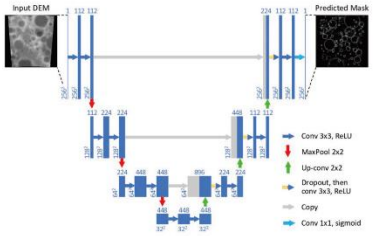

50

Object Dection (Yolo)

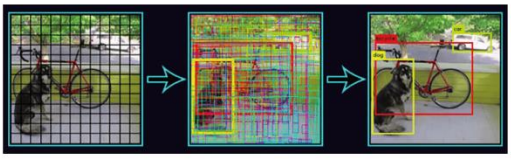

51

AI 系統的規劃與執行: To Be Continue

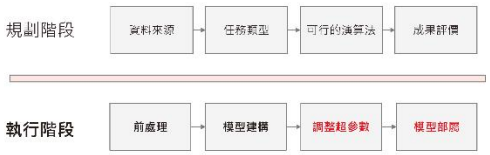

52